

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

JOÃO LUDOVICO MAXIMIANO BARBOSA

**PLATAFORMA COMPUTACIONAL PARA
ANÁLISE DE SINAIS EEG BASEADA EM PYTHON
APLICADA A INDIVÍDUOS EM COMA E
ESTIMULAÇÃO MUSICAL DE INDIVÍDUOS
NORMAIS**

UBERLÂNDIA – MG

2025

JOÃO LUDOVICO MAXIMIANO BARBOSA

**PLATAFORMA COMPUTACIONAL PARA ANÁLISE
DE SINAIS EEG BASEADA EM PYTHON APLICADA
A INDIVÍDUOS EM COMA E ESTIMULAÇÃO
MUSICAL DE INDIVÍDUOS NORMAIS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia, como requisito parcial para obtenção do título de Doutor em Ciências.

Área de Concentração: Engenharia Biomédica

Linha de Pesquisa: Sistemas Computacionais e Dispositivos Aplicados à Saúde

Orientador: Dr. João Batista Destro Filho
Coorientador: Dr. Murillo G. Carneiro

UBERLÂNDIA – MG

2025

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

B238
2025 Barbosa, João Ludovico Maximiano, 1991-
 Plataforma computacional para análise de sinais EEG baseada
 em python aplicada a indivíduos em coma e estimulação musical
 de indivíduos normais [recurso eletrônico] / João Ludovico
 Maximiano Barbosa. - 2025.

Orientador: João Batista Destro Filho.

Coorientador: Murillo Guimarães Carneiro.

Tese (Doutorado) - Universidade Federal de Uberlândia,
Doutorado em Engenharia Biomédica.

Modo de acesso: Internet.

DOI <http://doi.org/10.14393/ufu.te.2025.724>

Inclui bibliografia.

Inclui ilustrações.

1. Engenharia biomédica. I. Destro Filho, João Batista ,1970-,
(Orient.). II. Carneiro, Murillo Guimarães,1988-, (Coorient.). III.
Universidade Federal de Uberlândia. Doutorado em Engenharia
Biomédica. IV. Título.

CDU: 62:61

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091

Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
Coordenação do Programa de Pós-Graduação em Engenharia
Biomédica

Av. João Naves de Ávila, 2121, Bloco 3N, Sala 115 - Bairro Santa Mônica, Uberlândia-MG,
CEP 38400-902

Telefone: (34) 3239-4761 - www.ppgeb.feelt.ufu.br - ppegb@feelt.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Biomédica				
Defesa de:	Tese; 015, PPGEb				
Data:	onze de dezembro de dois mil e vinte e cinco	Hora de início:	15:30	Hora de encerramento:	19:00
Matrícula do Discente:	11923EBI005				
Nome do Discente:	João Ludovico Maximiano Barbosa				
Título do Trabalho:	Plataforma computacional para análise de sinais EEG baseada em <i>python</i> aplicada a indivíduos em coma e estimulação musical de indivíduos normais				
Área de concentração:	Engenharia Biomédica				
Linha de pesquisa:	Tecnologias em Radiações, Imagens Médicas e Biológicas				
Projeto de Pesquisa de vinculação:	Estudo do efeito da estimulação musical baseado em eletroencefalografia				

Reuniu-se via plataforma Teams, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Biomédica, assim composta: Professores Doutores: Aurélia Aparecida de Araújo Rodrigues - IME/UFU; Milena Bueno Pereira Carneiro - FEELT/UFU; Renato Tinós - FFCL-USP/Ribeirão Preto; Francisco Fambrini - Univesp/SP; João Batista Destro Filho - PPGEb/UFU orientador do candidato.

Iniciando os trabalhos o presidente da mesa, Dr. João Batista Destro Filho, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **João Batista Destro Filho, Professor(a) do Magistério Superior**, em 26/01/2026, às 16:40, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Milena Bueno Pereira Carneiro, Professor(a) do Magistério Superior**, em 27/01/2026, às 00:58, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Renato Tinós, Usuário Externo**, em 27/01/2026, às 08:09, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Francisco Fambrini, Usuário Externo**, em 27/01/2026, às 11:06, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Aurelia Aparecida de Araújo Rodrigues, Professor(a) do Magistério Superior**, em 27/01/2026, às 15:32, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6958225** e o código CRC **27175AD3**.

Dedico este trabalho aos meus queridos familiares, cujo amor, apoio e incentivo foram fundamentais para a realização deste sonho, que também é de vocês. A todos os professores e amigos que contribuíram para meu desenvolvimento acadêmico e científico, meu sincero agradecimento por me inspirarem a buscar sempre o conhecimento. Aos que acreditaram em mim e estiveram ao meu lado em todos os momentos, deixo minha eterna gratidão. E a mim mesmo, pela persistência e dedicação ao longo dessa jornada; que este esforço seja apenas o início de muitas conquistas.

AGRADECIMENTOS

Concluir esta tese representa não apenas o encerramento de uma etapa acadêmica, mas também a celebração de uma jornada repleta de desafios, descobertas e crescimento pessoal. Muitas pessoas foram fundamentais nesse percurso, e é com profunda gratidão que registro aqui meu reconhecimento.

Ao professor João Batista Destro Filho, meu orientador, agradeço por ter aceitado caminhar ao meu lado desde o início, enfrentando comigo os altos e baixos dessa trajetória. Sua escuta atenta, sua postura ética e seu olhar humano foram essenciais para que eu me mantivesse firme. Mais do que um orientador, foi um verdadeiro guia, cuja competência e generosidade deixaram marcas profundas na minha formação.

Ao professor Murillo Guimarães Carneiro, meu coorientador, sou grato pela parceria intelectual e pela troca constante de ideias. Sua dedicação, disponibilidade e entusiasmo foram fundamentais para o desenvolvimento dos artigos, para as participações em congressos e para o amadurecimento da pesquisa. Apreendi muito com sua forma de pensar e fazer ciência.

À minha mãe, Maria Barbosa da Silva, minha maior fonte de força e inspiração. Sua presença constante, mesmo nos momentos em que tudo parecia desmoronar, foi o que me sustentou. Seu amor, suas palavras de incentivo e sua fé em mim foram o combustível que me manteve em movimento. Esta conquista também é sua.

Ao Programa de Pós-Graduação em Engenharia Biomédica (PPGEB) da Universidade Federal de Uberlândia, agradeço pela estrutura acadêmica, pelo corpo docente comprometido e pelas oportunidades de aprendizado que me foram oferecidas. Aos funcionários da UFU, especialmente ao Edson, secretário do PPGEB, deixo meu reconhecimento pelo apoio prestativo e pela atenção em momentos decisivos. O cuidado com os estudantes faz toda a diferença.

Ao Jaime Dos Reis Leles Junior, meu coordenador de trabalho, sou profundamente grato pela compreensão e pelo incentivo constante. Sua sensibilidade em permitir que eu me dedicasse à tese em momentos cruciais foi determinante para que eu pudesse concluir este ciclo.

Aos meus amigos e familiares, que compreenderam minhas ausências, meu silêncio e minha dedicação quase exclusiva à pesquisa. Obrigado por respeitarem meu tempo, por torcerem por mim e por nunca deixarem de acreditar que tudo isso valeria a pena.

A todos que, de alguma forma, contribuíram direta ou indiretamente para a realização deste trabalho, meu sincero agradecimento.

Por fim, agradeço a mim mesmo, pela persistência, pela coragem de seguir mesmo quando tudo parecia difícil, e por nunca perder de vista o propósito que me trouxe até aqui.

*"Eu sei que a vida é curta pra viver
Mas tem tanto tempo pra aprender
Tanto tempo pra se jogar*

*Quanto tempo até você perceber?
Que os seus sonhos só
Dependem de você!!!*

Kélvyn Vieira

RESUMO

O eletroencefalograma (EEG) permite o registro não invasivo da dinâmica elétrica cerebral a partir do escalpo, sendo crucial para investigar processos cerebrais. No entanto, a complexidade dos sinais e a necessidade de ampliar o acesso às análises motivaram a migração de um *software* de processamento originalmente desenvolvido em uma plataforma computacional para Python, uma linguagem *openSource*.

Durante a transcrição foram incorporadas melhorias funcionais, incluindo rotinas customizadas de pré-processamento, critérios para descarte de canais ruidosos, seleção de quantificadores e parâmetros ajustáveis, além do desenvolvimento de uma interface gráfica que facilitou a adoção e o treinamento de pesquisadores com diferentes níveis de experiência.

Embora a versão da plataforma computacional tenha apresentado desempenho superior na etapa de pré e processamento, chegando a ser cerca de 60 vezes mais rápida, e tenha gerado arquivos de dados processados cinco vezes menores, a versão em Python garantiu equivalência funcional nos quantificadores calculados, com erro relativo irrelevante (da ordem de 10^{-12}), exceto para o quantificador de coerência, que possui um algoritmo ligeiramente distinto. Foram desenvolvidas rotinas estatísticas para avaliar efeitos da estimulação musical, nas quais o quantificador porcentagem de contribuição de potência (PCP), especialmente nas bandas delta e alfa, revelou-se mais informativo que a frequência mediana (FM).

Ao aplicar técnicas de inteligência artificial para classificar sinais em tarefas clínicas e musicais. Na base de dados do prognóstico do coma, obteve-se F1 Score (macro) de 90%; para a classificação da etiologia do coma, 63% de acurácia, que aumentou para 70% ao remover exames da categoria “outros”; e na classificação de estímulos musicais, com 67% de precisão.

Este trabalho contribui para a disseminação de ferramentas abertas e reprodutíveis em análise de sinais neurofisiológicos e abre caminhos para futuras melhorias e pesquisas na área.

Palavras-chave: EEG, Processamento, Estimulação Sonora, Reconhecimento de Padrões, Inteligência Artificial.

ABSTRACT

The electroencephalogram (EEG) allows the non-invasive recording of brain electrical dynamics from the scalp, being crucial for investigating cerebral processes. However, the complexity of the signals and the need to broaden access to analyses motivated the migration of a processing software originally developed on a computational platform to Python, an openSource programming language.

During the transcription, functional improvements were incorporated, including customized preprocessing routines, criteria for discarding noisy channels, selection of quantifiers, adjustable parameters, and the development of a graphical interface that facilitated adoption and training for researchers with different levels of experience.

Although the computational platform version presented superior performance in the preprocessing and processing stages, being about 60 times faster, and generated processed data files five times smaller, the Python version guaranteed functional equivalence in the calculated quantifiers, with negligible relative error (on the order of 10^{-12}), except for the coherence quantifier, which has a slightly different algorithm. Statistical routines were developed to evaluate the effects of musical stimulation, in which the percentage of power contribution (PCP) quantifier, especially in the delta and alpha bands, proved to be more informative than the median frequency.

Artificial intelligence techniques were applied to classify signals in clinical and musical tasks. In the coma prognosis database, a macro F1 Score of 90% was obtained; for coma etiology classification, 63% accuracy was achieved, increasing to 70% after removing exams in the "others" category; and in musical stimulus classification, 67% accuracy was reached.

This work contributes to the dissemination of open and reproducible tools in neurophysiological signal analysis and paves the way for future improvements and research in the field.

Keywords: EEG, Processing, Sound Stimulation, Pattern Recognition, Artificial Intelligence.

PUBLICAÇÕES

Publicações Resultantes deste Trabalho em Anais de Congressos:

BARBOSA, J. L. M., MAGALHAES, K. A., DESTRO-FILHO, J. B. ESTUDO COMPARATIVO DO PROCESSAMENTO DE SINAIS BIOMÉDICO ATRAVÉS DE DUAS PLATAFORMAS. In: **ANAIS DA CONFERÊNCIA DE ESTUDOS EM ENGENHARIA ELÉTRICA - CEEL XVIII - ISSN 2596-2221**, 2020, Uberlândia MG: Universidade Federal de Uberlândia - UFU, 2020, v. 01. p. 01-05. Disponível em: <https://www.peteletricaufu.com.br/static/ceel/artigos/artigo_604.pdf> Acesso em: 09 nov. 2025.

BARBOSA, J. L. M., CARNEIRO, M. G., BALDO-JÚNIOR, S., TINOS, R., Ji, D., ZHAO, L., DESTRO-FILHO, J. B. Attention to EEG signals: A transformer-based architecture for the Prognosis of Patients in Coma. In: **Proceedings of the International Joint Conference on Neural Networks-IJCNN**, Roma, Italia, 30 Junho a 5 Julho 2025.

BARBOSA, J. L. M., CARNEIRO, M. G., BALDO-JÚNIOR, S., TINOS, R., ZHAO, L., DESTRO-FILHO, J. B. Coma Etiology Prediction Using a CNN-LSTM Model Guided by EEG Brain Regions. In: **Proceedings of 35th Brazilian Conference on Intelligent Systems**, Fortaleza, CE, Brasil, 29 Setembro a 2 Outubro 2025.

Publicações Resultantes deste Trabalho em periódicos científicos:

BALDO-JÚNIOR, S., CARNEIRO, M. G., **BARBOSA, J. L. M.**, ZHAO, L., DESTRO-FILHO, J. B., CAMPOS, M., TINOS, R. A Bioinspired Multimodal CNN-LSTM Network for EEG Analysis of Patients in Coma. **Sensors**, Basel: MDPI, Suíça, 2025.

LISTA DE ILUSTRAÇÕES

Figura 1 - Sistema Internacional de montagem de eletrodos 10-20	34
Figura 2 - Exemplo de traçado de EEG.....	35
Figura 3 - Diagrama de Classe EegRecord.....	60
Figura 4 - Diagrama de Classe Epoch	60
Figura 5 - Diagrama de Classe EegRecordTest.....	61
Figura 6 - Diagrama de Classe EpochTest	61
Figura 7 - Tela inicial da interface gráfica do <i>software</i> em python.....	63
Figura 8 - Tela de processamento do EEG	64
Figura 9 - Tela de sucesso do processamento.....	64
Figura 10 - Tela de falha do processamento.....	64
Figura 11 - Tela para geração topográfica	65
Figura 12 - Tela com alteração de tema da interface gráfica.....	66
Figura 13 - Tempo de processamento em todas as etapas analisadas.....	69
Figura 14 - Etapa de Pré-Processamento e Processamento dos dados.	69
Figura 15 - Seleção do CSV para execução do teste de comparação de versão do <i>software</i>	71
Figura 16 - Janela de comandos durante a execução do testErrorPlatAndPython	72
Figura 17 - Histograma diferenças Coerência.....	74
Figura 18 - Comparação Coerência Python x Plataforma Computacional.....	74
Figura 19 - Exemplo de histograma	81
Figura 20 - Histograma VAP da FM Silêncio após seleção estatística	97
Figura 21 - Histograma VAP do FM demais estímulos após seleção estatística	98
Figura 22 - Histograma VAP do PCP Silêncio após seleção estatística	99
Figura 23 - Histograma VAP do PCP demais estímulos após seleção estatística	100
Figura 24 - VAP acima de 15% para PCP do estímulo Silêncio com os demais estímulos	102
Figura 25 - VAP acima de 15% para PCP outras comparações relevantes	104
Figura 26 - Arquitetura IA CNN-LSTM base adaptado de (BALDO JÚNIOR, 2023)	110
Figura 27 - Arquitetura CNN-LSTM somente com sinal puro adaptado de (BALDO JÚNIOR, 2023).....	111
Figura 28 – Arquitetura utilizando <i>Multi Layer Perceptron</i> (MLP) adaptado de (BALDO JÚNIOR, 2023)	112
Figura 29 - Modelo <i>k-fold</i> de 5 adotado para treinamento das redes neurais	113
Figura 30 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região frontal destacada em vermelho. Os eletrodos FP1, FP2, F7, F8, F3, F4 e FZ correspondem à área frontal.....	117
Figura 31 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região central destacada em amarelo. Os eletrodos C3, C4 e CZ	

correspondem à área central, localizada ao longo da linha média e das áreas laterais do couro cabeludo.....	118
Figura 32 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região occipital destacada em verde. Os eletrodos O1, O2 e OZ correspondem à área occipital, localizada na parte posterior do couro cabeludo, abrangendo o lobo occipital	119
Figura 33 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região parietal destacada em azul. Os eletrodos P3, P4 e PZ correspondem à área parietal, localizada na parte superior e posterior do couro cabeludo, abrangendo o lobo parietal	120
Figura 34 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região temporal destacada em laranja. Os eletrodos T3, T4, T5 e T6 correspondem à área temporal, localizada nas partes laterais do couro cabeludo, abrangendo o lobo temporal	121
Figura 35 - Evolução de cada <i>FOLD</i> do treinamento da base de dados Prognóstico Clínico com os melhores resultados	129
Figura 36 - Arquitetura IA (Modelo <i>Transformer</i> MT) utilizando <i>Transformers</i> através de sinais de EEG como entrada para camadas de <i>TransformerEncoder</i>	132
Figura 37 - Arquitetura IA (Modelo <i>Transformer</i> MT) utilizando <i>Transformers</i> através de sinais de EEG como entrada para camadas de <i>TransformerEncoder</i> , com as características extras adicionadas na camada densa	134
Figura 38 - Arquitetura IA (Modelo CNN- <i>Transformer</i> MCT) utilizando CNN e <i>Transformers</i> através de sinais de EEG como entrada para o CNN seguido das camadas de <i>TransformerEncoder</i> , com as características extras adicionadas na camada densa..	135
Figura 39 - Evolução de cada <i>FOLD</i> do treinamento da base de dados Prognóstico Clínico MCT com os melhores resultados.....	137
Figura 40 - Evolução de cada <i>FOLD</i> do treinamento da base de dados Prognóstico Clínico MT com os melhores resultados	138
Figura 41 - Visualização t-SNE dos dados brutos do EEG e a visão latente após a aplicação das camadas de <i>TransformerEncoder</i> do melhor resultado do Modelo MT ($N_H = 8, INT_D = 64, N_L = 3, DOUT = 0, 1$ e $EPC = 30$) para o primeiro <i>Fold</i>	139
Figura 42 - Visualização t-SNE latente após a aplicação das camadas de <i>TransformerEncoder</i> do melhor resultado do Modelo MT ($N_H = 8, INT_D = 64, N_L = 3, DOUT = 0, 1$ e $EPC = 30$) para o segundo e terceiro <i>Fold</i>	140
Figura 43 - Visualização t-SNE latente após a aplicação das camadas de <i>TransformerEncoder</i> do melhor resultado do Modelo MT ($N_H = 8, INT_D = 64, N_L = 3, DOUT = 0, 1$ e $EPC = 30$) para o quarto e quinto <i>Fold</i>	140
Figura 44 - Evolução de cada <i>FOLD</i> do treinamento da base de dados Etiologia do Coma melhores performances	144
Figura 45 - Evolução de cada <i>FOLD</i> do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rótulo outros, melhores performances.....	146
Figura 46 – Evolução de cada <i>FOLD</i> do treinamento base de dados Estimulação musical (Favorita e Desgostada) melhores performances.....	149

LISTA DE TABELAS

Tabela 1 Características básicas dos <i>software</i> de processamento de EEG pesquisados adaptado de (BARBOSA, 2019).....	40
Tabela 2 - Comparação entre o tamanho dos arquivos gerados pelos processamentos na plataforma computacional e Python	70
Tabela 3 - Erro Relativo comparação Plataforma Computacional x Python	72
Tabela 4 – Sequência de estímulos aplicado na coleta da base de dados de estimulação musical.....	91
Tabela 5 - Exemplo de matriz de confusão de uma classificação binaria	115
Tabela 6 - Formulas matemáticas das métricas	115
Tabela 7 - Abreviaturas utilizadas para os resultados dos modelos de IA.....	123
Tabela 8 - Resultados do treinamento da base de dados Prognóstico Clínico com os melhores resultados, em negrito se destaca o melhor modelo	129
Tabela 9 - Legenda para os hiperparâmetros do modelo <i>Transformer</i>	135
Tabela 10 - Resultado Prognostico Clínico usando Transformers variando os hiperparâmetros com os melhores resultados, em negrito se destaca o melhor modelo para MT e MCT	136
Tabela 11 - Distribuição da base dados em coma em termos de etiologia e desfecho clínico	142
Tabela 12 - Resultados do treinamento da base de dados Etiologia do Coma, melhores resultados, em negrito se destaca o melhor modelo	143
Tabela 13 - Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, melhores resultados, em negrito se destaca o melhor modelo	145
Tabela 14 - Resultados do treinamento base de dados Estimulação musical (Favorita e Desgostada) melhores performances, em negrito se destaca o melhor modelo.....	148
Tabela 15 – Resultados do treinamento da base de dados Prognóstico Clínico para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo	195
Tabela 16 - Resultados do treinamento da base de dados Prognóstico Clínico para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo	196
Tabela 17 - Resultados do treinamento da base de dados Prognóstico Clínico com características do paciente e regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo	197
Tabela 18 - Resultados do treinamento da base de dados Prognóstico Clínico para CSP, decomposição de Wavelet, e alterações na arquitetura do modelo, em negrito se destaca o melhor modelo	198
Tabela 19 - Resultados do treinamento da base de dados Prognóstico Clínico com outros modelos de rede neural, em negrito se destaca o melhor modelo.....	198
Tabela 20 - Resultado Prognostico Clínico usando <i>Transformers</i> com Sinal Puro variando os hiperparâmetros do modelo MT, em negrito se destaca o melhor modelo	200
Tabela 21 - Resultado Prognostico Clínico usando Transformers com Sinal Puro variando os hiperparâmetros do modelo MCT, em negrito se destaca o melhor modelo	202

Tabela 22 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com N_H = 4 e INT_D = 32 , em negrito se destaca o melhor resultado para MT e MCT	204
Tabela 23 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com N_H = 4 e INT_D = 64 , em negrito se destaca o melhor resultado para MT e MCT	204
Tabela 24 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com N_H = 4 e INT_D = 128 , em negrito se destaca o melhor resultado para MT e MCT	205
Tabela 25 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com N_H = 4 e INT_D = 256 , em negrito se destaca o melhor resultado para MT e MCT	205
Tabela 26 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com N_H = 8 e INT_D = 32 , em negrito se destaca o melhor resultado para MT e MCT	206
Tabela 27 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com N_H = 8 e INT_D = 64 , em negrito se destaca o melhor resultado para MT e MCT	207
Tabela 28 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com N_H = 8 e INT_D = 128 , em negrito se destaca o melhor resultado para MT e MCT	207
Tabela 29 - Resultado Prognostico Clinico usando Transformers com características estatísticas variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT	208
Tabela 30 - Resultado Prognostico Clinico usando Transformers com características de PCP variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT	210
Tabela 31 - Resultado Prognostico Clinico usando Transformers com características de FM variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT	211
Tabela 32 - Resultado Prognostico Clinico usando Transformers com características de Coerência variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT	212
Tabela 33 - Resultado Prognostico Clinico usando Transformers com características do paciente e estatísticas variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT	213
Tabela 34 - Resultado Prognostico Clinico usando Transformers com características do paciente e PCP variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT	214
Tabela 35 - Resultado Prognostico Clinico usando Transformers com características do paciente e FM variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT	216
Tabela 36 - Resultado Prognostico Clinico usando Transformers com características do paciente e Coerência variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT	217
Tabela 37 – Resultados do treinamento da base de dados Etiologia do Coma para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo	218

Tabela 38 – Resultados do treinamento da base de dados Etiologia do Coma para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo	219
Tabela 39 – Resultados do treinamento da base de dados Etiologia do Coma com características do paciente e regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo	220
Tabela 40 – Resultados do treinamento da base de dados Etiologia do Coma testando outras abordagens, em negrito se destaca o melhor modelo	221
Tabela 41 - Resultados do treinamento da base de dados Etiologia do Coma usando Transformers variando os hiperparâmetros do modelo MT e MCT para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo	222
Tabela 42 - Resultados do treinamento da base de dados Etiologia do Coma usando Transformers variando os hiperparâmetros do modelo MT e MCT, para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo	223
Tabela 43 - Resultados do treinamento da base de dados Etiologia do Coma usando Transformers com Sinal Puro variando os hiperparâmetros do modelo MT para as regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo	224
Tabela 44 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo	225
Tabela 45 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo	226
Tabela 46 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, com regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo	227
Tabela 47 - Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, usando Transformers com Sinal Puro variando os hiperparâmetros do modelo MT, em negrito se destaca o melhor modelo	228
Tabela 48 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, usando Transformers, com o sinal puro, características do paciente e estatísticas, em negrito se destaca o melhor modelo	230
Tabela 49 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, usando Transformers, para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo	231
Tabela 50 - Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, usando Transformers com Sinal Puro, variando os hiperparâmetros do modelo MT para as regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo	232
Tabela 51 - Resultados do treinamento da base de dados Estimulação musical (Favorita e Desgostada) para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo	233
Tabela 52 - Resultados do treinamento da base de dados Estimulação musical (Favorita e Desgostada) para o sinal puro, com os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo	234

Tabela 53 - Resultados do treinamento da base de dados Estimulação musical (Favorita e Desgostada) com características do voluntario e as regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo.....	234
Tabela 54 - Resultados do treinamento segregando a base de dados Estimulação musical (Favorita e Desgostada) para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo com <i>All Group</i>	236
Tabela 55 - Resultados do treinamento segregando a base de dados Estimulação musical (Favorita e Desgostada) para o sinal puro, com os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo <i>All Group</i>	238
Tabela 56 - Resultados do treinamento segregando a base de dados Estimulação musical (Favorita e Desgostada) com características do voluntario e as regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo para <i>All Group</i>	239
Tabela 57 - Resultados do treinamento segregando a base de dados Estimulação musical (Favorita e Desgostada) com outras arquiteturas, em negrito se destaca o melhor modelo para <i>All Group</i>	241
Tabela 58 - Resultados do treinamento da base de dados Estimulação musical (Favorita e Desgostada) usando arquitetura com <i>transformer</i> , para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo	243

LISTA DE SIGLAS E ABREVIATURAS

ASA	- <i>Advanced Source Analysis</i> (Análise Avançada de Fontes)
AVC	- Acidente Vascular Cerebral
BCI	- <i>Brain-Computer Interface</i> (Interface Cérebro-Computador)
BEAPP	- <i>Batch Electroencephalography Automated Processing Platform</i> (Plataforma Automatizada de Processamento em Lote de Eletroencefalografia)
BERT	- <i>Bidirectional Encoder Representations from Transformers</i> (Representações de Codificadores Bidirecionais de Transformers)
CM	- Coma Metabólico
CNN	- <i>Convolutional Neural Networks</i> (Redes Neurais Convolucionais)
CSV	- <i>Comma-Separated Values</i> (Valores Separados por Vírgula)
CVS	- <i>Concurrent Version System</i> (Sistema de Versões Concorrentes)
ECG	- Eletrocardiograma
ECoG	- Eletrocorticografia
EEG	- Eletroencefalograma
EMEGS	- <i>Electromagnetic Encephalography Software</i> (Software para Encefalografia Eletromagnética)
ERD	- <i>Event-related desynchronization</i> (Evento relacionado a dessincronização)
ERF	- <i>Event-Related Magnetic Field</i> (Campos Magnéticos Relacionados a Eventos)
ERP	- <i>Event-Related Potential</i> (Potenciais Relacionados a Eventos)
FM	- Frequência Mediana
fMRI	- <i>functional Magnetic Resonance Imaging</i> (ressonância magnética funcional)
GNU	- Projeto de Software Livre
GPL	- <i>General Public License</i> (Licença Pública Geral)
GPT	- <i>Generative Pre-trained Transformer</i> (Transformador Generativo Pré-Treinado)
GUI	- <i>Graphic User Interface</i> (Interface Gráfica de Usuário)
IA	- Inteligência Artificial
ICA	- <i>Independent Component Analysis</i> (Análise de Componentes Independentes)
MEG	- Magnetoencefalografia
MLP	- <i>Multi-Layer Perceptron</i>
MVPA	- <i>Multi-Variable Pattern Analysis</i> (Análise Multivariada de Padrões)
NCSE	- <i>Nonconvulsive Status Epilepticus</i> (Estados Epiléticos Não-convulsivos)
NIH	- <i>National Institutes of Health</i> (Instituto Nacional de Saúde)
NLP	- <i>Natural Language Processing</i> (Processamento de Linguagem Natural)
PCP	- Porcentagem da Contribuição de Potência

PET	- <i>Positron Emission Tomography</i> (tomografia por emissão de pósitrons)
POO	- Programação Orientada a Objetos
RNN	- <i>Recurrent Neural Networks</i> (Redes Neurais Recorrentes)
SBNC	- Sociedade Brasileira de Neurofisiologia Clínica
SSEP	- <i>SomatoSensory Evoked Potentials</i> (Potenciais Evocados Somatossensoriais)
TCE	- Traumatismo Cranioencefálico
UTI	- Unidade de Tratamento Intensivo
VAP	- Variação Percentual

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	25
1.1 CONTEXTUALIZAÇÃO	25
1.1.1 EEG e Estimulação musical	26
1.1.2 EEG e Inteligência Artificial	27
1.2 JUSTIFICATIVA	28
1.3 OBJETIVOS	30
1.3.1 Objetivo Geral	30
1.3.2 Objetivos Específicos	30
1.4 ORGANIZAÇÃO DO DOCUMENTO.....	31
CAPÍTULO 2 - ESTADO DA ARTE.....	33
2.1 ELETROENCEFALOGRAMA (EEG).....	33
2.1.1 Porcentagem de Contribuição de Potência (PCP)	35
2.1.2 Frequência Mediana (FM)	36
2.1.3 Coerência.....	37
2.2 SOFTWARE DE PROCESSAMENTO DE EEG.....	39
2.3 ESTIMULAÇÃO MUSICAL E NEUROCIÊNCIA	42
2.4 INTELIGÊNCIA ARTIFICIAL E EEG	45
CAPÍTULO 3 - PROCESSAMENTO DO EEG.....	49
3.1 MATERIAIS E MÉTODOS.....	49
3.1.1 Tecnologias utilizadas	49
3.1.2 Metodologia.....	52
3.2 SOFTWARE NA PLATAFORMA COMPUTACIONAL	53
3.3 EVOLUÇÃO DO SOFTWARE NA PLATAFORMA COMPUTACIONAL	54
3.3.1 Remoção de colunas do arquivo .CSV de entrada	54
3.3.2 Adição das seguintes colunas do arquivo .CSV de entrada.....	55
3.3.3 Alteração de ordem de coluna.....	57
3.3.4 Customização da coluna “QTD EPOCAS”	57
3.3.5 Considerações.....	57
3.4 SOFTWARE EM PYTHON	58
3.4.1 Versionamento	58

3.4.2 Detalhes da Implementação	58
3.4.3 Interface gráfica.....	62
3.5 TESTES DE REGRESSÃO PARA COMPARAÇÃO ENTRE O SOFTWARE ORIGINAL E A VERSÃO EM PYTHON.....	67
3.6 RESULTADOS.....	68
3.6.1 Processamento dos PLGs	68
3.6.2 Execução dos testes de regressão.....	71
3.7 CONSIDERAÇÕES FINAIS	75
CAPÍTULO 4 - ANÁLISE DE PADRÕES DE ESTIMULAÇÃO MUSICAL.....	77
4.1 MATERIAIS E MÉTODOS.....	77
4.1.1 Métodos Estatísticos, Ferramentas de Análise e Visualização de Dados	77
4.1.2 Metodologia.....	82
4.2 VERSIONAMENTO.....	83
4.3 FUNÇÕES IMPLEMENTADAS.....	83
4.3.1 Função groupPcpAndFmAndCoerencia	83
4.3.2 Função generateMedianMeanStdGrouped.....	84
4.3.3 Função computePercentVariation	84
4.3.4 Função computeTestPValue	85
4.3.5 Função histogramPercentVariationByMaxValueInTestPValue.....	85
4.3.6 Função createXlsxByStimulus	86
4.3.7 Função generateFileByStimulus	86
4.4 BASE DE DADOS	87
4.4.1 Fases da coleta dos estímulos	89
4.5 ESTRUTURAÇÃO E PROCESSAMENTO DOS DADOS.....	92
4.6 RESULTADOS	95
4.6.1 Quantificador Frequência Mediana (FM)	96
4.6.2 Quantificador Porcentagem de Contribuição de Potência (PCP)	99
4.7 CONSIDERAÇÕES FINAIS.....	105
CAPÍTULO 5 - APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL.....	108
5.1 DEFINIÇÃO FORMAL DO PROBLEMA.....	108
5.2 ARQUITETURAS.....	109
5.3 TREINAMENTO.....	112

5.4 MÉTRICAS DE PERFORMANCE.....	113
5.5 QUANTIFICADORES ADICIONADOS PARA ANÁLISE.....	116
5.5.1 PCP.....	116
5.5.2 FM.....	116
5.5.3 Coerência.....	116
5.5.4 Eletrodos Região Frontal.....	116
5.5.5 Eletrodos Região Central	117
5.5.6 Eletrodos Região Occipital	118
5.5.7 Eletrodos Região Parietal.....	119
5.5.8 Eletrodos Região Temporal.....	120
5.5.9 <i>Common spatial pattern</i> (CSP).....	121
5.5.10 Decomposição de Wavelet.....	122
5.6 ABREVIATURAS UTILIZADAS NO PROCESSAMENTO	123
5.7 CONFIGURAÇÃO DE EXECUÇÃO DOS TREINAMENTOS.....	125
5.8 PROGNÓSTICO CLÍNICO.....	125
5.8.1 Definição do problema.....	125
5.8.2 Base de dados	126
5.8.3 Resultados	128
5.8.4 Discussão.....	128
5.9 TRANSFORMER E PROGNÓSTICO CLÍNICO.....	131
5.9.1 Definição do problema.....	131
5.9.2 Base de dados	131
5.9.3 Descrição do Modelo.....	131
5.9.4 Resultados	136
5.9.5 Discussão.....	136
5.10 ETIOLOGIA DO COMA	141
5.10.1 Definição do problema.....	141
5.10.2 Base de dados	142
5.10.3 Resultados	143
5.10.4 Discussão.....	143
5.11 GOSTO MUSICAL.....	147
5.11.1 Definição do problema.....	147
5.11.2 Base de dados	148
5.11.3 Resultados	148
5.11.4 Discussão.....	148

CAPÍTULO 6 - CONCLUSÕES E TRABALHOS FUTUROS.....	152
6.1 CONCLUSÕES.....	152
6.2 TRABALHOS FUTUROS	154
6.3 CONSIDERAÇÕES FINAIS	155
APÊNDICE A - PROGRAMAS / FUNÇÕES <i>SOFTWARE</i> DE PROCESSAMENTO DE EEG VERSÃO PLATAFORMA COMPUTACIONAL	166
APÊNDICE B - DESCRIÇÃO DAS VARIÁVEIS IMPORTANTES DO <i>SOFTWARE</i> DE PROCESSAMENTO DE EEG VERSÃO PLATAFORMA COMPUTACIONAL.....	176
APÊNDICE C - ARQUIVO .CSV DE ENTRADA PARA O PROCESSRECORDS	186
APÊNDICE D - ARQUIVO .CSV DE RESULTADO DO PROCESSAMENTO DO APÊNDICE C APENAS COM AS COLUNAS ADICIONAIS	187
APÊNDICE E - ARQUIVO .CSV DE ENTRADA PARA O PROCESSRECORDS APÓS MELHORIAS	188
APÊNDICE F - EXEMPLO DE UM ARQUIVO EXCEL DE SAÍDA DE CÁLCULO DO TESTE DE FRIEDMAN.....	189
APÊNDICE G - EXEMPLO DE UM ARQUIVO EXCEL DE SAÍDA DO CÁLCULO DO VAP	191
APÊNDICE H - EXEMPLO DE UM ARQUIVO EXCEL DE SAÍDA DO CÁLCULO DO VAP SELECIONADO DE ACORDO COM TESTE DE FRIEDMAN (< 0,05).....	193
APÊNDICE I - RESULTADOS DO TREINAMENTO PROGNOSTICO CLINICO.....	195
APÊNDICE J - RESULTADOS DO TREINAMENTO <i>TRANSFORMER</i> E PROGNOSTICO CLINICO.....	200
APÊNDICE K - RESULTADOS DO TREINAMENTO ETIOLOGIA DO COMA.....	218
APÊNDICE L - RESULTADOS DO TREINAMENTO ETIOLOGIA DO COMA USANDO TRANSFORMER.....	222
APÊNDICE M - RESULTADOS DO TREINAMENTO ETIOLOGIA DO COMA REMOVENDO OS EXAMES PERTENCENTES AO ROTULO OUTROS	225
APÊNDICE N - RESULTADOS DO TREINAMENTO ETIOLOGIA DO COMA USANDO TRANSFORMER REMOVENDO OS EXAMES PERTENCENTES AO ROTULO OUTROS	228
APÊNDICE O - RESULTADOS DO TREINAMENTO GOSTO MUSICAL	233

**APÊNDICE P - RESULTADOS DO TREINAMENTO GOSTO MUSICAL SEGREGANDO A
BASE DE DADOS..... 236**

**APÊNDICE Q - RESULTADOS DO TREINAMENTO GOSTO MUSICAL USANDO
TRANSFORMER 243**

**ANEXO A - PARECER COMITÊ DE ÉTICA 369/11 BASE DE DADOS PACIENTES EM
COMA 245**

**ANEXO B - PARECER COMITÊ DE ÉTICA 2.570.022 BASE DE DADOS PACIENTES EM
COMA 246**

**ANEXO C - PARECER COMITÊ DE ÉTICA 1.715.960 BASE DE DADOS ESTIMULAÇÃO
MUSICAL 247**

CAPÍTULO 1 - INTRODUÇÃO

Este capítulo introdutório apresenta uma visão dos conceitos e contextos relacionados ao eletroencefalograma (EEG), um método essencial para o estudo da atividade elétrica cerebral. Além disso, discute-se a interação entre EEG e estimulação musical, ressaltando avanços recentes que associam padrões neurais a estímulos sonoros. Por fim, são abordadas as aplicações de técnicas de inteligência artificial no processamento e análise dos sinais de EEG, destacando seu potencial para a extração de informações relevantes e para o desenvolvimento de novos métodos diagnósticos.

1.1 CONTEXTUALIZAÇÃO

A etimologia da palavra **eletroencefalograma (EEG)** deriva de três termos de origem grega: **eletro** (*élektron*), que significa eletricidade; **encéfalo** (*egképhalos*), que se refere ao cérebro; **grama** (*grámma*), que significa registro ou escrita (ROSA, LAUCSEN DA, 2009). Dessa forma, o EEG consiste no registro da atividade do cérebro, originada pela soma dos potenciais das células nervosas (neurônios), refletindo os processos funcionais cerebrais.

As bases da eletroencefalografia remontam aos experimentos pioneiros realizados no final do século XIX, quando Richard Caton detectou sinais elétricos no cérebro de animais (NIEDERMEYER; SILVA, 2004). Entre 1875 e 1877, utilizando um galvanômetro, Caton posicionou sensores na substância cinzenta do cérebro e crânio, observando variações na tensão ao longo do tempo. Através de uma agulha acoplada ao galvanômetro, que vibrava conforme essas variações, foi possível registrar as oscilações elétricas em uma folha de papel em movimento contínuo, originando assim o conceito do eletroencefalograma (EEG) (ROSA, LAUCSEN DA, 2009).

Em 6 de julho de 1924, o psiquiatra alemão Hans Berger realizou o primeiro registro de eletroencefalograma (EEG) em um ser humano, um jovem de 17 anos submetido a uma neurocirurgia realizada pelo neurocirurgião Nikolai (İNCE; ADANIR; SEVMEZ, 2021). Inicialmente, Berger explorava a base fisiológica dos fenômenos

psíquicos, mas os resultados levaram-no a concentrar-se na atividade elétrica do cérebro. Sua técnica evoluiu de registros invasivos, com eletrodos posicionados diretamente no periósteo após aplicação de anestesia local, para a técnica não invasiva atual, com eletrodos acoplados ao couro cabeludo (ÍNCE; ADANIR; SEVMEZ, 2021). Este avanço marcou o início de uma nova era na neurociência clínica, possibilitando o estudo sistemático da atividade cerebral humana.

Com os avanços tecnológicos na aquisição e interpretação dos sinais de EEG, sua aplicação expandiu-se significativamente para diversas áreas do conhecimento. Atualmente, o EEG desempenha um papel essencial na prática clínica, sendo amplamente empregado no diagnóstico e prognóstico de doenças neurológicas. Além disso, tem se consolidado como uma ferramenta indispensável em pesquisas neurocientíficas, permitindo uma compreensão mais aprofundada da dinâmica cerebral. No campo da tecnologia, o EEG impulsiona o desenvolvimento de interfaces cérebro-máquina (BCI), viabilizando novas formas de interação entre humanos e dispositivos eletrônicos. Outro avanço relevante é sua utilização no monitoramento contínuo de pacientes internados em unidades de terapia intensiva (UTI), possibilitando a avaliação em tempo real da função cerebral.

1.1.1 EEG e Estimulação musical

Os sinais de EEG e magnetoencefalografia (MEG) são frequentemente definidos em faixas de frequência específicas, como ondas lentas ($<0,2$ Hz), delta (0,2 a 3,5 Hz), teta (4 a 7,5 Hz), alfa (8 a 13 Hz), beta (14 a 30 Hz), gama (30 a 90 Hz) e oscilações de alta frequência (>90 Hz), embora esses limites tenham sido estabelecidos de forma arbitrária e sem base direta em mecanismos neurofisiológicos conhecidos (LOPES DA SILVA, 2013).

Entretanto, a riqueza desses sinais eletrofisiológicos tem permitido analisar como estímulos externos complexos, como a música, podem modular a atividade cerebral. Pesquisas recentes indicam que diferentes características musicais, como o tempo e o modo, afetam as bandas de frequência do EEG, particularmente nas faixas alfa, teta e beta, relacionadas a estados emocionais e atenção. Por exemplo, (YANG *et al.*, 2025) observaram que tempos musicais lentos aumentam a potência das ondas teta e alfa na região frontal, promovendo relaxamento, enquanto tempos rápidos

elevam a atividade beta e gama, associadas a estados de alerta e excitação. Esses achados indicam o potencial da música em regular a atividade cerebral e seus possíveis usos terapêuticos.

Dessa forma, a musicoterapia tem se destacado como uma intervenção promissora no cuidado de pacientes oncológicos, contribuindo significativamente para a redução de sintomas como dor, ansiedade e estresse, além de promover o bem-estar emocional e melhorar a qualidade de vida desses pacientes (BRADT *et al.*, 2016). Revisões sistemáticas recentes indicam que a terapia musical ativa áreas cerebrais envolvidas no processamento emocional e influencia positivamente a percepção da dor, revelando-se uma ferramenta valiosa no tratamento integrado do câncer. Embora sejam necessários estudos adicionais para consolidar as evidências, os resultados atuais apontam para melhorias significativas no enfrentamento dos efeitos adversos do tratamento quimioterápico, abrindo caminho para perspectivas terapêuticas mais eficazes (RODRIGUES *et al.*, 2025).

1.1.2 EEG e Inteligência Artificial

A aplicação da inteligência artificial (IA) na análise de sinais de eletroencefalografia (EEG) tem representado um avanço significativo na neurociência clínica. Modelos avançados de aprendizado profundo vêm sendo aplicados para interpretar padrões complexos no EEG com alta precisão, permitindo diagnósticos mais rápidos e acurados de distúrbios neurológicos como epilepsia (ALKHALDI *et al.*, 2024), demência (REZAEI *et al.*, 2025) e distúrbios do sono (TRANG *et al.*, 2025). Estudos indicam que algoritmos de IA superam métodos tradicionais na detecção automática de anomalias em EEG, ampliando o potencial diagnóstico em contextos clínicos com menor necessidade de intervenção humana.

Além disso, a integração da IA aos sinais de EEG tem viabilizado aplicações inovadoras em interfaces cérebro-computador (BCI), monitoramento em tempo real e prognóstico de doenças neurológicas. Estudos recentes evidenciam que sistemas baseados em IA podem analisar dados de EEG com alta precisão para detectar padrões associados a condições neurológicas e melhorar a interação entre o cérebro e dispositivos externos, como demonstrado por avanços em BCI que possibilitam controle motor e comunicação assistida (BARBERA *et al.*, 2025; ZHANG *et al.*, 2020).

Esses progressos promovem uma abordagem personalizada e eficaz no cuidado em saúde, aprimorando a detecção, o monitoramento e a intervenção terapêutica em tempo real.

1.2 JUSTIFICATIVA

O eletroencefalograma (EEG) capta a atividade elétrica do cérebro por meio de sensores posicionados no couro cabeludo, produzindo sinais brutos que, isoladamente, possuem pouca relevância clínica. Contudo, a análise detalhada desses dados, especialmente a identificação de oscilações em diferentes faixas de frequência e sua localização em regiões específicas do cérebro, transforma o EEG em uma ferramenta essencial para investigações neurológicas. Quando associados a informações biológicas e clínicas adicionais, esses dados potencializam a compreensão dos processos cerebrais, aprimorando a precisão no diagnóstico e na previsão de condições neurológicas.

Sua portabilidade e os custos acessíveis fazem do EEG uma ferramenta amplamente utilizada em pesquisas multicêntricas e na formação de bases de dados (LEVIN *et al.*, 2018). Essa técnica pode ser aplicada em grupos de indivíduos saudáveis e clínicos de diferentes faixas etárias, com relativa facilidade na aquisição dos dados. No entanto, a análise desses sinais exige conhecimentos técnicos especializados e ferramentas que facilitem o processamento e a identificação das informações relevantes.

Muitos dos *software* utilizados para processar dados de EEG são pagos ou estão disponíveis em plataformas comerciais, o que gera a demanda por alternativas de código aberto para essas tarefas. Além disso, o desenvolvimento de scripts e pipelines¹ analíticos para EEG é complexo e desafiador, devido a variáveis como o formato dos arquivos de entrada, a taxa de amostragem, o posicionamento dos

¹ pipeline – consiste em um conjunto de passos para processar o EEG, onde se torna necessário chamar várias rotinas de *software*, cada uma com sua função delimitada onde o resultado de uma função é entrada de outra função até se cumprir o objetivo proposto. Exemplo de pipeline para separar o EEG por bandas de frequência: inicialmente faz a leitura do arquivo de EEG, converte o mesmo para matrizes, separa épocas/segmentos, converte no domínio da frequência, separa em bandas de frequência.

eletrodos, além da presença de ruídos de linha e artefatos de movimento, fatores que dificultam a padronização e a comparação dos resultados (LEVIN *et al.*, 2018).

Durante a análise do EEG, muitos registros e coletas são frequentemente descartados devido à alta presença de ruídos ou outros fatores que comprometem a qualidade dos dados. Essa situação muitas vezes ocorre pela falta de especialistas qualificados ou pela indisponibilidade de ferramentas de ciência de dados, que geralmente possuem custos elevados. Entretanto, caso a validação dos dados possa ser automatizada por meio de plataformas acessíveis e de fácil utilização, o treinamento de profissionais de saúde e cientistas de dados poderá ser otimizado, minimizando a perda de informações valiosas (RAMACHANDRAN *et al.*, 2018).

A automação na análise dos dados de EEG não apenas torna essa tecnologia mais acessível, como também amplia seu uso na exploração de fenômenos neurocientíficos complexos. Um campo de especial interesse é a investigação da relação entre estímulos sonoros e emoções, motivada pelo impacto significativo que a música e outros estímulos auditivos exercem sobre a atividade cerebral. Essa linha de pesquisa tem despertado grande atenção por sua relevância clínica e experimental, possibilitando avanços importantes na compreensão dos mecanismos neurais subjacentes às respostas emocionais.

É amplamente reconhecido que os sons desempenham um papel fundamental na regulação das emoções. Ao ouvir o rugido de um predador, como um leão ou uma onça, o corpo interpreta rapidamente o som como uma ameaça, desencadeando uma resposta fisiológica associada ao medo. Da mesma forma, a exposição a uma música apreciada pode ativar diversas emoções, como alegria, felicidade e memória afetiva. Além disso, algumas abordagens terapêuticas sugerem que a estimulação musical pode acelerar o processo de recuperação em determinados tratamentos de saúde. Nesse contexto, torna-se essencial investigar como a música influencia as emoções e quais áreas cerebrais são ativadas, considerando que um mesmo estímulo sonoro pode gerar respostas emocionais distintas em cada indivíduo.

Para compreender essas relações com maior precisão, é necessário um aprofundamento na análise dos sinais cerebrais. No entanto, a identificação precisa

dos padrões cerebrais requer técnicas avançadas de análise, visto que os sinais de EEG são altamente dinâmicos e complexos.

Nesse sentido, a aplicação de inteligência artificial (IA) tem se mostrado uma abordagem promissora para a classificação automática dos exames, permitindo detectar padrões sutis nos sinais elétricos do cérebro e associá-los tanto a diferentes estados emocionais quanto a possíveis condições patológicas. Essa abordagem não apenas facilita a interpretação dos dados, como também amplia as possibilidades de diagnóstico precoce, monitoramento de distúrbios neurológicos e personalização de tratamentos, tornando a análise do EEG uma ferramenta ainda mais acessível e eficiente para diversas aplicações clínicas e terapêuticas.

1.3 OBJETIVOS

1.3.1 Objetivo Geral

Desenvolver uma plataforma computacional de código aberto para o processamento de sinais neurofisiológicos e análise estatística, possibilitando a realização de avaliações quantitativas automatizadas por meio de técnicas de aprendizado de máquina.

Aplicar essa plataforma a bases de dados de estimulações cognitivas, abrangendo tanto indivíduos saudáveis quanto pacientes com condições neurológicas, a fim de identificar padrões característicos de atividade cerebral, investigar correlações entre estímulos e respostas neurais e contribuir para avanços no diagnóstico, monitoramento e prognóstico de patologias.

1.3.2 Objetivos Específicos

Para alcançar o objetivo geral proposto, este trabalho visa atender aos seguintes objetivos específicos:

- Desenvolver uma pipeline computacional em código aberto capaz de realizar o processamento de sinais neurofisiológicos, integrando técnicas de filtragem, segmentação e normalização para garantir a qualidade dos dados analisados.

- Implementar algoritmos de aprendizado de máquina para a classificação automatizada de padrões neurais, explorando modelos supervisionados e não supervisionados para aprimorar a detecção de assinaturas eletrofisiológicas associadas a estímulos cognitivos.
- Criar um módulo de análise estatística avançada para investigar relação entre atividade cerebral e estímulos externos, possibilitando a extração de métricas quantitativas que auxiliem na interpretação dos resultados.
- Aplicar a plataforma a bases de dados de EEG, tanto de indivíduos saudáveis quanto pacientes com condições neurológicas, avaliando a eficácia da ferramenta na distinção de padrões neurais específicos em diferentes cenários clínicos.
- Otimizar a escalabilidade e acessibilidade da plataforma, garantindo que o código desenvolvido seja modular, de fácil reprodução e compatível com diferentes conjuntos de dados e configurações experimentais.
- Validar a metodologia proposta por meio de experimentos comparativos, analisando o desempenho da plataforma em relação a abordagens tradicionais e verificando sua aplicabilidade em estudos neurocientíficos e clínicos.

1.4 ORGANIZAÇÃO DO DOCUMENTO

Esta tese está organizada da seguinte forma:

- **Capítulo 1** – Apresenta uma introdução ao tema, destacando a relevância do EEG para a ciência e a sociedade, além da justificativa para a escolha do tema e da definição dos objetivos;
- **Capítulo 2** – Discute o estado da arte, abordando os principais *software* utilizados no processamento de EEG, acompanhados de uma comparação sucinta dessas ferramentas sob a perspectiva de desenvolvimento e implementação. Também aborda o estudo da estimulação musical relacionada à neurociência e apresenta a aplicação da inteligência artificial na classificação dos sinais de EEG;
- **Capítulo 3** – Descreve a transcrição do *software* de processamento de EEG desenvolvido pelo grupo de pesquisa para a linguagem Python, incluindo as melhorias implementadas em relação a versão anterior e a criação de uma interface gráfica para facilitar o uso da ferramenta;

- **Capítulo 4** – Propõe um mecanismo para a extração de atributos destinado à análise de padrões nos sinais de EEG sob estimulação musical;
- **Capítulo 5** – Explora a aplicação de técnicas de inteligência artificial e aprendizado de máquina na classificação das bases de dados, avaliando o desempenho de diferentes abordagens computacionais;
- **Capítulo 6** – Apresenta as conclusões do estudo e sugere direções para trabalhos futuros, discutindo as principais contribuições e possíveis desdobramentos da pesquisa.

CAPÍTULO 2 - ESTADO DA ARTE

O avanço das tecnologias para o processamento de sinais de eletroencefalografia (EEG) tem impulsionado significativamente a pesquisa e as aplicações clínicas na neurociência. Diversos *software*, tanto de código aberto quanto comerciais, oferecem ferramentas especializadas que permitem a análise detalhada dos dados brutos, facilitando desde o pré-processamento até a extração de padrões complexos. Paralelamente, a exploração dos efeitos da estimulação musical sobre a atividade cerebral, capturada pelo EEG, tem revelado conexões importantes entre estímulos auditivos e respostas neurofisiológicas. Adicionalmente, a incorporação de técnicas de inteligência artificial no processamento e análise de EEG tem ampliado a capacidade de detectar e interpretar padrões neurais, promovendo melhorias nos diagnósticos e no entendimento dos fenômenos cerebrais. Este capítulo revisa o estado da arte nessas três áreas.

2.1 ELETROENCEFALOGRAMA (EEG)

O eletroencefalograma (EEG) é um método não invasivo que registra a atividade elétrica cerebral por meio de eletrodos posicionados no couro cabeludo, captando os impulsos gerados pelos neurônios do córtex cerebral (SCHOMER; LOPES DA SILVA, 2017). Cada eletrodo corresponde a um canal, permitindo o registro simultâneo dos sinais provenientes de diferentes regiões do cérebro.

Para a coleta do EEG, a Sociedade Brasileira de Neurofisiologia Clínica (SBNC) recomenda o uso do Sistema Internacional 10-20, que consiste em 21 eletrodos cuja colocação segue critérios bem definidos (MARINHO, 2017). O posicionamento dos eletrodos é realizado com base em medidas específicas dos pontos de referência do crânio, buscando adequação ao tamanho e formato individual de cada paciente.

A nomenclatura dos eletrodos reflete as áreas cerebrais subjacentes, facilitando a interpretação por profissionais de diferentes áreas e a padronização entre laboratórios. Cada eletrodo é identificado por uma letra, que indica a região cerebral coberta (Fp: fronto-polar, F: frontal, C: central, P: parietal, T: temporal, O: occipital), e

por um número, que representa a lateralização. Os números ímpares correspondem ao hemisfério esquerdo e pares ao direito. Os eletrodos da linha média são identificados com a letra Z (Fz, Cz, Pz).

O posicionamento dos eletrodos no sistema 10-20 é baseado em medidas proporcionais ao tamanho do crânio, utilizando pontos de referência como nábio, ínton e pontos pré-auriculares. As distâncias entre os eletrodos são definidas de modo que o espaçamento corresponde a 10% ou 20% das dimensões totais do crânio, tanto na direção antero-posterior quanto na transversal. O primeiro eletrodo é colocado a 10% da distância total entre dois pontos de referência, e os demais são dispostos a intervalos de 20%, garantindo cobertura adequada e padronização entre diferentes indivíduos (RECOMMENDATIONS FOR THE PRACTICE OF CLINICAL NEUROPHYSIOLOGY: GUIDELINES OF THE INTERNATIONAL FEDERATION OF CLINICAL NEUROPHYSIOLOGY, 1999).

A Figura 1 ilustra a disposição dos eletrodos de acordo com o sistema 10-20, evidenciando as posições das medidas de 10% e 20% ao longo do crânio, conforme os pontos de referência utilizados. Essa representação facilita a compreensão da distribuição dos eletrodos e reforça a importância do método para a padronização dos registros de EEG.

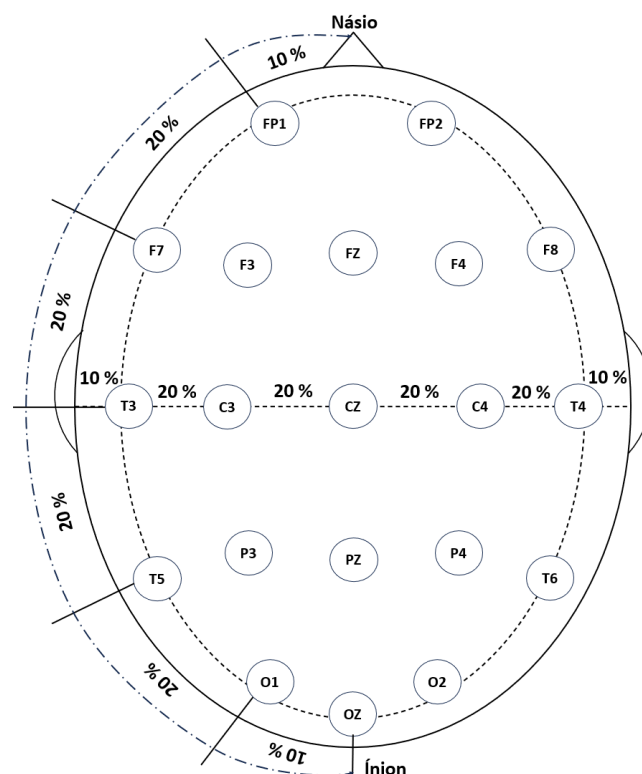


Figura 1 - Sistema Internacional de montagem de eletrodos 10-20

O traçado do EEG representa a variação da atividade elétrica cerebral ao longo do tempo, registrada simultaneamente em múltiplos canais (eletrodos). Esse traçado exhibe oscilações de diferentes frequências e amplitudes, que refletem os padrões de atividade neural em repouso ou durante tarefas específicas. A análise visual do traçado permite identificar características como ritmos dominantes, artefatos e eventos transientes, sendo fundamental para a interpretação clínica e pesquisa em neurociência. Na Figura 2, é apresentado um exemplo de traçado de EEG, ilustrando a disposição dos sinais registrados pelos diferentes eletrodos ao longo do tempo.




Figura 2 - Exemplo de traçado de EEG

Caracterizado por sua complexidade, o registro de EEG apresenta variações dinâmicas ao longo do tempo e entre diferentes regiões cerebrais. Para facilitar a análise, o sinal é frequentemente dividido em janelas temporais menores, conhecidas como épocas, que permitem isolar segmentos de interesse relacionados a eventos específicos ou estados cognitivos. A partir dessas épocas, são aplicadas diversas técnicas de análise de sinais, como transformadas de Fourier, wavelets e o cálculo de quantificadores espectrais, incluindo a Porcentagem de Contribuição de Potência (PCP), Frequência Mediana (FM) e a Coerência, com o objetivo de extrair informações relevantes e facilitar a interpretação dos dados obtidos.

2.1.1 Porcentagem de Contribuição de Potência (PCP)

A Porcentagem de Contribuição de Potência (PCP) é um quantificador que mensura, de maneira relativa, a potência presente em cada ritmo cerebral em relação

à potência total do espectro, informando a contribuição que cada ritmo tem perante a época/segmento avaliada (RAMOS *et al.*, 2018). Este parâmetro é particularmente útil na análise de sinais de EEG, pois permite avaliar como a energia do sinal está distribuída entre as diferentes bandas de frequência.

O cálculo do PCP inicia-se com a determinação da potência total do sinal na época/segmento, sendo definido como a Equação 1 abaixo:

$$P_n = \int |S_x n(f)|^2 df \quad (1)$$

Onde:

- P_n - Potência total do sinal na época/segmento n
- $S_x n$ - Densidade espectral de potência do sinal EEG na época/segmento n .
- n - Época/segmento selecionada

Em seguida realiza-se o cálculo do PCP (Equação 2):

$$PCP_{n_ritmo} = \frac{\int |S_x n(f)|^2 df}{P_n} \quad (2)$$

Onde:

- PCP_{n_ritmo} - Contribuição de potência do ritmo específico em relação a potência total do sinal
- P_n - Potência total do sinal na época/segmento n
- $|S_x n(f)|^2$ - Densidade espectral de potência do ritmo específico na época/segmento n
- n - Época/segmento selecionada

2.1.2 Frequência Mediana (FM)

A Frequência Mediana (FM) é um parâmetro fundamental na análise espectral de sinais de EEG, representando o valor de frequência que divide o espectro de potência em duas partes iguais. Conforme indicado na Equação 3, a FM é definida como o valor de frequência em que 50% da potência calculada está concentrada nas frequências mais baixas e 50% nas frequências mais altas (RAMOS *et al.*, 2016).

$$F_{mediana} = \frac{\sum_{k=0}^n |x(k)| f(k)}{\sum_{k=0}^n |x(k)|} \quad (3)$$

Onde:

- $|x(k)|$ - Módulo obtido pela Transformada Discreta de Fourier
- $f(k)$ - Vetor de frequências
- n - Número de amostras do sinal $|x(k)|$

Em indivíduos acordados e neurologicamente normais, a FM geralmente está em torno de 12 Hz (TONNER; BEIN, 2006). No entanto, estudos piloto com voluntários saudáveis mostraram que, dependendo da região cerebral analisada, a FM pode variar entre 20 e 30 Hz, predominando o ritmo Beta da atividade cerebral (RAMOS *et al.*, 2016). A distribuição da FM varia conforme os eletrodos das regiões cerebrais, com médias de 25 Hz (frontal), 24 Hz (central), 27 Hz (temporal), 23 Hz (parietal) e 22 Hz (occipital), conforme reportado por (RAMOS *et al.*, 2016). Essa distribuição indica que as regiões anteriores apresentam frequências medianas mais elevadas, com maior presença de ritmos de alta frequência (Beta e Gama), enquanto as regiões posteriores exibem predominância de ritmos mais lentos (Delta, Teta e Alfa).

A FM também possui aplicações clínicas relevantes, como na monitorização da profundidade anestésica. Durante a anestesia, a FM desloca-se para valores mais baixos, atingindo cerca de 2 a 3 Hz em estados de anestesia profunda, sendo que valores menores indicam maior profundidade anestésica (TONNER; BEIN, 2006).

2.1.3 Coerência

A coerência, conforme definida na Equação 4, quantifica a consistência da diferença de fase entre dois sinais de EEG, refletindo o grau de sincronia entre eles (RAMOS, 2017). Esse parâmetro é especialmente valioso para avaliar a simetria funcional entre os hemisférios cerebrais direito e esquerdo, revelando relações de conectividade entre diferentes regiões corticais.

$$|\Gamma_{xy}(e^{j\omega})|_i^2 = \frac{|S_{xy}(e^{j\omega})|^2}{S_x(e^{j\omega}) \cdot S_y(e^{j\omega})} \quad (4)$$

Onde:

- S_{xy} - Densidade espectral de potência cruzada
- S_x - Densidade espectral do sinal X
- S_y - Densidade espectral do sinal Y
- i - Segmento considerado

A Equação 5 estabelece uma propriedade fundamental da coerência delimitando seus valores entre 0 e 1.

$$0 \leq |\Gamma_{xy}(e^{j\omega})|^2 \leq 1 \quad (5)$$

Valores próximos a zero indicam que os componentes de frequência dos sinais são linearmente independentes, sugerindo baixa ou nenhuma sincronia entre as regiões cerebrais analisadas (WANG *et al.*, 2015). Em contraste, valores próximos a um revelam forte correlação linear, indicando alta sincronização entre as áreas cerebrais correspondentes.

A coerência é baseada principalmente na consistência de fase entre os sinais, não necessariamente em suas amplitudes, o que significa que dois sinais podem ter fases diferentes, mas apresentar alta coerência quando se a diferença de fase permanecer constante (SRINIVASAN *et al.*, 2007). Esta característica torna a coerência uma métrica valiosa para avaliar o nível de conectividade funcional cortical.

Na análise da simetria interhemisférica, são utilizados 8 pares de eletrodos simétricos (FP1-FP2, F7-F8, F3-F4, T3-T4, C3-C4, T5-T6, P3-P4, O1-O2) para avaliar a atividade elétrica cerebral entre os hemisférios direito e esquerdo. Essa abordagem permite identificar assimetrias funcionais que podem estar associadas a condições neurológicas específicas. Estudos anteriores demonstraram que diferentes pares de eletrodos podem apresentar níveis variados de coerência, com eletrodos occipitais frequentemente exibindo maior coerência em comparação com pares temporais mais amplamente separados (FRENCH, 1982).

A alta coerência entre regiões homólogas indica cooperação neuronal eficiente e maior transmissão de informação entre as áreas cerebrais correspondentes. Por definição matemática, sinais idênticos apresentam coerência

igual a 1,0, enquanto a presença de componentes de frequência não relacionados em um dos sinais reduzirá proporcionalmente o valor da coerência.

2.2 SOFTWARE DE PROCESSAMENTO DE EEG

Cada instante de medição do sinal de EEG é registrado em um vetor X_t , que corresponde a uma amostra temporal distribuída ao longo de Y_{ch} canais, representando as posições dos eletrodos no couro cabeludo. Essa configuração caracteriza uma amostragem discreta de um campo elétrico contínuo, evidenciando a natureza espaço-temporal do EEG (VON WEGNER; LAUFS, 2018). Cada elemento da matriz que representa o sinal de EEG, de dimensão (X_t, Y_{ch}) , contém um valor numérico em ponto flutuante correspondente ao potencial elétrico captado por cada eletrodo, sendo esse valor altamente suscetível a ruídos e interferências provenientes de outros sinais. A complexidade inerente ao EEG torna a análise direta um desafio, requerendo o uso de *software* especializados para o pré-processamento, a remoção de ruídos e a interpretação precisa dos dados.

Os sinais de EEG são caracterizados por sua alta variabilidade e suscetibilidade a ruídos, tornando essencial o uso de *software* especializados que processam as X_t amostras para extrair informações adicionais, reduzir a complexidade dos sinais e mitigar a influência de artefatos. Esses *software* desempenham um papel fundamental ao automatizar a aquisição, o pré-processamento, a extração de características e a visualização dos sinais elétricos cerebrais. Dependendo da situação, eles podem ser projetados para atender a diferentes objetivos, como a remoção de artefatos, a segmentação de dados ou a análise de padrões espaciais e temporais.

Dessa forma, existem diversas ferramentas desenvolvidas para o processamento de EEG, cada uma com finalidades específicas. Algumas são focadas na análise clínica, auxiliando no diagnóstico de distúrbios neurológicos, enquanto outras são voltadas para pesquisa e desenvolvimento de aplicações em neurociência e interfaces cérebro-computador, conforme descrito em (BARBOSA, 2019).

A seguir, é apresentada a Tabela 1 que sintetiza as principais características dos *software* analisados por (BARBOSA, 2019), permitindo uma visão comparativa de suas especificidades. A Tabela 1 contém as seguintes colunas:

- **Software** – Nome da ferramenta analisada;
- **Linguagem** – A principal linguagem de programação utilizada no desenvolvimento do *software*;
- **Interface Gráfica** – Indica se a ferramenta possui uma interface gráfica (GUI) ou se é baseada em scripts;
- **Licença de Uso** – Tipo de licenciamento, informando se o *software* é de código aberto, gratuito para pesquisa ou comercial;
- **Características** – Principais funcionalidades e aplicações, como suporte a EEG e MEG, métodos de análise, visualização e integração com outras ferramentas.

Essa comparação possibilita uma visão abrangente das diferentes ferramentas disponíveis para processamento e análise de dados EEG e MEG, auxiliando na escolha do *software* mais adequado conforme as necessidades específicas do usuário.

Tabela 1 Características básicas dos *software* de processamento de EEG pesquisados adaptado de (BARBOSA, 2019)

Software	Lingua-gem	Interface Gráfica	Licença de Uso	Características
EEGLAB	Matlab®	Sim	GNU General Public License	Funções: 400 Linhas de código: 50000 Plataforma: Multi
ERPLAB	Matlab®	Sim	Creative Commons Attribution License (CC BY)	Número de downloads do <i>software</i> : 7000
FIELDTRIP	Matlab®	Não	GNU General Public License	Plataforma: Multi Funções alto nível: 108 Funções baixo nível: 858 Linhas de código: 103227
MNE-Python	Python	Não	BSD licenced	Linhas de Código em Python: 44000 Linhas de comentário: 22000 Documentação: 35% Está entre os mais bem documentado projetos Python
PyEEG	Python	Não	Open Source	
Brain Vision Analyser	-	Sim	100 euros por 2 meses de teste	Recursos facilmente expansíveis (MATLAB®) e compatíveis com outros <i>software</i> de análise (BESA)

Software	Lingua-gem	Interface Gráfica	Licença de Uso	Características
Brainstorm	Matlab®	Sim	GNU General Public License	Usuários registrados: > 20000
MEGS	Matlab®	Sim	GNU General Public License	Memória RAM necessária: > 2 GB Aceleradores gráficos são bem-vindos para montagem de visões 3D.
BRAINVISA	Python	Sim		Plataforma: Multi Memória RAM: 2 Gb Espaço em disco: 1.5 Gb
ELAN	C	Sim		Plataforma: Linux Memória RAM necessária: > 128 MB Memória RAM recomendada: 4 GB
BIOSIG	Matlab®/C	Sim	GNU General Public License	
ASA		Sim	Paga	Plataforma: Windows Processador (CPU): > 2.2 GHz Memória RAM: > 1024 MB Internet Explorer: > 6.0.26 DirectX: > 9.0 c
CARTOOL	C++	Sim	Gratuito para pesquisas sem fins lucrativos	Plataforma: Windows Usuários cadastrados: 650 Memória RAM recomendada: 8 GB Tela de resolução recomendada: 1600x1200 pixels
BEAPP	Matlab®	Sim	GNU General Public License	Rastreia a saída e os parâmetros de cada etapa da análise, permitindo a revisão de etapas anteriores ou a execução novamente de uma parte da análise com novos parâmetros quando necessário.
Análise Geral	50% Matlab®, 22% Python, 28% Outros	78% Sim, 22% Não	71% Gratuito, 15% Pago, 14% Não especificado	Apenas 36% especifica os requerimentos de sistema para utilização. 21% Multiplataforma, 15% Windows, 7% Linux, 57% Não especificado

A análise dos *software* para processamento de EEG revela que metade deles são desenvolvidos em Matlab®, evidenciando a popularidade dessa plataforma entre pesquisadores e desenvolvedores. Além disso, a grande maioria 78% dos *software* oferece interfaces gráficas que facilitam a interação do usuário, e alguns permitem alternar entre uso via interface gráfica e linha de comando, ampliando a flexibilidade para diferentes perfis de usuário (BARBOSA, 2019).

Outro dado importante é que 71% dessas ferramentas são gratuitas e de código aberto, o que promove um ambiente colaborativo e acessível para a comunidade científica, beneficiando especialmente o meio acadêmico

(COMBRISSEON *et al.*, 2017). Contudo, muitos desses *software*, embora abertos, dependem da plataforma proprietária Matlab® para sua execução. Além disso, apenas uma parte menor, cerca de 36%, fornece informações detalhadas sobre os requisitos computacionais necessários para sua operação, o que pode ser um obstáculo, visto que o processamento de dados de EEG frequentemente demanda recursos computacionais elevados, especialmente em estudos que envolvem grandes volumes de dados.

Em relação à reprodutibilidade das análises, observa-se que ainda há limitações significativas devido à falta de padronização na documentação e compartilhamento dos códigos usados. Para mitigar isso, alguns *software* incluem registros detalhados dos parâmetros e operações realizadas, promovendo maior transparência e facilitando a replicação dos estudos (BARBOSA, 2019). Também é perceptível uma tendência crescente na utilização de *software* e dispositivos portáteis para monitoramento em tempo real, sobretudo em contextos de *neurofeedback* e interfaces cérebro-computador, favorecendo a usabilidade em ambientes extraclínicos e aumentando a aplicabilidade prática dessas tecnologias (BLUM *et al.*, 2017).

Diante do exposto, esta tese propõe a tradução do *software* de processamento de EEG desenvolvido pelo grupo de pesquisa do Professor Doutor João Batista Destro Filho, dedicado aos estudos de eletroencefalograma, para a linguagem Python, uma linguagem de programação de código aberto que permite uso e distribuição livres, sem custos associados. Tal mudança justifica-se pela substituição da versão corrente em uma plataforma computacional que possui algumas despesas. Além disso, baseado no levantamento dos *software* existentes, planeja-se a criação de uma interface gráfica integrada, visando facilitar a utilização da ferramenta por novos pesquisadores do grupo e ampliar seu potencial de aplicação.

2.3 ESTIMULAÇÃO MUSICAL E NEUROCIÊNCIA

A música está presente no cotidiano e possui o poder de influenciar os sentidos e os processos cognitivos. Grande parte desses estímulos são processados pelo córtex auditivo, desencadeando atividades cerebrais que vão desde a ativação da memória até a modulação do estado emocional, podendo gerar sensações como

alegria, amor, tristeza e angústia (MAGUIRE, 2012). Dessa forma, a música pode ser compreendida como uma combinação harmoniosa de sons, capaz de gerar experiências sensoriais significativas para o ser humano.

Estudos como o de (MOORE, 2013) buscam compreender como a estimulação musical influencia as estruturas neurais envolvidas na regulação emocional, investigando suas possíveis implicações clínicas. Esses achados permitem identificar características musicais e experiências associadas a diferentes padrões de ativação neural, dependendo do contexto musical. Ao ouvir músicas preferidas ou familiares, cantar ou improvisar, observa-se um padrão específico de ativação. Por outro lado, quando a música introduz maior complexidade, dissonância ou eventos musicais inesperados, a ativação neural pode seguir um padrão distinto, refletindo diferentes mecanismos de regulação emocional.

O EEG possibilita a associação entre o estado físico e mental do paciente durante o exame, com base na frequência das ondas cerebrais registradas pelos eletrodos. Ondas de baixa frequência (Delta: 0,5 – 3,5 Hz; Teta: 3,5 – 7,5 Hz; Alfa: 7,5 – 12,5 Hz) estão associadas ao sono profundo e ao estado de vigília. Por outro lado, ondas de maior frequência (Beta: 12,5 – 30 Hz; Gama: 30 – 80 Hz; Supergama: 80 – 120 Hz) estão relacionadas a atividades cognitivas, como percepção, atenção e memória (FREEMAN; QUIROGA, 2013).

Com base em dados de EEG, diversos estudos investigam a relação entre a estimulação sonora e as faixas de frequência observadas nos exames de EEG. Por exemplo, o estudo de (CHEN; YAO; JIANG, 2017) identificou que a faixa de 20 a 35 Hz (Beta e Gama) na região do córtex frontal apresentou destaque durante a audição de músicas e a imaginação musical. Essa mesma relação foi evidenciada no estudo de (WILL; BERG, 2007), que apontou que os efeitos de sincronização na faixa de 13 a 44 Hz (Beta e Gama) influenciam funções cognitivas como aprendizagem e memória.

O estudo de (MAITY *et al.*, 2015) destacou a ativação das faixas Alfa e Teta na região frontal durante a estimulação musical com drones de tampura (instrumento de corda indiano), em comparação ao mesmo paciente sem estímulo musical.

Da mesma forma, (TANDLE *et al.*, 2016) enfatizou que a potência da faixa Teta no hemisfério esquerdo apresenta um comportamento distinto do hemisfério

direito durante a estimulação musical. Observou-se um aumento da atividade Teta em voluntários que apreciaram a música, evocando emoções positivas e/ou agradáveis, enquanto aqueles que não apreciaram a estimulação apresentaram uma redução nessa atividade. Além disso, (TSENG *et al.*, 2013) também identificou um destaque na faixa Teta e apontou a assimetria na atividade Alfa ao longo da estimulação musical.

Conforme (FOLGIERI; BERGOMI; CASTELLANI, 2014), a relação entre estímulos musicais agradáveis e desagradáveis e a atividade neural em diferentes regiões frontais apresenta padrões distintos. Os resultados indicaram que músicas classificadas como agradáveis apresentam maior relevância na região frontal esquerda, com predominância das faixas Teta e Gama em comparação às faixas Alfa e Beta. Em contrapartida, estímulos sonoros considerados desagradáveis mostraram maior ativação na região frontal direita, com destaque para as faixas Alfa e Beta, quando comparadas a Teta e Gama.

Pesquisas como a de (KOELSCH, 2011) buscam identificar as áreas cerebrais envolvidas na percepção musical e na memória associada à música. No entanto, essas investigações enfrentam desafios significativos para obter dados conclusivos, evidenciando que essa ainda é uma temática em desenvolvimento, que demanda estudos mais aprofundados e fundamentação adicional.

O que se evidencia em todos os estudos envolvendo música e EEG é que a atividade cerebral sofre alterações significativas durante a estimulação musical, refletindo padrões distintos no traçado do exame. Além disso, essas alterações podem se manifestar de maneira específica em diferentes regiões cerebrais, dependendo das características do estímulo aplicado.

Dessa forma, a literatura revisada demonstra que a relação entre música e atividade neural é um campo de estudo promissor, mas ainda em desenvolvimento. Embora os avanços permitam identificar padrões de ativação cerebral associados à estimulação musical, os desafios metodológicos e a variabilidade individual dos participantes reforçam a necessidade de investigações mais aprofundadas e metodologias mais padronizadas.

Esta tese investiga a análise dos sinais de EEG submetidos à estimulação musical, com o objetivo de comparar diferentes tipos de estímulos e identificar padrões

distinguíveis em suas respostas cerebrais. A continuidade dessas pesquisas é fundamental para aprofundar o entendimento dos efeitos da música sobre a atividade cerebral, contribuindo para avanços em áreas como neurociência, reabilitação e promoção do bem-estar.

2.4 INTELIGÊNCIA ARTIFICIAL E EEG

A inteligência artificial (IA) constitui um campo proeminente da ciência da computação, voltado ao desenvolvimento de sistemas capazes de desempenhar funções cognitivas complexas, abrangendo, entre outras, aprendizado, raciocínio, percepção, compreensão de linguagem natural e tomada de decisão. Esse campo tem encontrado ampla aplicação em diversas áreas, como saúde (BAJWA *et al.*, 2021), finanças (RAMEZANI *et al.*, 2023), transporte (WILBUR *et al.*, 2023) e segurança (KOMMRUSCH, 2019), transformando a interação cotidiana com tecnologias (MARTINS, 2023). No núcleo desses avanços, destacam-se as redes neurais profundas e os modelos de aprendizado de máquina, que possibilitam a construção de soluções cada vez mais precisas e eficientes, capacitando sistemas a processar grandes volumes de dados e extrair informações relevantes de maneira autônoma (ORACLE, [s.d.]).

No contexto da neurociência e da interação homem-máquina, a inteligência artificial (IA) exerce um papel crucial, sobretudo em sistemas de interface cérebro-computador (BCI). Essas tecnologias viabilizam a conexão direta entre o cérebro humano e dispositivos externos por meio de sinais, como os obtidos pelo eletroencefalograma (EEG). Esse registro da atividade elétrica cerebral fornece uma fonte rica de dados para a aplicação de algoritmos de aprendizado profundo e outras abordagens de IA (GU *et al.*, 2021).

Os sinais de EEG caracterizam-se por desafios notáveis, como a elevada variabilidade interindividual, a susceptibilidade a ruídos e sua natureza não estacionária (KAMRUD; BORGHETTI; SCHUBERT KABBAN, 2021). Para contornar essas limitações, técnicas de inteligência artificial (IA), como redes neurais convolucionais (CNNs) e redes neurais recorrentes (RNNs), têm sido amplamente utilizadas (LAM; LUI, 2023). Esses métodos possibilitam a identificação de padrões

relevantes, aprimorando o desempenho em tarefas como a classificação de emoções, a detecção de imaginação motora e a previsão de prognósticos clínicos (CARNEIRO *et al.*, 2023; LAM; LUI, 2023; QIAN *et al.*, 2022; YAO *et al.*, 2024).

Adicionalmente, algumas aplicações de IA têm integrado sinais de eletroencefalograma (EEG) a outros dados fisiológicos, como a resposta galvânica da pele e os batimentos cardíacos, em abordagens multimodais. Essas integrações contribuem para o desenvolvimento de sistemas mais robustos, com aplicações em saúde, entretenimento e neurociência (FU *et al.*, 2022). Por exemplo, no âmbito da avaliação emocional, estudos demonstraram que a combinação de EEG com sinais periféricos permite identificar estados afetivos com maior precisão, resultando em classificações mais acuradas (BALDO JÚNIOR, 2023; FU *et al.*, 2022).

A inteligência artificial (IA) segue transformando o campo das BCI, expandindo as possibilidades de interação entre humanos e máquinas. Desde o controle de dispositivos por indivíduos com deficiências motoras até o diagnóstico de condições neurológicas, a IA oferece soluções inovadoras que redefinem a integração entre tecnologia e saúde (WILLETT *et al.*, 2023; ZHANG *et al.*, 2024).

Entre as inovações mais marcantes no campo da IA destaca-se o surgimento dos modelos baseados em *Transformers*. Introduzidos por (VASWANI *et al.*, 2017) no artigo “*Attention is All You Need*”, publicado pela equipe do *Google Research*, os *Transformers* revolucionaram o processamento de linguagem natural (NLP, na sigla em inglês) ao propor um mecanismo de atenção que captura eficientemente relações de longo alcance em sequências de dados. Diferentemente das arquiteturas tradicionais, como redes neurais recorrentes (RNNs) e convolucionais (CNNs), que processam sequências de forma iterativa ou local, os *Transformers* utilizam exclusivamente o mecanismo de atenção, possibilitando o processamento paralelo dos dados e alcançando maior eficiência computacional (VASWANI *et al.*, 2017).

A arquitetura dos *Transformers* constitui a base de modelos amplamente reconhecidos, como o GPT (*Generative Pre-trained Transformer*) e o BERT (*Bidirectional Encoder Representations from Transformers*), e tem sido aplicada em áreas além do processamento de linguagem natural (NLP), como visão computacional, biologia computacional e, mais recentemente, o desenvolvimento de sistemas multimodais. Sua capacidade de processar grandes volumes de dados e de

se adaptar a diferentes tipos de tarefas a posiciona como uma das tecnologias mais promissoras no campo da IA (ISLAM *et al.*, 2023).

A principal inovação dos *Transformers* reside em sua capacidade de processar dados paralelamente, diferentemente do processamento sequencial característico das redes neurais recorrentes (RNNs) (VASWANI *et al.*, 2017). Esse avanço proporciona ganhos expressivos em eficiência computacional, especialmente em aplicações que demandam o manejo de grandes volumes de dados, como o processamento de linguagem natural (NLP) e a análise de sinais cerebrais. Na análise de EEG, essa característica permite que os *Transformers* integrem informações temporais e espaciais de forma eficiente, aprimorando a precisão das classificações em tarefas complexas (YAO *et al.*, 2024).

Recentemente, os *Transformers* têm sido adaptados para tarefas específicas na análise de EEG, como o reconhecimento de emoções e a classificação de imaginação motora. Modelos como o EEGformer integram convoluções unidimensionais (1D-CNNs) para extrair características locais com camadas de *Transformer* que capturam dependências globais, alcançando resultados superiores em comparação com outras arquiteturas de aprendizado profundo (WAN *et al.*, 2023).

Além disso, arquiteturas híbridas que integram *Transformers* a redes neurais convolucionais (CNNs) têm se revelado promissoras. Estudos recentes, por exemplo, empregaram *Transformers* para detectar padrões complexos em sinais de EEG, utilizando mecanismos de atenção que destacam regiões cerebrais relevantes enquanto mantêm as características temporais do sinal (LIU *et al.*, 2024; LU; MA; TAN, 2023). Essas abordagens têm sido aplicadas com êxito em áreas como diagnóstico clínico, reconhecimento de emoções e controle de dispositivos assistivos.

Em síntese, os *Transformers* revolucionaram o aprendizado profundo ao estabelecer um novo paradigma para a análise de dados sequenciais e espaciais. Sua flexibilidade e eficiência o consolida como uma ferramenta essencial em aplicações que abrangem desde a neurociência até a inteligência artificial geral. Contudo, sua utilização na análise de EEG permanece pouco explorada, sobretudo em tarefas voltadas à avaliação de pacientes em coma.

Nesta tese, explorou-se a aplicação de diversos modelos de inteligência artificial (IA) ao treinamento de bases de dados de EEG, com o objetivo de aprimorar

a análise e interpretação dos sinais cerebrais. Para tanto, empregou-se arquiteturas de aprendizado profundo como redes neurais convolucionais (CNNs), redes de memória de longo curto prazo (LSTMs), perceptrons multicamadas (MLPs) e *Transformers*, além de modelos híbridos. Essa seleção diversificada visa avaliar sistematicamente o desempenho em diferentes tarefas, que incluem o prognóstico clínico, a identificação da etiologia do coma e a análise da resposta à estimulação musical.

CAPÍTULO 3 - PROCESSAMENTO DO EEG

O processamento do EEG é uma etapa fundamental para a extração de informações relevantes a partir dos sinais cerebrais. Esse processo envolve diversas técnicas, como filtragem, segmentação, extração de características e análise estatística, possibilitando a interpretação e a aplicação dos dados em diferentes contextos científicos e clínicos.

Neste capítulo, será apresentado o funcionamento do *software* de processamento de EEG, destacando sua implementação tanto na plataforma computacional corrente, quanto em sua versão transcrita para Python. A transcrição do código visa proporcionar maior acessibilidade e flexibilidade, uma vez que o Python é uma linguagem de código aberto amplamente utilizada na comunidade científica. A seguir, serão descritos os principais aspectos do processamento, comparando as abordagens adotadas em cada linguagem e suas respectivas funcionalidades.

3.1 MATERIAIS E MÉTODOS

Esta seção apresenta e descreve as tecnologias e metodologias empregadas no processamento do EEG, destacando os recursos utilizados para a implementação do *software* na plataforma computacional e em linguagem Python. Serão abordadas as ferramentas computacionais, bibliotecas e algoritmos empregados, bem como os critérios adotados para a extração, filtragem e análise dos sinais cerebrais.

A seguir, são detalhados os materiais utilizados e os procedimentos metodológicos aplicados no desenvolvimento deste estudo.

3.1.1 Tecnologias utilizadas

Para a implementação e processamento dos sinais de EEG, diversas tecnologias foram empregadas ao longo do desenvolvimento deste estudo. Estas ferramentas foram selecionadas com base em sua eficiência, compatibilidade e

relevância científica, permitindo um fluxo de trabalho organizado e reproduzível. A seguir, são apresentadas as principais tecnologias utilizadas, juntamente com suas funções e aplicações dentro do projeto.

3.1.1.1 GIT

O GIT é um sistema de controle de versão distribuído que facilita o gerenciamento de arquivos e o rastreamento de alterações, registrando cada modificação realizada no projeto. Sua utilização permite que múltiplos desenvolvedores trabalhem simultaneamente no mesmo conjunto de arquivos, evitando o risco de sobrescrita de alterações e garantindo a integridade do código (SCHMITZ, 2015).

Uma das principais funcionalidades do GIT é a criação de *branches*, que consistem em cópias do projeto em um determinado estado. Essas ramificações permitem o desenvolvimento de novas funcionalidades de forma paralela à evolução do projeto principal, sem interferir diretamente na versão estável. Somente após serem testadas e validadas, as novas implementações são integradas novamente ao projeto principal, garantindo maior segurança e organização no desenvolvimento (SCHMITZ, 2015).

O versionamento de arquivos GIT segue um conjunto abrangente de regras, garantindo controle e organização no desenvolvimento de projetos. Diversas empresas adotam essas diretrizes e oferecem serviços baseados em GIT, como o *Bitbucket* e o *GitHub*, que permitem o armazenamento, a colaboração e o gerenciamento remoto de repositórios de código.

Mantido pela *Atlassian*, o *Bitbucket* oferece suporte a um número ilimitado de repositórios privados, sendo gratuito para equipes pequenas de até cinco desenvolvedores. Para equipes maiores ou em expansão, há planos pagos, como o Padrão (US\$ 3 por usuário/mês) e o Premium (US\$ 6 por usuário/mês) (BITBUCKET, 2021).

Adquirido pela Microsoft, o *GitHub* é uma das plataformas de controle de versão mais populares, oferecendo suporte a repositórios públicos e privados. O serviço é gratuito para usuários individuais e pequenas equipes, permitindo a criação de repositórios privados sem custo. Para equipes maiores ou com demandas

corporativas, o GitHub disponibiliza planos pagos, como o Team (US\$ 4 por usuário/mês) e o Enterprise (US\$ 21 por usuário/mês), que oferecem recursos adicionais de segurança e gerenciamento (GITHUB, 2024).

Para garantir o versionamento e a rastreabilidade das diferentes versões do código-fonte, o GIT foi empregado ao longo do desenvolvimento deste projeto. A ferramenta permitiu o controle eficiente das modificações, possibilitando a organização das alterações, o acompanhamento da evolução do *software* e a colaboração entre diferentes versões. Além disso, o uso de repositórios remotos, como GitHub e Bitbucket, proporcionou maior segurança no armazenamento do código e facilitou a recuperação de versões anteriores quando necessário.

3.1.1.2 Plataforma computacional

A plataforma computacional é um ambiente interativo de computação científica, utilizado para cálculo numérico, processamento de sinais e visualização de dados. Sua popularidade deve-se, em grande parte, à sua capacidade otimizada para manipulação de matrizes e vetores, facilitando a implementação de algoritmos complexos e a análise de dados em diversas áreas, como engenharia, neurociência e aprendizado de máquina. Além disso, a plataforma computacional oferece uma ampla variedade de ferramentas e bibliotecas especializadas, que permitem a execução eficiente de simulações, modelagem matemática e processamento avançado de sinais.

3.1.1.3 Python

O Python é uma linguagem de programação de alto nível, amplamente adotada para análises e processamento de dados, estando em constante evolução e aprimoramento. Atualmente, é considerada uma das principais ferramentas para ciência de dados, aprendizado de máquina, computação científica e desenvolvimento de *software* (GRAMFORT *et al.*, 2013). Sua versatilidade permite sua aplicação em diversas áreas, sendo utilizada em diferentes tipos de *software*, desde sistemas embarcados até plataformas avançadas de inteligência artificial.

3.1.1.4 CSV

O CSV (*Comma-Separated Values* – Valores Separados por Vírgula) é um formato de arquivo amplamente utilizado para armazenar e organizar dados de forma tabular. Esse tipo de arquivo pode ser criado ou editado em *software* como Microsoft Excel ou em qualquer editor de texto, pois trata-se de um arquivo de texto simples, onde os valores são separados por vírgulas (ou, em algumas configurações, por ponto e vírgula). Cada vírgula representa uma separação entre colunas, permitindo que os dados sejam interpretados corretamente por diferentes programas e linguagens de programação (MICROSOFT, [s.d.]).

3.1.2 Metodologia

Dando continuidade ao projeto desenvolvido na dissertação de mestrado (BARBOSA, 2019), iniciou-se um levantamento de linguagens de programação que atendessem a dois critérios essenciais: serem de código aberto (*open source*) ou não exigirem o pagamento de licença de uso. Além disso, a escolha da linguagem levou em consideração a familiaridade do grupo de pesquisa do Professor Doutor João Batista Destro Filho, dedicado aos estudos de eletroencefalograma, de modo a facilitar a implementação e manutenção do código.

Entre as linguagens analisadas, destacaram-se Python, Octave e Scilab. A opção pelo Python foi motivada por dois fatores principais: a expertise prévia do coorientador da tese nessa linguagem e a adoção crescente do Python pelo grupo de pesquisa, que já vinha desenvolvendo outros projetos utilizando essa tecnologia.

Após a definição da linguagem, foi realizado um estudo aprofundado sobre suas melhores práticas e sintaxe, com base em documentação oficial, materiais didáticos, vídeos educacionais e cursos especializados na plataforma *Alura* (plataforma de cursos online). Esse estudo teve como objetivo garantir uma implementação estruturada, padronizada e alinhada com as diretrizes mais eficientes para desenvolvimento em Python.

Concluída essa etapa, foi realizada a transcrição do *software* original, previamente implementado na plataforma computacional, para Python. Essa conversão mostrou-se necessária devido às restrições da plataforma computacional,

que limitavam tanto o acesso quanto a reprodutibilidade do *software* original dentro do grupo de pesquisa. A adoção do Python, por ser uma linguagem de código aberto e amplamente utilizada na comunidade científica, proporcionou maior acessibilidade, flexibilidade e escalabilidade ao projeto.

Para assegurar a confiabilidade e robustez do código transcrito, foi desenvolvida uma suíte de testes unitários, um processo essencial para a validação automatizada das funcionalidades implementadas. Os testes unitários têm como principal objetivo verificar individualmente cada módulo ou função do código, garantindo que operem corretamente de forma isolada antes de serem integrados ao sistema completo.

A aplicação dessa metodologia foi fundamental para identificar rapidamente eventuais falhas, assegurar a equivalência entre as versões do *software* original e Python, garantindo a reprodutibilidade dos resultados. Além disso, a implementação dos testes unitários permitiu um desenvolvimento mais seguro e eficiente, reduzindo a ocorrência de erros sistêmicos e facilitando manutenções futuras no código.

A transcrição preservou a lógica e a funcionalidade do *software* original, mantendo-se alinhada à proposta apresentada na dissertação de mestrado (BARBOSA, 2019). O fluxo de processamento pode ser descrito da seguinte forma:

1. O *software* recebe um arquivo no formato .CSV, contendo os parâmetros de entrada para o processamento de cada EEG.
2. Para cada linha do arquivo CSV (correspondente a um EEG), o sistema executa as rotinas definidas e gera um arquivo de saída, contendo os quantificadores extraídos e/ou calculados.

Essa abordagem visa garantir acessibilidade, flexibilidade e reprodutibilidade na análise de EEG, ampliando a aplicabilidade do *software* para diferentes contextos de pesquisa.

3.2 SOFTWARE NA PLATAFORMA COMPUTACIONAL

O *software* desenvolvido na plataforma computacional tem sua implementação fundamentada no trabalho apresentado na dissertação de mestrado

de (BARBOSA, 2019), na qual foi originalmente concebido. Nesse trabalho, o *software* foi projetado para o processamento de sinais de EEG, permitindo a extração e análise de quantificadores específicos a partir dos dados registrados. Sua estrutura segue uma organização modular, garantindo maior reprodutibilidade e escalabilidade.

Nessa dissertação, todo o código-fonte foi versionado e armazenado em um repositório privado no Bitbucket, acessível exclusivamente pelos desenvolvedores do grupo de pesquisa do Professor Doutor João Batista Destro Filho. Esse controle de versão permite o rastreamento das alterações, assegurando a organização, segurança e integridade do desenvolvimento do *software*.

A documentação detalhada das funções desenvolvidas no *software* pode ser encontrada no **APÊNDICE A**, onde cada função é descrita em termos de sua finalidade, parâmetros de entrada e saída, além de seu papel no processamento dos sinais de EEG. Complementarmente, no **APÊNDICE B**, está o detalhamento completo das variáveis geradas durante a execução do software, incluindo suas definições e formatos.

3.3 EVOLUÇÃO DO SOFTWARE NA PLATAFORMA COMPUTACIONAL

No início deste trabalho, foi solicitado pelos membros do grupo de pesquisa do Professor Doutor João Batista Destro Filho o aprimoramento do *software* de processamento de sinais, com o objetivo de agregar novas funcionalidades e simplificar o processamento dos EEGs pela equipe. As melhorias realizadas buscaram atender às necessidades específicas do grupo, otimizando tanto a eficiência quanto a usabilidade da ferramenta. A seguir, são detalhadas as principais modificações implementadas.

3.3.1 Remoção de colunas do arquivo .CSV de entrada

Durante o processo de melhorias no *software* de processamento, uma das alterações realizadas foi a remoção de colunas específicas do arquivo de entrada no formato .CSV. Essa modificação visou simplificar a estrutura do arquivo e garantir que os dados processados fossem estritamente os necessários para as análises. As colunas removidas, bem como suas respectivas descrições, estão listadas abaixo:

- **Coluna N (Qtd Ruidosos):** Quantidade de canais ruidosos indicado pelo médico;
- **Coluna O a Q (Canal ruidoso X):** Nome do canal ruidoso informado pelo médico, podendo ser: FP1, FP2, F7, F3, FZ, F4, F8, T3, C3, CZ, C4, T4, T5, P3, PZ, P4, T6, O1, OZ, O2;
- **Coluna R (Normal/Coma):** Se o valor "Normal" for encontrado nesta coluna, o filtro passa baixa será ajustado para 100 Hz; caso o valor seja "COMA", o filtro será ajustado para 30 Hz; e
- **Coluna S (Filtro):** Filtro passa baixa.

3.3.2 Adição das seguintes colunas do arquivo .CSV de entrada

Como parte das melhorias implementadas no *software*, foram adicionadas novas colunas ao arquivo .CSV de entrada, com o objetivo de expandir as funcionalidades e permitir maior flexibilidade no processamento dos sinais EEG. A descrição das colunas introduzidas, juntamente com suas respectivas funções, é apresentada a seguir:

- **Coluna B (Função Filtro):** Define o nome da função responsável pelo filtro do sinal;
 - Essa função deve estar localizada no mesmo diretório que os arquivos de script da plataforma computacional utilizados para processar os PLGs. O nome do arquivo deve ser idêntico ao da função;
 - A função deve obrigatoriamente receber uma matriz de dimensões $(X \times Y)$ como entrada e retornar o sinal filtrado com dimensões $(X_1 \times Y_1)$.
- **Coluna C (Limiar de erro):** Indica o limiar de erro aceitável para determinar se um canal será zerado. O valor padrão é 0.7;
 - Utiliza-se o ponto, e não a vírgula, para números decimais;
 - Os valores representam:
 - 0 representa 0%;
 - 0.5 representa 50%; e
 - 1 representa 100%.

- Um canal é considerado ruidoso se o valor máximo da potência na faixa de ruído (58 a 62 Hz) ultrapassar o **Limiar de erro** (errorThreshold) em relação à potência máxima da faixa do sinal.
- **Coluna P (Medico Canais Ruidosos):** Lista os canais ruidosos identificados pelo médico. Exames com mais de 3 canais ruidosos deverão ser descartados;
 - Os canais devem ser separados por vírgula. Exemplo: FP1,FP2,F7,F3,FZ,F4,F8,T3,C3,CZ,C4,T4,T5,P3,PZ,P4,T6,O1,OZ,O2.
- **Coluna Q (Filtro Passa Baixa):** Define a frequência máxima de processamento do exame em Hertz;
 - Valor padrão: 100 Hz para indivíduos saudáveis;
 - Recomenda-se 35 Hz para exames realizados na Unidade de Terapia Intensiva (UTI).
- **Coluna R (Quantificadores):** Determina os quantificadores a serem calculados ou processados (PCP, FM, COERENCIA, PSNG, PSNE, VPN, TODOS);
 - Os valores devem ser separados por vírgula. Se a palavra "TODOS" estiver presente, todos os quantificadores serão processados
- **Coluna S (Parametros):** Especifica os parâmetros para o cálculo dos quantificadores. Deve-se usar o formato nome do parâmetro seguido do operador de igual e posteriormente o valor que se deseja que ele assuma, como no exemplo:
 - $taumax=300;$
 - Valor padrão: $taumax = fix(1.67 * fa);$
 - **Atenção:** o *software* diferencia maiúsculas e minúsculas, sendo essencial respeitar o padrão indicado.
- **Coluna T (Canais a Processar):** Define os canais utilizados no cálculo dos quantificadores.
 - Devem ser separados por vírgula. Exemplo: FP1,F8,T3,C3,CZ,T4,T5,OZ,O2;
 - Caso nenhum canal seja informado, o sistema utilizará os seguintes canais presentes: FP1,FP2,F7,F3,FZ,F4,F8,T3,C3,CZ,C4,T4,T5,P3,PZ,P4,T6,O1,OZ,O2.

3.3.3 Alteração de ordem de coluna

Em continuidade às adaptações realizadas no *software*, foi necessária a reorganização da ordem de determinadas colunas no arquivo .CSV de entrada. Com essas mudanças, a coluna 'Nome Saida' passou a ocupar a última posição, identificada como Coluna V, enquanto o campo 'Gerar Excel' foi reposicionado para a penúltima posição, agora definida como Coluna U. Essas alterações promovem uma estruturação mais lógica e funcional dos dados.

3.3.4 Customização da coluna “QTD EPOCAS”

A coluna “QTD EPOCAS” foi customizada para permitir maior flexibilidade no processamento dos sinais EEG. Quando esta coluna apresentar o conteúdo $SEQUENCIAL = X$, onde X é um número inteiro, o *software* utilizará os dados presentes no campo $Ep1$ para gerar X épocas. Neste contexto, uma época é definida como um segmento contínuo do sinal EEG, delimitado por um intervalo de tempo específico, geralmente utilizado para análise de eventos ou estímulos. Essas épocas serão criadas com base no tempo especificado no referido campo e terão uma duração equivalente ao valor definido na coluna D.

3.3.5 Considerações

As alterações priorizaram a reorganização estrutural e a inserção de novas colunas no arquivo CSV de entrada. Embora essas mudanças tenham sido significativas, as funcionalidades essenciais do *software* original foram preservadas, enquanto as personalizações oriundas das novas colunas incrementaram sua flexibilidade operacional e aplicabilidade clínica (ver **APÊNDICE E**).

Como produto complementar, desenvolveu-se um manual de operação detalhado para orientar usuários no processamento de exames EEG com a evolução do *software* original. Para validação, foi conduzido um teste de regressão rigoroso, comparando 100 exames do grupo controle (indivíduos saudáveis) com 100 exames de pacientes com condições neurológicas, ambos analisados nas versões original e aprimorada do *software*. Os achados demonstraram consistência nos resultados mesmo após as modificações, confirmando a estabilidade do *software*.

3.4 SOFTWARE EM PYTHON

O processamento de sinais EEG é uma área complexa na neurociência, permitindo a análise detalhada da atividade cerebral. Com o objetivo de expandir a acessibilidade e a flexibilidade dessas análises, o *software* original desenvolvido na plataforma computacional foi traduzido para Python. Essa migração aproveita as vantagens do Python, como sua ampla comunidade de desenvolvedores, bibliotecas avançadas para processamento de dados (como *NumPy* e *SciPy*), e a capacidade de integração com outras ferramentas científicas.

A escolha do Python para essa tradução foi motivada pela sua eficiência em lidar com grandes conjuntos de dados, além de sua facilidade de uso e manutenção. Além disso, o Python permite uma maior interoperabilidade com outras linguagens e plataformas, facilitando a colaboração entre pesquisadores de diferentes áreas. Neste item, detalhamos o processo de desenvolvimento do *software* em Python, destacando as principais características, desafios enfrentados e soluções implementadas durante a tradução.

3.4.1 Versionamento

Para garantir a consistência e a rastreabilidade das modificações realizadas durante a tradução do *software* original da plataforma computacional para Python, foi adotado um esquema de versionamento compatível com o utilizado no projeto original. Uma pasta intitulada "Python" foi criada dentro do projeto, contendo todos os códigos relacionados à transcrição para Python. Este esquema permite que as atualizações e melhorias sejam facilmente identificadas e gerenciadas, mantendo a integridade do desenvolvimento do *software*.

3.4.2 Detalhes da Implementação

A adoção do paradigma de programação orientada a objetos (POO) foi uma decisão consciente do autor, motivada pela familiaridade e experiência prévia com essa abordagem. A escolha do POO foi guiada pela necessidade de garantir modularidade e extensibilidade no desenvolvimento do *software* em Python, aspectos essenciais para um sistema que requer flexibilidade e manutenção contínua.

A decisão de utilizar o POO foi justificada por várias razões:

- **Encapsulamento e Modularidade:** O POO permite encapsular dados e comportamentos relacionados em unidades lógicas (classes), facilitando a organização do código e a manutenção futura. Isso foi crucial para o desenvolvimento de um sistema que lida com dados complexos de EEG, onde a clareza e a estruturação são fundamentais;
- **Extensibilidade:** A capacidade de criar classes que podem ser facilmente estendidas ou modificadas foi essencial para permitir a inclusão de novas funcionalidades sem comprometer a estabilidade do sistema existente. Isso foi particularmente importante, pois o *software* precisava ser adaptável a diferentes tipos de análises e processamentos de sinais EEG;
- **Reutilização de Código:** O POO facilita a reutilização de código, uma vez que as classes podem ser compartilhadas entre diferentes partes do sistema ou até mesmo em outros projetos. Essa característica foi vital para otimizar o desenvolvimento, reduzindo o tempo e o esforço necessários para implementar funcionalidades semelhantes;
- **Legibilidade e Manutenção:** A estruturação do código em classes e objetos melhora significativamente a legibilidade, tornando mais fácil para outros desenvolvedores entenderem e contribuir para o projeto. Além disso, a modularidade facilita a identificação e correção de erros, reduzindo o tempo de manutenção.

Foram desenvolvidas duas classes principais, *EegRecord* e *Epoch*, com papéis complementares no processamento dos dados de EEG. Essas classes foram projetadas para mapear os exames e gerenciar as épocas do sinal, aproveitando plenamente os princípios da Programação Orientada a Objetos (POO), o que assegura um sistema robusto, flexível e escalável.

- **EegRecord:** responsável pelo mapeamento do exame de EEG. Seu diagrama de classe é apresentado na Figura 3;
- **Epoch:** encarregada de gerenciar as épocas do exame de EEG, com seu diagrama de classe ilustrado na Figura 4.



Figura 3 - Diagrama de Classe EegRecord

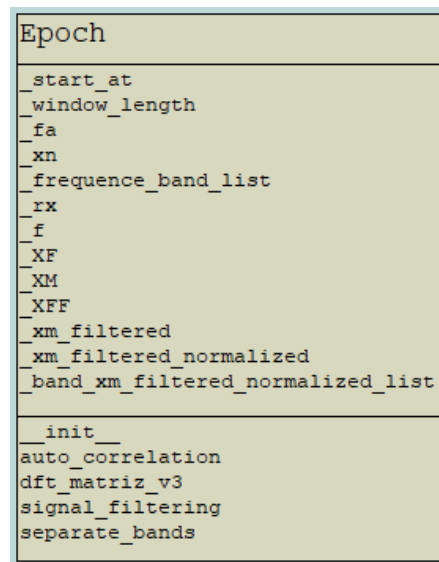


Figura 4 - Diagrama de Classe Epoch

Nota-se que essas duas classes refletem, em essência, as mesmas funcionalidades presentes no *software* na plataforma computacional. Para validar sua implementação, foram desenvolvidas duas suítes de testes correspondentes, uma para cada classe:

- **EegRecordTest**: suíte de testes destinada à classe EegRecord, cujo diagrama de classe é apresentado na Figura 5;
- **EpochTest**: suíte de testes associada à classe Epoch, com seu diagrama de classe ilustrado na Figura 6.



Figura 5 - Diagrama de Classe EegRecordTest

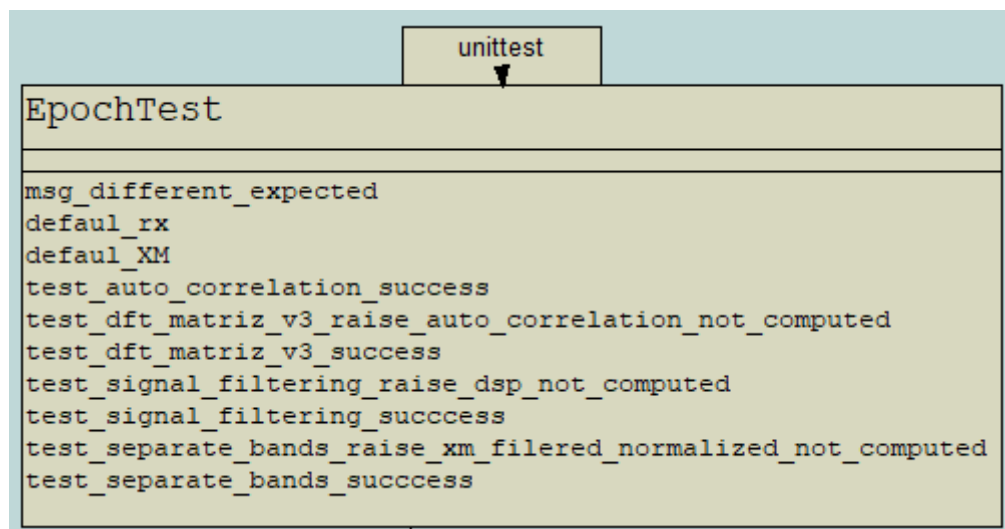


Figura 6 - Diagrama de Classe EpochTest

Os testes foram desenvolvidos com dados significativamente menores do que aqueles encontrados na prática, uma escolha intencional devido à simplicidade desejada para os testes unitários. O uso de dados excessivamente volumosos tornaria a comparação dos resultados demasiadamente extensa e complexa. Assim, foi criada uma unidade de teste adicional, dedicada à comparação entre os resultados gerados

em Python e aqueles obtidos com o *software* original na plataforma computacional, os quais serão detalhados na sequência.

3.4.3 Interface gráfica

A criação de uma interface gráfica visou facilitar o uso do *software* de processamento de EEG, especialmente para usuários que não possuem conhecimentos avançados em programação. Para isso, foi utilizada a biblioteca *Tkinter*, padrão do Python para desenvolvimento de interfaces gráficas, compatível com os principais sistemas operacionais, como Windows, Linux e MacOS. A interface permite que o usuário execute funcionalidades complexas do software por meio de uma plataforma visual intuitiva, eliminando a necessidade de lidar diretamente com o *prompt* de comandos ou instalar manualmente as dependências, etapas que costumam ser desafiadoras para iniciantes.

Dessa forma, a interface apresenta um ponto de entrada acessível, onde basta executar um arquivo para que a janela principal seja exibida, disponibilizando menus e opções organizados para conduzir o usuário durante o processamento dos dados. Essa abordagem não só torna o *software* mais amigável para novos pesquisadores do grupo, como também contribui para a padronização e repetibilidade das análises realizadas, potencializando a disseminação e o uso da ferramenta em diferentes contextos.

Para facilitar a utilização, a interface gráfica foi projetada para ser executada por meio de um arquivo executável único, que abre diretamente a janela principal do *software*, conforme ilustrado na Figura 7. Essa janela dispõe dos seguintes menus:

- **Processar EEG (arquivo .CSV):** permite ao usuário selecionar um arquivo no formato .CSV, conforme especificado anteriormente, para o processamento dos dados de EEG;
- **Topografia:** oferece a possibilidade de inserir um vetor contendo 20 números reais, que serão utilizados para gerar mapas topográficos da atividade cerebral;
- **Change Theme!:** possibilita ao usuário alterar o tema visual da interface gráfica, modificando as cores e proporcionando uma experiência personalizada durante o uso.




Figura 7 - Tela inicial da interface gráfica do software em python

Ao selecionar o primeiro menu, é exibida a tela ilustrada na Figura 8. Nesta interface, o usuário pode escolher o arquivo .CSV para processamento clicando no botão **“Select”** ou digitando o caminho do arquivo no campo **“File:”**. Em seguida, o processamento é iniciado ao clicar no botão **“Process”** e os detalhes do processamento são exibidos em tempo real na área **“Logs”**. Ao término do processo, um modal informa o sucesso da operação, conforme mostrado na Figura 9, enquanto uma mensagem de erro é exibida em caso de falha, ilustrada na Figura 10.

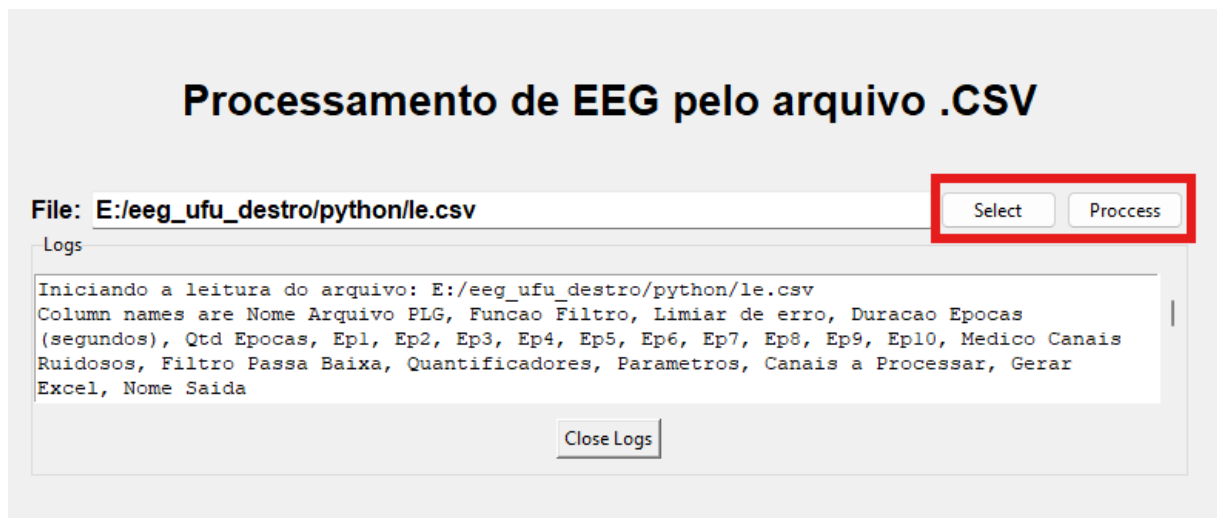


Figura 8 - Tela de processamento do EEG

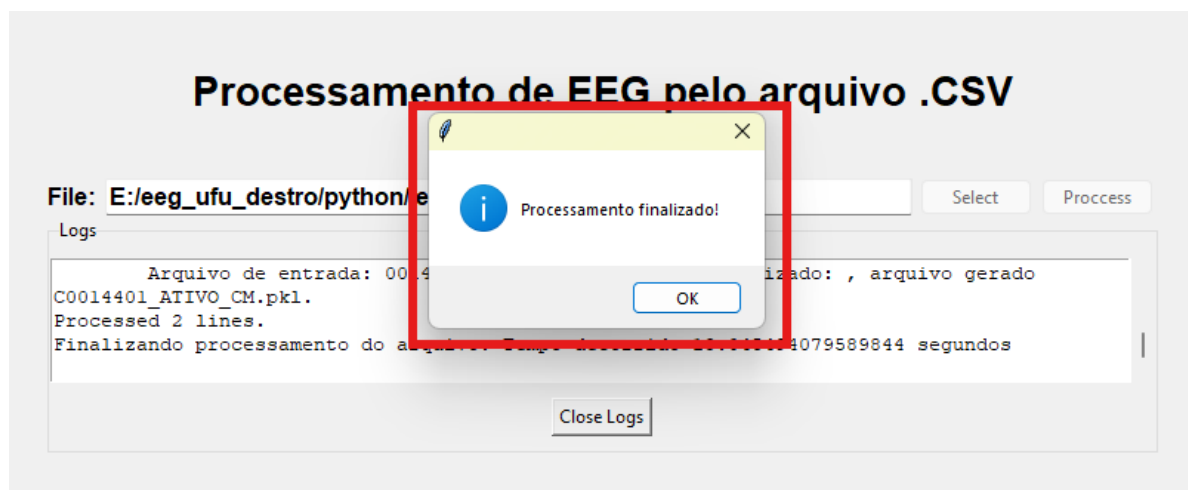


Figura 9 - Tela de sucesso do processamento

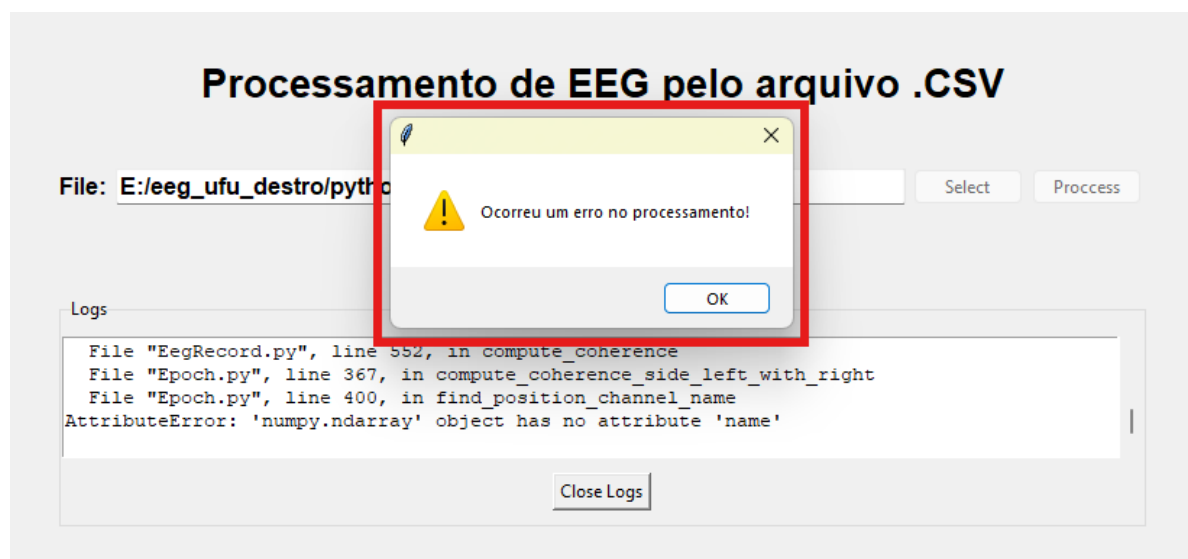


Figura 10 - Tela de falha do processamento

Já o menu "**Topografia**" abre a janela ilustrada na Figura 11, onde o usuário pode inserir os dados em formato de vetor contendo 20 posições. Ao clicar no botão "**Preencher**", os valores correspondentes aos eletrodos localizados no lado esquerdo da tela são automaticamente preenchidos. Em seguida, ao acionar o botão "**Generate**", situado no canto inferior esquerdo, a topografia é gerada e exibida no centro da tela. Caso o usuário deseje customizar ou realçar a imagem, pode selecionar um dos padrões de cores disponíveis no menu "**Colors**", que utiliza esquemas já estabelecidos pela linguagem Python para destacar diferentes efeitos visuais. Por fim, há um *checkbox* no canto inferior direito que permite ativar ou desativar a exibição da escala na topografia.

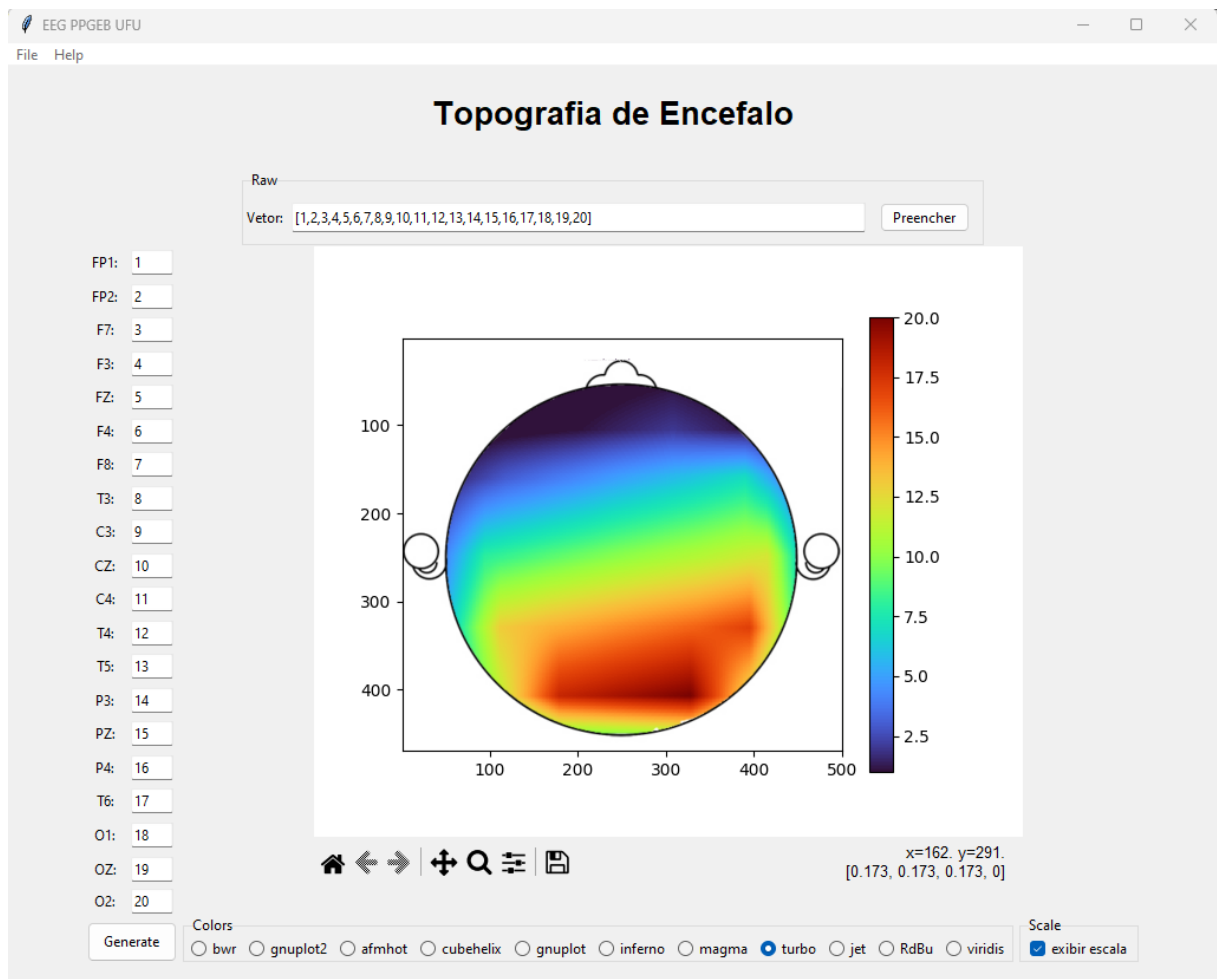


Figura 11 - Tela para geração topográfica

Por fim, o menu "**Change Theme!**" permite ao usuário alternar a interface gráfica para um tema escuro (*dark mode*), conforme ilustrado na Figura 12. O modo escuro reduz a emissão de luz da tela, proporcionando maior conforto visual em ambientes com pouca iluminação e minimizando a fadiga ocular durante o uso

prolongado. Além disso, o tema *dark* traz uma estética mais moderna e sofisticada à interface, aprimorando a experiência do usuário.




Figura 12 - Tela com alteração de tema da interface gráfica

Assim, a interface gráfica representa um diferencial para o *software* de processamento de EEG desenvolvido em Python pelo grupo de pesquisa, uma vez que simplifica a interação do usuário com a ferramenta. Com a interface, torna-se possível adequar o uso do *software* para pesquisadores com diferentes níveis de conhecimento em programação, eliminando barreiras técnicas e proporcionando uma experiência mais intuitiva e eficaz. Essa facilidade de uso contribui não só para ampliar o acesso às análises de EEG, mas também para aumentar a produtividade e a confiabilidade dos resultados obtidos.

3.5 TESTES DE REGRESSÃO PARA COMPARAÇÃO ENTRE O SOFTWARE ORIGINAL E A VERSÃO EM PYTHON

Para realizar os testes de regressão, optou-se pela plataforma computacional, uma vez que a versão do *software* descrita na dissertação de (BARBOSA, 2019) já continha códigos para comparação entre versões, permitindo o reaproveitamento parcial desse material. O teste de regressão empregado consistiu na comparação do comportamento e dos resultados gerados pelo *software* original e pela versão em Python, assegurando que esta última não introduziu falhas em funcionalidades já validadas (BASTOS *et al.*, 2012). Esse tipo de teste é amplamente utilizado no desenvolvimento de *software* para garantir a integridade e consistência dos resultados após alterações no código. Nesse contexto, gerou-se, em Python, um arquivo no formato da plataforma computacional por meio de bibliotecas existentes, que foi posteriormente importado pela plataforma computacional.

Devido a particularidades do arquivo produzido em Python, foram necessárias algumas adaptações antes de executar a rotina de comparação previamente elaborada. Para avaliar os resultados gerados por ambos os *software* (original e em Python), utilizou-se uma função de cálculo do erro relativo, desenvolvida anteriormente e expressa na Equação 6.

$$Err = \left| \frac{V_{calc} - V_{esper}}{V_{esper}} \right| \quad (6)$$

Onde:

- Err - Erro relativo.
- V_{calc} - Valor calculado
- V_{esper} - Valor esperado

As variáveis geradas pelos *software* e comparadas foram: PCP, FM e COR_PairsOfElectrodes, as quais já foram descritas anteriormente.

3.6 RESULTADOS

Esta seção apresenta os resultados obtidos a partir do processamento e da análise dos dados de EEG, com foco na validação do *software* Python em comparação com o *software* original na plataforma computacional. Os experimentos realizados buscaram avaliar a consistência das saídas geradas por ambos os *software*, bem como identificar eventuais discrepâncias decorrentes da transcrição do código. Os detalhes do processamento, incluindo as revisões realizadas e os exames utilizados, são descritos nas subseções a seguir.

3.6.1 Processamento dos PLGs

Durante a transcrição do código, foi conduzida uma revisão tanto teórica quanto prática das rotinas previamente desenvolvidas, o que permitiu identificar um erro no cálculo da função de autocorrelação programada, especificamente no processo de normalização dos resultados.

Para verificar se o *software* transcrito em Python produzia resultados idênticos aos da versão original, foram selecionados 10 exames de EEG, coletados seguindo o padrão 10-20 de montagem dos eletrodos. Esses exames foram processados por ambos os *software* (original e em Python), sendo cinco referentes a indivíduos saudáveis e cinco a pacientes com condições neurológicas.

Para a comparação dos tempos de execução das etapas de processamento do *software*, foi utilizado um notebook *Itautec InfoWay*, modelo W7545, equipado com o sistema operacional Windows 10, processador Intel Core i3-2350M de 2,30 GHz e 8 GB de memória RAM.

A Figura 13 apresenta a comparação dos tempos de processamento para cada etapa. Devido a uma significativa discrepância, as etapas de pré-processamento e processamento foram separadas e detalhadas na Figura 14.




Figura 13 - Tempo de processamento em todas as etapas analisadas.




Figura 14 - Etapa de Pré-Processamento e Processamento dos dados.

O *software* original na plataforma computacional, ao concluir o processamento dos exames e/ou registros, armazena os resultados em um arquivo específico. No *software* em Python, os resultados são salvos em um arquivo com extensão .pkl. A Tabela 2 apresenta uma comparação do tamanho dos arquivos gerados por ambos os *software*.

Tabela 2 - Comparação entre o tamanho dos arquivos gerados pelos processamentos na plataforma computacional e Python

Nome PLG	Plataforma (kBytes)	Python (kBytes)
COMA_1	4.767	22.233
COMA_2	4.644	23.421
COMA_3	3.885	18.920
COMA_4	4.115	20.519
COMA_5	4.589	20.519
NORMAL1	10.398	52.185
NORMAL2	9.330	49.088
NORMAL3	9.886	50.672
NORMAL4	8.958	44.660
NORMAL5	9.945	46.676

Observou-se que o *software* em Python performou mais rapidamente nas etapas de Leitura PLG, PCP, FM e Coerência. Em contrapartida, o *software* original na plataforma computacional demonstrou melhor desempenho nas etapas de Separação de Épocas, pré-processamento e processamento. Verificou-se que, nas fases de Leitura PLG e Separação de Épocas, as duas versões exibiram desempenhos complementares, compensando-se mutuamente.

Contudo, nas etapas de pré-processamento e processamento, o *software* em Python revelou-se quase 60 vezes mais lento que o *software* original. Essa discrepância pode estar associada à forma como os objetos foram criados seguindo o paradigma da programação orientada a objetos, sugerindo a necessidade de uma investigação mais aprofundada para identificar as causas dessa diferença tão expressiva.

Com relação aos arquivos gerados a partir do processamento dos registros e/ou exames, constatou-se que os arquivos produzidos pelo *software* em Python apresentaram um tamanho quase cinco vezes maior que os gerados pelo *software* original na plataforma computacional. Entretanto, é importante destacar que, nesse

tipo de arquivo, ainda é possível aplicar algoritmos de compressão, como gzip, ou utilizar outros formatos, como HDF5, que oferece suporte a compressão nativa e desempenho otimizado para grandes volumes de dados.

3.6.2 Execução dos testes de regressão

A execução dos testes comparativos segue um procedimento semelhante ao do teste de regressão já disponível no *software* anterior, exigindo a criação de um arquivo CSV com duas colunas. A primeira coluna deve conter o nome do arquivo gerado pela versão na plataforma computacional, utilizado como referência. A segunda coluna deve indicar o nome do arquivo produzido pela versão em Python. Na interface de comandos da plataforma computacional, o usuário deve executar a função **testErrorPlatAndPython**, e, em seguida, será exibida a janela apresentada na Figura 15, permitindo a seleção do arquivo CSV pelo usuário.

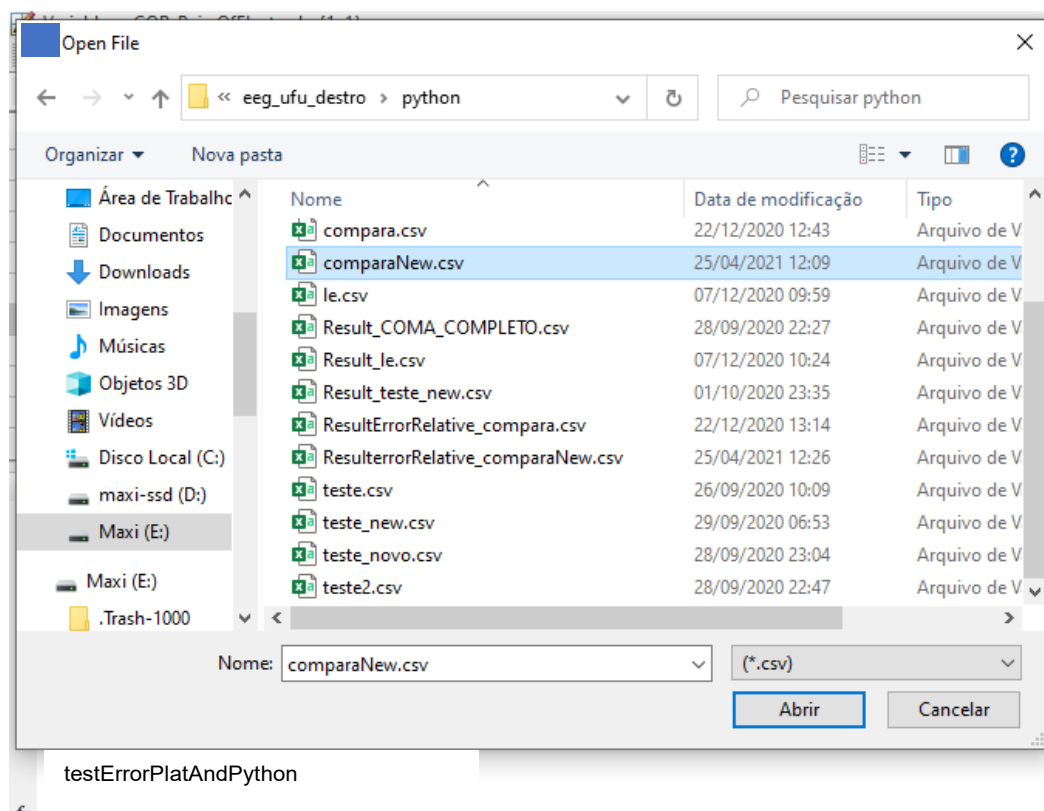
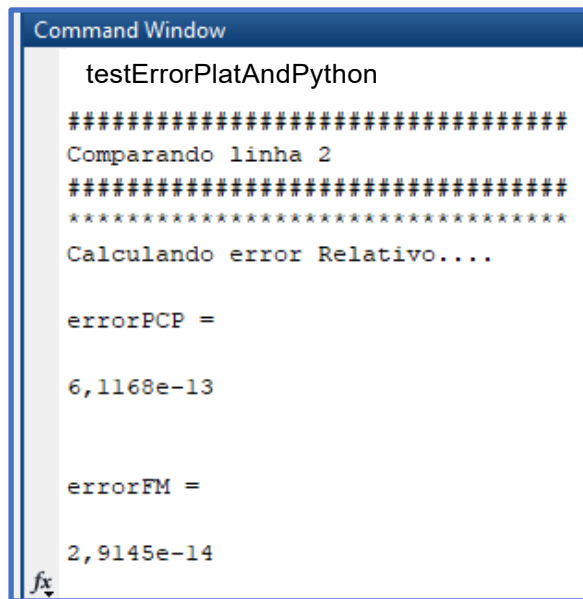


Figura 15 - Seleção do CSV para execução do teste de comparação de versão do *software*

Após a seleção do arquivo CSV, o *software* inicia a comparação das variáveis, calculando o erro relativo para cada linha do arquivo. As variáveis em análise são

exibidas na interface de comandos (Figura 16), permitindo ao usuário acompanhar a execução do programa e identificar em que etapa ele se encontra.



```

Command Window

testErrorPlatAndPython

#####
Comparando linha 2
#####
*****
Calculando error Relativo....

errorPCP =

6,1168e-13

errorFM =

2,9145e-14

```

Figura 16 - Janela de comandos durante a execução do testErrorPlatAndPython

Após a execução da função **testErrorPlatAndPython**, é gerado um arquivo CSV com o prefixo "ResultErrorRelative_" (**APÊNDICE F**), seguido do nome do arquivo CSV de entrada. Esse arquivo contém as mesmas informações do CSV de entrada, acrescidas dos resultados da comparação para cada variável (PCP, FM e Coerência).

A Tabela 3 apresenta os resultados do cálculo do erro relativo para os 10 exames e/ou registros de EEG mencionados anteriormente. Ressalta-se que as variáveis comparadas são multidimensionais, com três dimensões, e o valor de erro exibido na tabela corresponde a um único valor por exame e/ou registro. Esse valor foi obtido por meio da média dos erros calculados em cada matriz multidimensional, sendo o desvio padrão calculado da mesma forma para esses dados.

Tabela 3 - Erro Relativo comparação Plataforma Computacional x Python

Nome PLG	PCP Media ERRO	PCP Desvio Padrão	FM Media ERRO	FM Desvio Padrão	COERENCIA Media ERRO	COERENCIA Desvio padrão
COMA_1	1,24E-15	2,22E-15	2,36E-16	4,75E-16	167,8058	1,51E+04
COMA_2	2,72E-15	5,69E-15	3,16E-16	5,87E-16	13	721
COMA_3	1,68E-15	3,53E-15	2,71E-16	5,68E-16	174,1348	1,63E+04
COMA_4	4,84E-15	6,42E-15	5,18E-16	5,87E-12	Dif. Tamanho	Dif. Tamanho
COMA_5	3,02E-15	4,05E-15	4,61E-16	5,47E-16	Dif. Tamanho	Dif. Tamanho

Nome PLG	PCP Media ERRO	PCP Desvio Padrão	FM Media ERRO	FM Desvio Padrão	COERENCIA Media ERRO	COERENCIA Desvio padrão
NORMAL1	2,83E-14	5,69E-14	1,12E-15	2,31E-15	83,0848	7,08E+03
NORMAL2	3,75E-14	8,54E-14	1,31E-15	2,48E-15	193,514	1,88E+04
NORMAL3	2,07E-14	3,54E-14	7,89E-16	1,03E-15	10,8543	122,7668
NORMAL4	2,47E-14	4,87E-14	9,01E-16	1,53E-15	11,9667	196,962
NORMAL5	2,91E-14	5,73E-14	1,27E-15	2,06E-15	9,7615	178,4611

Ao analisar a Tabela 3, verifica-se que o erro relativo é bastante reduzido, apresentando diferença apenas na décima terceira casa decimal. Contudo, para a variável Coerência, o erro revelou-se significativamente elevado.

Diante da expressiva discrepância observada para a Coerência, constatou-se que os algoritmos utilizados pelas funções *mscohere* da plataforma computacional e *scipy.signal.coherence* do Python são distintos. Para minimizar essa diferença, foi realizado um estudo aprofundado dessas funções, envolvendo engenharia reversa dos processos e depuração dos objetos, a fim de identificar o ponto exato em que os dois algoritmos divergem.

Inicialmente, constatou-se que os parâmetros padrão (*default*) de cada aplicação eram distintos, especialmente no que diz respeito ao número de pontos da transformada de Fourier, ao número de janelas e à técnica de janelamento. No Python, utiliza-se a janela *Hann*, enquanto a plataforma computacional emprega-se a janela *Hamming*. Após a equalização dos parâmetros de entrada, obtiveram-se resultados bastante semelhantes.

Essa semelhança pode ser observada nos histogramas de diferença entre as duas plataformas, gerados para um exame de EEG com cinco épocas. Nesses histogramas, a diferença entre as épocas foi inferior a 0,04%, conforme ilustrado na Figura 17.

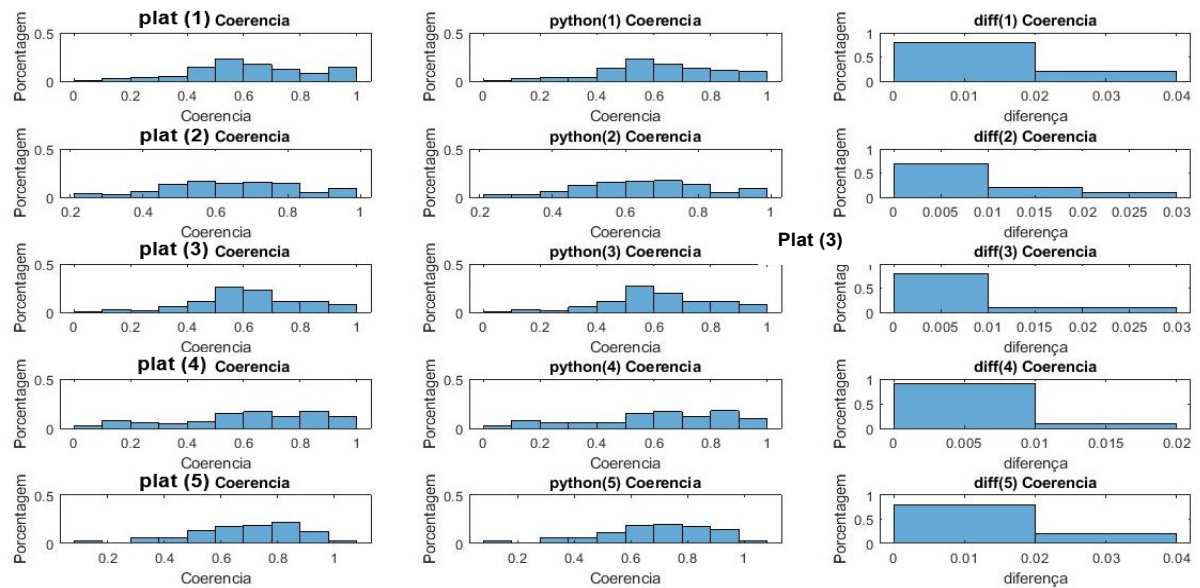


Figura 17 - Histograma diferenças Coerência

Com o objetivo de identificar com maior clareza a distribuição das diferenças, foi plotada a curva dos resultados de coerência para ambas as plataformas em uma única imagem. Essa visualização revelou que a maior divergência ocorre nas frequências iniciais ou finais, conforme exibido na Figura 18.




Figura 18 - Comparação Coerência Python x Plataforma Computacional

Na tentativa de obter resultados ainda mais próximos dos exibidos pela plataforma computacional, foi identificada a biblioteca **matplotlib.mlab.cohere** do Python. Segundo sua documentação (HUNTER *et al.*, 2021), essa função segue os

mesmos procedimentos das implementações da plataforma computacional. Contudo, ao utilizá-la com os mesmos parâmetros de entrada em ambas as plataformas, constatou-se um problema.

Esse problema está relacionado aos parâmetros de entrada. A função em Python restringe o número de pontos da transformada de Fourier (FFT) com base no número de pontos do sinal fornecido como argumento, respeitando o teorema da amostragem de *Nyquist*, segundo o qual o número de pontos da FFT não pode exceder a metade do número de amostras do sinal analisado. Na plataforma computacional, essa validação não é aplicada, o que resulta em divergências entre os cálculos das duas plataformas.

3.7 CONSIDERAÇÕES FINAIS

Diante do exposto, constatou-se que a plataforma computacional se mostrou mais veloz em comparação com a versão em Python. Contudo, é importante destacar que a transcrição para o Python foi realizada de maneira simplificada. Para trabalhos futuros, pretende-se aprofundar o estudo da linguagem e dos recursos disponíveis no Python, a fim de avaliar se é possível alcançar um desempenho semelhante ao observado na plataforma computacional.

É importante destacar que a interface gráfica criada não apenas simplifica o uso do *software*, mas também desempenha um papel crucial na aceleração do aprendizado e na integração de novos pesquisadores ao grupo. Ao eliminar a necessidade de conhecimentos avançados em programação, a interface torna o processo mais acessível e menos intimidante, o que contribui para uma curva de aprendizado mais rápida. Além disso, a usabilidade aprimorada promove maior autonomia e confiança dos usuários, resultando em uma aplicação mais eficaz das ferramentas de processamento de EEG e um avanço mais consistente nas pesquisas desenvolvidas pelo grupo.

O desenvolvimento dos testes unitários e do teste de regressão para comparação entre as duas versões revelou-se extremamente útil. Esses testes auxiliaram na transcrição do código ao identificar erros de implementação,

especialmente por compararem duas plataformas distintas. Assim, pode-se afirmar que a versão em Python apresentou diferenças reduzidas em relação à versão na plataforma computacional.

No entanto, para o cálculo da coerência, ainda não se obteve o resultado esperado com uma taxa de erro suficientemente baixa. O grupo de pesquisa segue investigando abordagens alternativas para comparar a coerência, como a realização da média para cada banda de frequência (Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído) e a subsequente comparação dos resultados entre as duas plataformas.

CAPÍTULO 4 - ANÁLISE DE PADRÕES DE ESTIMULAÇÃO MUSICAL

Este capítulo tem como objetivo apresentar e discutir os mecanismos e as ferramentas empregados na extração e análise de atributos derivados de sinais de eletroencefalograma (EEG), com foco na identificação de padrões relevantes para o escopo desta pesquisa. A análise de padrões em EEG constitui uma etapa fundamental para compreender fenômenos neurofisiológicos, sendo amplamente reconhecida na literatura por sua capacidade de revelar informações sobre estados cognitivos e patológicos (KLIMESCH, 1999). Assim, este capítulo detalha as abordagens técnicas e metodológicas adotadas, estabelecendo uma base sólida para os resultados subsequentes.

4.1 MATERIAIS E MÉTODOS

Este subitem dedica-se a descrever, de maneira concisa e sistemática, os materiais, as tecnologias e as metodologias empregados no desenvolvimento das análises apresentadas neste capítulo. A escolha desses recursos fundamenta-se em sua capacidade de garantir a robustez e a reprodutibilidade dos procedimentos, aspectos essenciais em estudos envolvendo sinais de EEG (PERNET *et al.*, 2020). Aqui, são abordados desde os equipamentos utilizados na aquisição dos dados até as técnicas computacionais aplicadas no processamento e na extração de atributos, proporcionando uma visão integrada do fluxo metodológico adotado.

4.1.1 Métodos Estatísticos, Ferramentas de Análise e Visualização de Dados

4.1.1.1 Média

A média constitui uma das medidas estatísticas fundamentais empregadas para determinar um valor central em um conjunto de dados amostrais. Seu cálculo é obtido pela soma de todos os valores amostrais dividida pelo número total de

elementos considerados, conforme expresso na Equação 7 (MORETTIN; BUSSAB, 2024). Essa medida é amplamente utilizada na análise de sinais de EEG para sumarizar características temporais ou espaciais dos dados, como a amplitude média em uma janela de tempo específica, oferecendo uma representação simplificada de tendências centrais.

$$M = \frac{\sum_{i=1}^N X_i}{N} \quad (7)$$

Onde:

- M - Resultado da média
- X_i - i-ésimo elemento amostral
- N - Quantidade de elementos amostrais

4.1.1.2 Mediana

A mediana é uma medida estatística utilizada para determinar o valor central de um conjunto de dados amostrais, sendo definida como o elemento que ocupa a posição central após a ordenação dos valores em sequência crescente ou decrescente (MORETTIN; BUSSAB, 2024). Quando o número de amostras é par, calcula-se a mediana como a média aritmética dos dois elementos centrais. Essa medida é particularmente útil na análise de sinais de EEG, pois, ao contrário da média, é menos sensível a valores extremos ou ruídos, como os causados por artefatos musculares ou piscadas, oferecendo uma representação robusta das tendências centrais dos dados.

4.1.1.3 Desvio Padrão

O desvio padrão constitui uma medida estatística essencial aplicada a um conjunto de dados amostrais, destinada a quantificar o grau de dispersão dos valores em relação à média (MORETTIN; BUSSAB, 2024). Quanto mais próximo de zero for seu valor, menor é a variabilidade dos dados, indicando maior consistência em torno do valor central. Na análise de sinais de EEG, o desvio padrão é frequentemente utilizado para avaliar a estabilidade de características como a amplitude ou a potência espectral ao longo do tempo, sendo particularmente útil para detectar variações

anormais causadas por ruídos ou eventos neurofisiológicos. Seu cálculo é dado pela Equação 8, apresentada a seguir.

$$DP = \sqrt{\frac{\sum_{i=1}^N (X_i - M)^2}{N}} \quad (8)$$

Onde:

- DP - Desvio Padrão
- X_i - i-ésimo elemento amostral
- N - Quantidade de elementos amostrais
- M - Média do conjunto amostral

4.1.1.4 Teste de Friedman

O teste de Friedman é um método estatístico não paramétrico empregado para comparar diferenças entre grupos em experimentos com blocos randomizados, especialmente quando os dados amostrais são vinculados, isto é, quando cada bloco é submetido a múltiplas avaliações, testes ou condições (CORDER; FOREMAN, 2014).

Diferentemente de testes paramétricos, ele não utiliza os valores numéricos brutos diretamente, mas sim os postos (ou ranks) atribuídos aos dados após sua ordenação dentro de cada bloco separadamente. O teste avalia a hipótese nula de que a soma dos postos é igual entre os grupos, rejeitando-a caso haja diferenças significativas (CORDER; FOREMAN, 2014). Na análise de sinais de EEG, o teste de Friedman é particularmente útil para comparar características extraídas (como potência espectral ou amplitude) em diferentes condições experimentais ou janelas temporais, especialmente quando os dados não atendem aos pressupostos de normalidade.

O teste de Friedman trabalha com duas hipóteses:

- H_0 : as distribuições dos k experimentos são semelhantes;
- H_1 : as distribuições se diferem na localização.

O critério de decisão é rejeitar a hipótese nula (H_0) quando o valor-p for menor que o nível de significância estabelecido (geralmente $\alpha = 0,05$). Assim, um resultado

significativo indica que existe diferença estatisticamente relevante entre os grupos analisados.

4.1.1.5 Variação Percentual (VAP)

A variação percentual (VAP) é uma medida empregada para quantificar a diferença relativa entre duas situações ou condições, utilizando os valores das medianas correspondentes como base para o cálculo. O procedimento consiste em subtrair a mediana da primeira situação da mediana da segunda situação, dividir o resultado pelo maior valor de mediana entre as duas e, posteriormente, multiplicar o quociente por 100 para expressar o resultado em porcentagem.

Na análise de sinais de EEG, a VAP é particularmente útil para comparar variações em características extraídas, como a potência de ritmos cerebrais (ex.: alfa, beta, teta), entre diferentes estados ou períodos experimentais, oferecendo uma métrica quantitativa para avaliar mudanças relativas. Esse cálculo é realizado para cada ritmo, conforme detalhado na Equação 9 (LIMA, 2020), apresentada a seguir.

$$VAP_{situação} = \left| \frac{X - Y}{\text{Max}(X, Y)} \right| \times 100\% \quad (9)$$

Onde:

$VAP_{situação}$	- Variação percentual entre duas situações
X	- Mediana da primeira situação
Y	- Mediana da segunda situação
$\text{Max}(X, Y)$	- Maior valor entre X e Y

4.1.1.6 Histograma

O histograma é uma ferramenta visual que possibilita a representação gráfica da distribuição de frequências de um conjunto de dados amostrais, evidenciando a repetição dos elementos dentro desse conjunto. Essa técnica permite identificar a concentração predominante dos dados, destacando regiões de maior densidade. Comumente, a visualização é realizada por meio de um gráfico de barras, no qual:

- eixo X corresponde aos valores ou intervalos de valores presentes no conjunto amostral;

- eixo Y indica a frequência absoluta, ou seja, o número de ocorrências de cada valor ou intervalo no conjunto.

Na análise de sinais de EEG, o histograma é amplamente empregado para examinar a distribuição de atributos como amplitude ou potência espectral, auxiliando na detecção de padrões ou anomalias, como assimetrias causadas por artefatos ou eventos neurofisiológicos. Um exemplo dessa aplicação pode ser observado na Figura 19, que ilustra um histograma típico, revelando que a maior parte dos dados se concentra entre os valores 0,6 e 0,9.




Figura 19 - Exemplo de histograma

4.1.1.7 Arquivo Excel

O arquivo Excel é um formato de planilha digital gerado pelo *software* Microsoft Excel, desenvolvido e mantido pela Microsoft. Essa ferramenta organiza dados em tabelas estruturadas, compostas por linhas e colunas, possibilitando a realização de cálculos, a manipulação de informações e a apresentação visual de resultados.

Na análise de sinais de EEG, o uso de arquivos Excel é frequente para o armazenamento e o pré-processamento inicial de dados amostrais, como valores de amplitude ou potência espectral extraídos de experimentos, bem como para a aplicação de fórmulas estatísticas básicas, a exemplo da média ou do desvio padrão. Sua versatilidade e acessibilidade o tornam uma escolha comum em etapas preliminares de organização e análise de dados antes da utilização de *software* mais especializados.

4.1.2 Metodologia

Para o desenvolvimento do *software* destinado à geração de insights para o reconhecimento de padrões em sinais de EEG, foi realizada, inicialmente, uma reunião com o grupo de pesquisa com o objetivo de definir a abordagem metodológica a ser adotada no processamento. Nessa reunião, foram estabelecidas as seguintes etapas:

1. Processamento dos exames a serem analisados:
 - Nessa etapa, os exames foram configurados com janelas de tamanho uniforme e igual quantidade de janelas em todos os registros, garantindo consistência na análise temporal dos sinais.
2. Agrupamento dos quantificadores (PCP, FM e Coerência):
 - Os quantificadores gerados na etapa anterior foram consolidados em um único arquivo, facilitando o armazenamento e o acesso aos dados processados.
3. Geração de arquivo Excel com atributos:
 - Um arquivo Excel foi criado para registrar os seguintes atributos extraídos dos quantificadores vinculados a todos os exames: média, mediana, desvio padrão, teste de Friedman e variação percentual (VAP), permitindo uma análise estatística abrangente.
4. Visualização dos resultados:
 - Os resultados foram representados graficamente por meio de histogramas, possibilitando a identificação visual da distribuição dos atributos.
5. Identificação de padrões:
 - Foram analisados os atributos extraídos para detectar padrões relevantes nos sinais de EEG, constituindo o objetivo final do processamento.

Para executar essas etapas, inicialmente elaborou-se um arquivo CSV contendo os exames a serem avaliados, conforme especificado no item 1. Esse arquivo foi então processado no *software* de análise de EEG descrito em (BARBOSA, 2019) para a extração dos quantificadores PCP, FM e Coerência.

Em seguida, utilizando a plataforma computacional, foram desenvolvidas funções específicas para realizar as demais etapas descritas. Adicionalmente, o cálculo da variação percentual (VAP) foi implementado tanto no Excel quanto em uma função programada na plataforma computacional, com o propósito de validar a precisão da função desenvolvida por meio da comparação entre os resultados obtidos nas duas plataformas.

4.2 VERSIONAMENTO

Para o controle de versionamento do *software* desenvolvido, adotou-se a mesma estrutura de versionamento empregada pelos *software* na plataforma computacional e Python. As novas funções criadas foram organizadas e armazenadas na raiz do projeto, garantindo compatibilidade e facilidade de acesso durante o desenvolvimento e a manutenção do sistema. Essa abordagem permite gerenciar eficientemente as versões das funções implementadas para o processamento e análise de sinais de EEG, assegurando a rastreabilidade e a integração das atualizações ao longo do projeto.

4.3 FUNÇÕES IMPLEMENTADAS

Para alcançar os objetivos estabelecidos na metodologia apresentada no item 4.1.2, foram desenvolvidas funções específicas que atendem às etapas definidas para o processamento e análise de sinais de EEG. Essas funções, descritas a seguir, foram implementadas com o propósito de automatizar a extração de quantificadores, o cálculo de atributos estatísticos e a geração de visualizações, contribuindo para a identificação de padrões nos dados amostrais.

4.3.1 Função `groupPcpAndFmAndCoerencia`

A função `groupPcpAndFmAndCoerencia` foi desenvolvida para processar arquivos com os dados localizados em um diretório específico, utilizando um prefixo de nome de arquivo como critério de identificação. Essa função realiza a leitura de

todos os arquivos correspondentes, extraindo as variáveis PCP, FM e COERENCIA contidas em cada arquivo.

Em seguida, esses quantificadores foram organizados em variáveis distintas, uma para cada tipo (PCP, FM e COERENCIA), agrupando os dados de todos os exames de EEG coletados sob um mesmo estímulo. Esse processo facilita a consolidação dos quantificadores em um formato estruturado, permitindo sua posterior análise conjunta para identificação de padrões nos sinais de EEG.

4.3.2 Função **generateMedianMeanStdGrouped**

Essa função foi desenvolvida para calcular a média, a mediana e o desvio padrão de um conjunto de dados amostrais. Essa função geralmente utiliza como entrada um dos quantificadores agrupados pela função **groupPcpAndFmAndCoerencia** (como PCP, FM ou COERENCIA), processando os dados consolidados de exames de EEG. Os resultados gerados — valores de média, mediana e desvio padrão — são posteriormente empregados no cálculo da variação percentual (VAP).

Essa etapa é essencial para a análise estatística dos quantificadores, fornecendo medidas fundamentais para a caracterização e comparação dos sinais de EEG.

4.3.3 Função **computePercentVariation**

Função responsável em calcular a variação percentual (VAP) entre os valores contidos em células de matrizes fornecidas como argumentos. Essa função processa os dados provenientes das análises de sinais de EEG, utilizando as medianas extraídas de diferentes condições ou períodos experimentais.

O cálculo da VAP é realizado comparando pares de valores em cada matriz, gerando uma métrica que quantifica as diferenças relativas entre os quantificadores agrupados, como PCP, FM ou COERENCIA. Essa funcionalidade é essencial para avaliar mudanças nos padrões dos sinais de EEG, contribuindo para a análise estatística e a identificação de variações significativas no conjunto de dados amostrais.

4.3.4 Função `computeTestPValue`

A função `computeTestPValue` foi desenvolvida para executar o teste de Friedman, calculando o valor-p associado às diferenças entre os valores contidos em células de matrizes fornecidas como argumentos. Essa função processa os quantificadores extraídos dos sinais de EEG, como PCP, FM ou COERENCIA, organizados em matrizes provenientes de diferentes condições ou blocos experimentais.

O teste de Friedman é aplicado para avaliar se há diferenças significativas entre os grupos de dados, gerando um valor-p que indica a probabilidade de aceitação da hipótese nula de igualdade entre os quantificadores. Contribuindo para a identificação de padrões e variações relevantes nos sinais analisados.

4.3.5 Função `histogramPercentVariationByMaxValueInTestPValue`

Essa função realiza análise estatística comparativa entre duas matrizes de dados através de duas etapas principais:

1. Teste de Friedman para verificação de diferenças significativas entre grupos;
2. Cálculo da Variação Percentual (VAP) entre pares de valores correspondentes.

A rotina inicia com a aplicação do teste de Friedman, que avalia a hipótese nula de igualdade distribucional entre os conjuntos de dados (nível de significância definido por $p < X_{input}$). Os resultados que ultrapassam este limiar são marcados como estatisticamente relevantes.

Posteriormente, calcula-se a VAP entre cada par de elementos homólogos das matrizes. A associação estratégica entre ambas análises ocorre através da filtragem seletiva: somente as variações percentuais correspondentes às posições com significância estatística no teste de Friedman são consideradas. Essa abordagem dual permite:

- Reduzir falsos positivos por acaso estatístico;
- Identificar mudanças biologicamente relevantes em sinais EEG;
- Priorizar alterações consistentes nos quantificadores (PCP, FM, COERENCIA).

A etapa final gera um histograma das VAPs significativas, possibilitando a visualização da distribuição das variações percentuais significativas.

4.3.6 Função `createXlsxByStimulus`

Esta função gera uma planilha no formato Excel (.xlsx) contendo seis tabelas comparativas para um quantificador pré-definido (PCP, FM, ou Coerência). Cada tabela contrasta um dos seis estímulos experimentais com um sétimo estímulo de referência – este último dá nome à folha (ou *sheet*) criada. A estrutura de saída organiza-se da seguinte forma:

1. Entrada:

- Um quantificador de EEG (variável numérica);
- Nome do estímulo de referência (*string*).

2. Processamento:

- Criação automática de seis pares comparativos (estímulo experimental vs. referência);
- Cálculo de métricas de comparação para cada par.

3. Saída:

- Planilha única com abas nomeadas segundo o estímulo de referência;
- Layout padronizado para análise transversal (ver **APÊNDICE F**, **APÊNDICE G** e **APÊNDICE H**).

4.3.7 Função `generateFileByStimulus`

Esta função é responsável pela geração de três arquivos no formato Excel (.xlsx), cada um contendo resultados relacionados às comparações entre os estímulos fornecidos como argumento para um único quantificador (PCP, FM ou COERÊNCIA). Os arquivos gerados correspondem às seguintes análises:

- **Teste de Friedman:** Este arquivo apresenta os resultados do teste estatístico de Friedman, que avalia a significância das diferenças entre os estímulos para o quantificador analisado. O sufixo "_p_value" é adicionado ao nome do arquivo para indicar que ele contém valores de significância (p-values);

- **Variação Percentual (VAP):** Este arquivo contém os cálculos da variação percentual entre os estímulos, permitindo a análise das mudanças relativas nos valores do quantificador. O sufixo "_percent_variation" identifica este arquivo;
- **VAP com Teste de Friedman Significativo:** Este arquivo combina os resultados das duas análises anteriores, filtrando as variações percentuais que correspondem às posições em que o teste de Friedman apresentou significância estatística. O sufixo "_final" é utilizado para nomear este arquivo.

Cada planilha gerada possui sete abas (folhas ou *sheets*), onde cada aba corresponde ao resultado da função **createXlsxByStimulus** aplicada a um dos sete estímulos experimentais – sendo o sétimo estímulo considerado como referência para as comparações realizadas. Exemplos dessas planilhas podem ser encontrados nos **APÊNDICE F, APÊNDICE G e APÊNDICE H**.

4.4 BASE DE DADOS

Os dados utilizados nesta pesquisa foram reaproveitados do trabalho de (RAMOS, 2018), conduzido entre os anos de 2017 e 2018, antes da pandemia de COVID-19. Esse estudo foi realizado no âmbito do Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia (UFU), com foco na estimulação musical e atenuação de ruídos em sinais de EEG coletados na Unidade de Terapia Intensiva (UTI) do Hospital de Clínicas da UFU (HCU-UFU) (RAMOS, 2018).

A coleta dos dados seguiu rigorosos protocolos éticos, sendo previamente autorizada pelo Comitê de Ética em Pesquisa da UFU (CEP-UFU) (parecer consubstanciado CEP número: 1.715.960 (**ANEXO C**)). Para garantir o cumprimento das normas éticas aplicáveis a pesquisas envolvendo seres humanos, foi elaborado um Termo de Consentimento Livre e Esclarecido (TCLE), que detalhava os procedimentos da pesquisa, as responsabilidades dos pesquisadores e voluntários, além de outros documentos necessários para autorização do uso dos equipamentos e instalações do HCU-UFU, do Laboratório de Processamento Digital de Sinais (PDS) e do Laboratório de Engenharia Biomédica (BioLab) da Faculdade de Engenharia

Elétrica da UFU (FEELT-UFU). Esses documentos foram avaliados e aprovados pelo CEP-UFU.

O trabalho original utilizou métodos avançados para análise de sinais eletroencefalográficos, incluindo técnicas de processamento digital e análise quantitativa, com o objetivo de explorar padrões cerebrais em resposta à estimulação musical. Os dados coletados foram fundamentais para a construção da base utilizada nesta pesquisa, permitindo a continuidade dos estudos sobre reconhecimento de padrões em EEG.

O protocolo para a coleta dos exames de EEG foi desenvolvido pelo grupo de pesquisa liderado pelo professor Doutor João Batista Destro Filho e estruturado em quatro fases principais: pré-estímulo, estímulo, pós-estímulo e gravação a vazio (RAMOS, 2018). Essas fases serão detalhadas posteriormente na tese, destacando sua importância para o registro sistemático das respostas cerebrais aos estímulos aplicados.

As coletas foram realizadas utilizando o amplificador de sinais biológicos *BrainNet* BNT-EEG, juntamente com seu *software* proprietário de aquisição, o “EEGCaptações32”, versão REDE36 (1.0). Este equipamento conta com 21 canais, dos quais 20 são dedicados à aquisição digital dos sinais de EEG e um canal adicional é reservado para o registro de eletrocardiograma (ECG) (RAMOS, 2018).

Na utilização do *software* de registro mencionado anteriormente, foram realizadas as seguintes configurações para ajuste dos filtros e da frequência de aquisição, conforme descrito por (RAMOS, 2018):

- Para canais de EEG:
 - **Constante de Tempo ou Filtro Passa Alta:** 0,16 s – 1,0 Hz;
 - **Filtro de Alta Frequência ou Filtro Passa Baixa:** 100 Hz;
 - **Filtro NOTCH:** ativado para eliminação da frequência de 60 Hz.
- Para canais de ECG:
 - **Constante de Tempo:** 0,16 s – 1,0 Hz;
 - **Filtro Passa Baixa:** 70 Hz;
 - **Filtro NOTCH:** ativado.
- **Frequência de Amostragem:** 400 Hz.

Para a montagem dos eletrodos, foram conectados um total de 25 eletrodos ao paciente e ao aparelho de coleta, seguindo o padrão universal de montagem 10-20. Dos 25 eletrodos utilizados, 23 foram dedicados à coleta do EEG e dois ao ECG. Entre os eletrodos do EEG, dois funcionaram como referenciais (bi-auriculares), um como terra e os demais foram responsáveis pela aquisição dos sinais cerebrais (RAMOS, 2018).

4.4.1 Fases da coleta dos estímulos

Neste tópico, são apresentadas as fases principais da coleta dos estímulos, que foram detalhadamente descritas em (RAMOS, 2018). Essas fases são fundamentais para a estruturação do protocolo experimental, garantindo a consistência e a validade dos dados coletados. A seguir, será fornecida uma visão geral dessas etapas, que incluem a pré-estimulação, o estímulo propriamente dito, a pós-estimulação e a gravação a vazio.

4.4.1.1 Pré-estímulo

Esta fase consiste na gravação de três minutos de atividade cerebral com os olhos fechados, sem qualquer estimulação externa, como movimentação, fala ou outras atividades que possam interferir no sinal gravado. O objetivo é capturar um padrão basal de atividade cerebral em condições de repouso, permitindo uma referência para as fases subsequentes. Durante essa etapa, o paciente deve permanecer imóvel e relaxado, minimizando qualquer artefato que possa afetar a qualidade do registro.

4.4.1.2 Estímulo musical

Nesta etapa, realiza-se a gravação de 60 segundos de atividade cerebral em repouso, sob silêncio ambiental e com olhos fechados, durante a exposição a estímulos sonoros controlados. O protocolo incluiu seis estímulos auditivos distintos, selecionados para investigar respostas neurofisiológicas a diferentes perfis acústicos e emocionais:

- **Música favorita:** Seleccionada individualmente pelo voluntário para induzir valência emocional positiva;
- **Música desgostada:** Escolhida pelo participante para eliciar reações de aversão ou desconforto;
- **Ruído branco:** Estímulo acústico de espectro plano, utilizado como controle neutro;
- **Ruído rosa:** Caracterizado por maior energia em baixas frequências, contrastando com o ruído branco;
- **Tom puro dó:** Frequência específica para análise de respostas a tons puros;
- **Tom puro em ritmo baião (sol):** Padrão rítmico culturalmente relevante (baião).

Os estímulos foram aplicados sequencialmente, com cada um durando 60 segundos, seguido imediatamente por uma fase de pós-estímulo. Para evitar interferências acústicas, foi mantido um período de silêncio entre os estímulos. Essa estrutura experimental visa minimizar efeitos de habituação e garantir a integridade dos dados coletados (MAGALHÃES *et al.*, 2021).

A escolha de músicas com valência emocional oposta (favorita e desgostada) alinha-se com estudos que demonstram padrões assimétricos de ativação frontal no EEG durante estímulos emocionais (TANDLE *et al.*, 2018). Esses padrões são consistentes com a hipótese de que a ativação frontal lateralizada pode refletir processos emocionais e cognitivos associados à experiência musical. A literatura sugere que a música favorita tende a induzir maior atividade no hemisfério esquerdo, enquanto a música desgostada pode ativar mais o hemisfério direito, refletindo assimetrias emocionais (MAGALHÃES *et al.*, 2021).

4.4.1.3 Pós-estímulo

Esta fase consiste na gravação de 30 segundos de atividade cerebral em repouso, sob silêncio ambiental e com olhos fechados. Ela é realizada imediatamente após cada um dos estímulos sonoros descritos anteriormente, visando capturar as respostas cerebrais residuais ou de recuperação após a exposição ao estímulo. A duração de 30 segundos permite avaliar a estabilização da atividade neural pós-

estímulo, fornecendo uma referência para comparar com as fases pré e durante o estímulo.

4.4.1.4 Gravação à Vazio

Nesta etapa, ocorre a gravação de 60 segundos com os eletrodos desconectados do aparelho de coleta, visando registrar os sinais estáticos (ruído instrumental e ambiental) na ausência de qualquer sinal fisiológico. O objetivo é estabelecer uma linha de base para a quantificação do ruído intrínseco do sistema de aquisição, permitindo:

- Identificação de artefatos técnicos:
 - Caracterização do ruído de fundo do amplificador (*input-referred noise*);
 - Detecção de interferências eletromagnéticas residuais.
- Calibração instrumental:
 - Validação da impedância dos eletrodos em circuito aberto;
 - Verificação da estabilidade térmica do sistema.

4.4.1.5 Considerações Finais

O procedimento de coleta do EEG, conforme descrito por (RAMOS, 2018), teve a sequência de estimulação descrita na Tabela 4.

Tabela 4 – Sequência de estímulos aplicado na coleta da base de dados de estimulação musical

Estímulo	Tempo (minutos)
Pré	3
Música favorita	1
Pós	0,5
Ruído rosa	1
Pós	0,5
Dó	1
Pós	0,5
Música desgostada	1
Pós	0,5
Ruído branco	1

Estímulo	Tempo (minutos)
Pós	0,5
Sol Baião	1
Pós	0,5
Vazio	1
Total	13

Este procedimento foi aplicado a 60 voluntários, constituindo a base de dados utilizada para o reconhecimento de padrões em sinais de EEG.

4.5 ESTRUTURAÇÃO E PROCESSAMENTO DOS DADOS

De acordo com as informações de cada exame coletado para a base de dados, montou-se o arquivo .CSV utilizado como entrada para o *software* de processamento de EEG desenvolvido pelo grupo de pesquisa descrito anteriormente, onde pegou-se o instante inicial de cada estímulo musical conforme descrito em (RAMOS, 2018) no qual esse instante foi considerado como o tempo inicial das épocas.

Assim, a planilha/CSV de entrada constou de sete linhas por exame/EEG, no qual, cada linha se refere a um estímulo sonoro, com janela de época de duração de dois segundos com um total de trinta épocas sequencias a partir do tempo de início da estimulação, totalizando assim os 60 segundos da estimulação musical. Configurou-se esta planilha também para que o *software* calcula-se os seguintes quantificadores: PCP, FM e COERENCIA. Desta forma, o arquivo CSV ficou configurada com 420 linhas (60 EEG x 7 estímulos).

O processamento quantitativo dos exames de EEG foi estruturado em um arquivo CSV, configurado conforme o protocolo experimental descrito em (RAMOS, 2018). Este arquivo serve como entrada para o *software* de processamento desenvolvido pelo grupo de pesquisa. A configuração inclui:

- **Organização temporal:** Identificação do instante inicial de cada estímulo musical, com janelas de 2 segundos por época, totalizando 30 épocas sequenciais por estímulo, cobrindo os 60 segundos de duração total do estímulo.

- **Estrutura de dados:** 7 linhas por exame/EEG, correspondentes aos 7 estímulos sonoros, resultando em 420 linhas no total (60 exames × 7 estímulos).
- **Variáveis calculadas:** Os quantificadores PCP, FM e COERÊNCIA foram calculados para cada época, visando analisar a potência do sinal nos eletrodos, a frequência mediana e a correlação entre o hemisfério esquerdo e direito.

Para otimizar o agrupamento posterior dos estímulos musicais provenientes dos diversos exames de EEG, foi estabelecido um padrão de nomenclatura para os arquivos de saída gerados pelo processamento de cada linha do arquivo CSV. Esse padrão consiste em um prefixo específico, que identifica o tipo de estímulo sonoro, seguido do identificador do participante (PLG) registrado durante a coleta dos dados.

Os prefixos adotados foram: PRE_, MUSIC_FAVOR_, DO_CONT_, RUIDO_ROSA_, MUSIC_DESGOST_, RUIDO_BRANCO_ e SOL_BAIAO_, cada um correspondendo a um dos sete estímulos analisados. Por exemplo, o arquivo RUIDO_BRANCO_V2801 representa o processamento do estímulo "ruído branco" para o participante identificado como V2801. Essa convenção de nomenclatura facilita a organização e a rastreabilidade dos quantificadores extraídos para cada estímulo e paciente.

Prosseguindo com o desenvolvimento, foram aproveitadas as funções programadas descritas no item 4.3 para processar os dados gerados. Especificamente, a função groupPcpAndFmAndCoerencia foi empregada para agrupar os quantificadores calculados no processamento dos sinais de EEG (PCP, FM e COERENCIA) organizando-os por tipo de estímulo sonoro. Para isso, executou-se essa função sete vezes, uma para cada um dos sete estímulos definidos no arquivo CSV (conforme item 4.4.1), consolidando os dados de todos os exames de EEG correspondentes a cada estímulo em variáveis distintas. A título de detalhamento, as dimensões das variáveis geradas por esse processo são apresentadas a seguir:

- **PCP (7 x 1800 x 20)**
 - 7 células, representando as bandas de frequência: Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído;
 - 1800 linhas, correspondendo às 30 épocas de cada um dos 60 exames de EEG (60 EEGs x 30 épocas);

- 20 colunas, referentes aos eletrodos utilizados: FP1, FP2, F7, F3, FZ, F4, F8, T3, C3, CZ, C4, T4, T5, P3, PZ, P4, T6, O1, OZ, O2.
- **FM (7 x 1800 x 20)**
 - Possui estrutura idêntica à de PCP, uma vez que ambas as variáveis foram calculadas a partir da mesma configuração de dados, abrangendo as mesmas bandas de frequência, épocas e eletrodos.
- **COERENCIA (8 x 1740 x 129)**
 - 8 células, representando os pares de eletrodos analisados: FP1-FP2, F7-F8, F3-F4, T3-T4, C3-C4, T5-T6, P3-P4 e O1-O2;
 - 1740 linhas, referentes as 30 épocas de cada um dos 58 exames de EEG (58 EEGs x 30 épocas), sendo necessária a exclusão de dois exames devido a divergências na frequência de amostragem que afetaram os resultados da função de coerência, comprometendo a consistência dos dados; essa exclusão foi realizada para assegurar a homogeneidade do conjunto analisado e evitar distorções na análise subsequente;
 - 129 colunas, correspondendo às frequências geradas pela função de coerência aplicadas aos pares de eletrodos.

Em seguida, utilizou-se a função `generateMedianMeanStdGrouped` para calcular a mediana, média e desvio padrão das variáveis geradas anteriormente. Esses cálculos foram fundamentais para obter um panorama geral da distribuição dos dados no grupo de estímulos sonoros. A análise dessas medidas de tendência central e dispersão permitiu uma melhor compreensão da variabilidade e consistência dos resultados, facilitando a identificação de padrões nas respostas cerebrais aos diferentes estímulos.

Continuando o processamento, foi executada a função `histogramPercentVariationByMaxValueInTestPValue`, que realiza o cálculo do teste de Friedman para identificar diferenças significativas entre um estímulo sonoro específico e outro. Essa função gera uma matriz de 20 linhas, correspondendo aos canais de EEG (FP1, FP2, F7, F3, FZ, F4, F8, T3, C3, CZ, C4, T4, T5, P3, PZ, P4, T6, O1, OZ e O2), e 7 colunas, representando as bandas de frequência (Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído). Cada elemento dessa matriz contém o valor-p resultante do teste de Friedman, obtido ao comparar os 1800 valores de cada

quantificador (30 épocas × 60 EEGs) entre os estímulos analisados, adotando-se um nível de significância de 0,05.

Em seguida, aplicando a mesma lógica de comparação, calculou-se a variação percentual (VAP) entre os 1800 valores de cada par de estímulos. Posteriormente, com base no valor de significância do teste de Friedman, foram zerados todos os elementos da matriz de VAP cujas posições correspondentes na matriz do teste apresentassem valor-p superior a 0,05, preservando apenas as variações estatisticamente significativas. Por fim, um histograma foi gerado a partir dos valores de VAP remanescentes (elementos diferentes de zero na matriz), possibilitando a visualização da distribuição das variações relevantes.

Para concluir essa etapa e facilitar análises futuras, executou-se a função `generateFileByStimulus`, que produz três arquivos Excel contendo os resultados de cada fase do processamento realizado por `histogramPercentVariationByMaxValueInTestPValue`: o teste de Friedman (sufixo `p_value`), a variação percentual (sufixo `percent_variation`) e os valores de VAP filtrados pelo teste estatístico (sufixo final). Diferentemente da função anterior, que compara apenas um estímulo com outro, esses arquivos apresentam uma visão mais abrangente, exibindo as comparações de cada estímulo sonoro em relação a todos os demais. Essas funções foram aplicadas exclusivamente aos quantificadores FM e PCP, e os resultados obtidos são detalhados no próximo tópico.

4.6 RESULTADOS

Esta seção tem como objetivo apresentar os resultados quantitativos obtidos após a execução das funções computacionais desenvolvidas para o reconhecimento de padrões em sinais de eletroencefalograma (EEG). Esses resultados refletem o desempenho das análises estatísticas e visuais implementadas ao longo do processamento dos dados, que buscaram caracterizar as respostas neurais a diferentes estímulos sonoros.

Através da aplicação das ferramentas descritas nos itens anteriores, como o cálculo de quantificadores (PCP, FM e COERENCIA), testes estatísticos e geração de histogramas, foi possível extrair informações relevantes sobre a variabilidade e as

tendências dos sinais, contribuindo para a identificação de padrões associados aos sete estímulos analisados. Os dados aqui apresentados são organizados por quantificador e fundamentam as discussões subsequentes sobre as implicações neurofisiológicas dos estímulos sonoros no contexto deste estudo.

4.6.1 Quantificador Frequência Mediana (FM)

O quantificador Frequência Mediana (FM) foi analisado para avaliar as variações nas respostas neurais captadas pelos sinais de EEG frente aos sete estímulos sonoros investigados neste estudo. Esse quantificador, que representa a frequência central das bandas analisadas (Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído), foi processado por meio das funções computacionais descritas no item 4.3, resultando na extração de 1800 valores por estímulo (30 épocas × 60 EEGs) para cada um dos 20 canais.

A partir desses dados, calculou-se a variação percentual (VAP) entre os estímulos, seguida da aplicação do teste de Friedman para identificar diferenças estatisticamente significativas (valor- $p \leq 0,05$). Os valores de VAP filtrados, que indicam as variações relevantes após a exclusão dos elementos não significativos (VAP = 0), foram organizados no arquivo Excel com o sufixo final, servindo como base para a geração de histogramas que ilustram a distribuição dessas diferenças.

A Figura 20 e Figura 21 apresentam os histogramas (sete no total) gerados a partir desse arquivo Excel, conforme detalhado no item **4.5 Estruturação e Processamento dos Dados**, para os valores de VAP do quantificador Frequência Mediana (FM) após a seleção estatística significativa. Na construção desses histogramas, foram excluídos os elementos com valor zero, ou seja, aqueles que não exibiram diferenças estatisticamente relevantes com base no teste de Friedman, destacando apenas as variações significativas entre os estímulos sonoros.

Cada histograma corresponde a uma folha (*sheet*) do arquivo Excel, nomeada de acordo com o estímulo sonoro específico comparado, contendo seis tabelas comparativas que detalham as diferenças do FM em relação aos demais estímulos. Essas tabelas são estruturadas em 20 linhas, representando os canais de EEG (FP1, FP2, F7, F3, FZ, F4, F8, T3, C3, CZ, C4, T4, T5, P3, PZ, P4, T6, O1, OZ e O2), e 7 colunas, correspondendo às bandas de frequência, conforme exemplificado no

APÊNDICE H. Essa visualização permite uma análise detalhada das alterações na frequência mediana (FM) induzidas por cada estímulo em diferentes regiões do cérebro.

Diante dos resultados apresentados, os histogramas podem conter até 840 (20 canais x 7 bandas x 6 estímulos) elementos, organizados em quatro intervalos de valores de VAP no eixo X: 0 a 5%, 5 a 10%, 10 a 15% e 15 a 20%. Esses intervalos agrupam as variações percentuais significativas do quantificador FM, enquanto o eixo Y representa a frequência relativa de elementos em cada intervalo, calculada como a quantidade de elementos dentro do grupo dividida pelo total de elementos significativos. Essa representação permite visualizar a distribuição das variações do FM entre os estímulos sonoros, destacando a magnitude e a proporção das diferenças estatisticamente relevantes nos sinais de EEG.



Figura 20 - Histograma VAP da FM Silêncio após seleção estatística

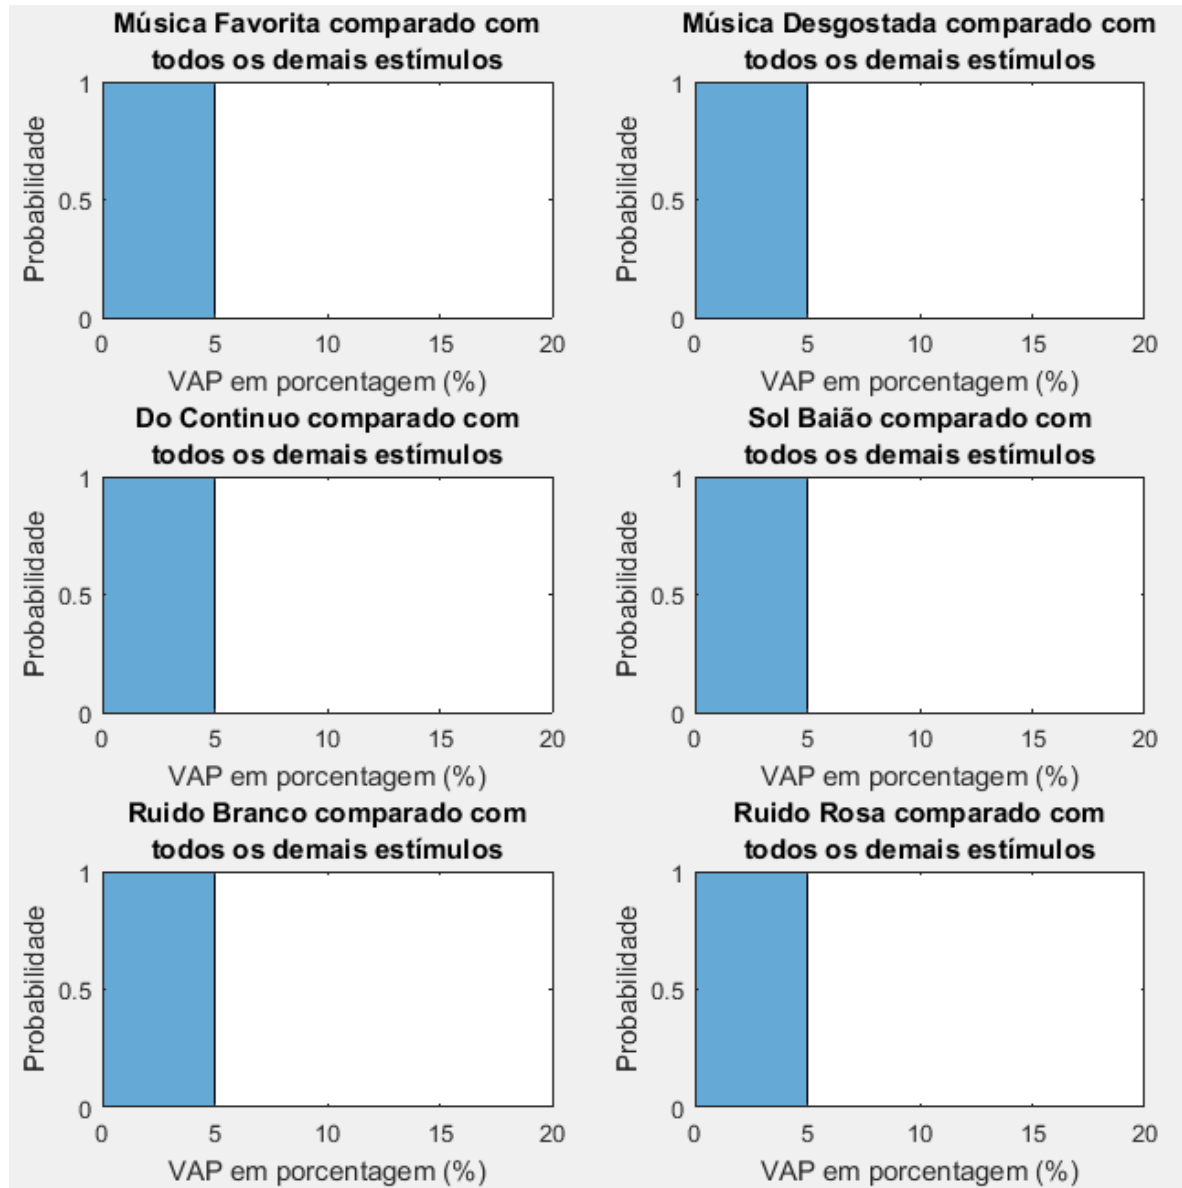


Figura 21 - Histograma VAP do FM demais estímulos após seleção estatística

Conforme observado nos histogramas da Figura 20 e Figura 21, 100% dos valores de VAP concentraram-se no intervalo de 0 a 5%, indicando que as variações do quantificador Frequência Mediana (FM) entre os estímulos sonoros foram mínimas. Esse resultado sugere que a metodologia empregada, apesar de identificar diferenças estatisticamente significativas ($\text{valor-}p \leq 0,05$), não foi eficaz em evidenciar distinções expressivas entre os estímulos no que diz respeito à frequência mediana dos sinais de EEG. Tal concentração em um intervalo de baixa variação pode refletir uma limitação na sensibilidade do quantificador FM para captar alterações neurofisiológicas induzidas pelos estímulos sonoros analisados neste estudo.

4.6.2 Quantificador Porcentagem de Contribuição de Potência (PCP)

O quantificador Porcentagem de Contribuição de Potência (PCP) foi analisado para complementar a avaliação das respostas neurais aos estímulos sonoros nos sinais de EEG.

A Figura 22 e Figura 23 apresentam os histogramas gerados a partir do arquivo Excel com o sufixo final para o quantificador PCP, de maneira análoga ao descrito no item **4.6.1 Quantificador Frequência Mediana (FM)**. Esses histogramas ilustram a distribuição dos valores de variação percentual (VAP) do PCP após a seleção estatística significativa, com base nas comparações entre os sete estímulos sonoros. A única diferença em relação ao FM reside na configuração do eixo X, que para o PCP é dividido em dez intervalos de 5 unidades, abrangendo valores de 0 a 50% (0-5, 5-10, 10-15, 15-20, 20-25, 25-30, 30-35, 35-40, 40-45 e 45-50), refletindo uma maior amplitude nas variações observadas.




Figura 22 - Histograma VAP do PCP Silêncio após seleção estatística

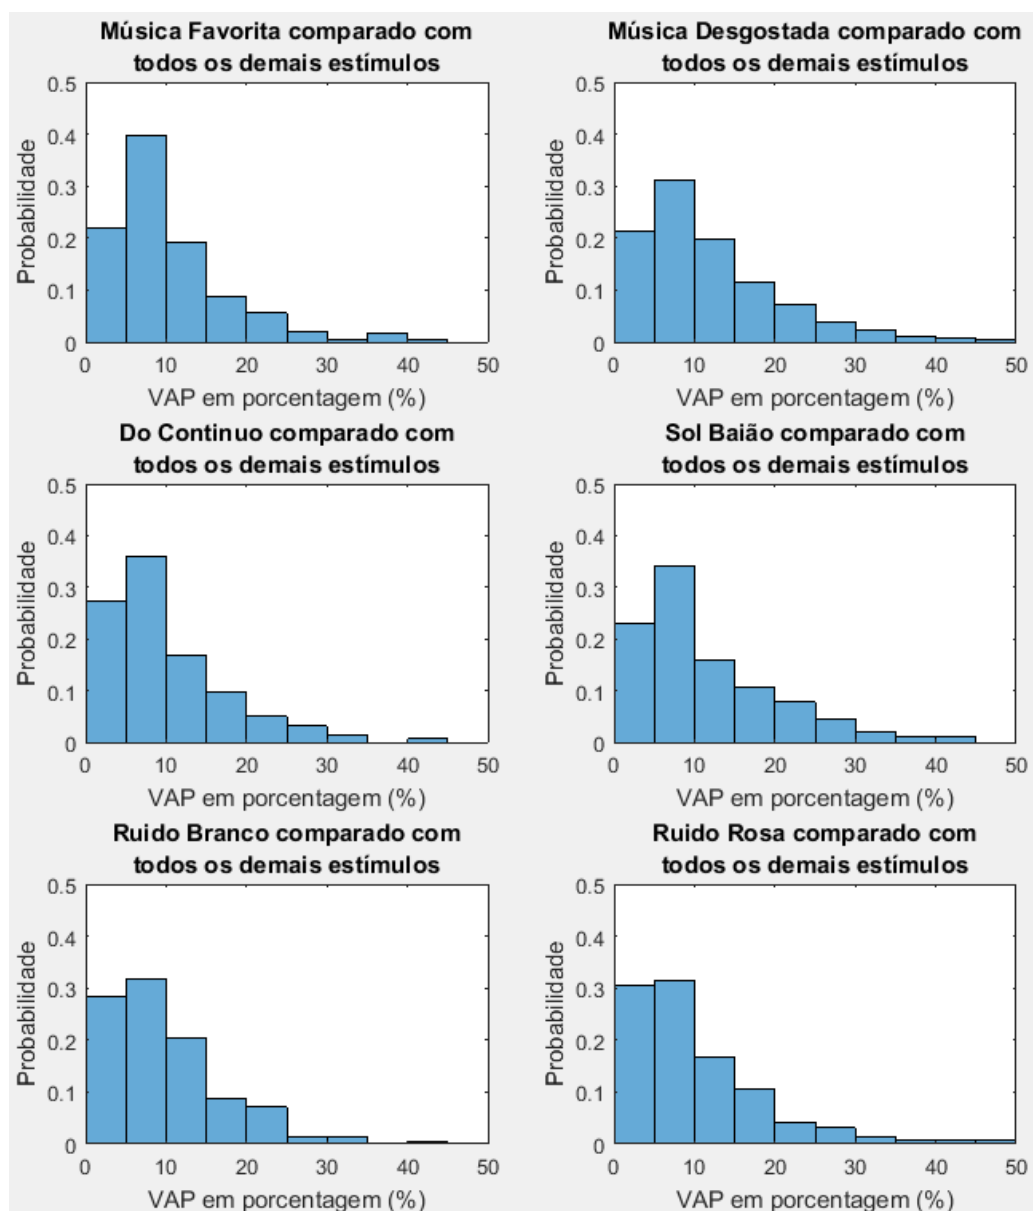


Figura 23 - Histograma VAP do PCP demais estímulos após seleção estatística

Com base nos resultados observados nos histogramas apresentados na Figura 22 e Figura 23, constata-se a presença de uma proporção significativa de valores de variação percentual (VAP) com magnitudes relevantes para o quantificador PCP. Especificamente, 80% desses valores encontram-se concentrados nos três primeiros intervalos (0 a 5%, 5 a 10% e 10 a 15%), enquanto os 20% restantes distribuem-se entre os intervalos subsequentes (15 a 50%).

No caso do histograma associado ao estímulo "silêncio", a distribuição dos valores de VAP apresenta uma forma simétrica e concentrada em torno do intervalo de 10 a 15%, o que sugere uma discrepância estatisticamente mais acentuada para esse estímulo em relação aos demais. Em contraste, a análise dos histogramas

referentes aos outros estímulos sonoros indica uma predominância de valores no intervalo de 5 a 10%, sugerindo que as variações significativas do PCP tendem a se concentrar em magnitudes inferiores para esses casos.

4.6.2.1 Definição do limiar de VAP após seleção estatística

Com base nos histogramas para o quantificador PCP (Figura 22 e Figura 23), estabeleceu-se um limiar mínimo de 15% para os valores de variação percentual (VAP), com o objetivo de identificar os canais de EEG ou bandas de frequência que mais se destacam na diferenciação entre os estímulos sonoros. Essa escolha foi motivada pela observação de que aproximadamente 80% dos valores de VAP situam-se abaixo desse patamar, conforme evidenciado na análise anterior.

Para implementar esse critério, utilizou-se o mesmo procedimento de filtragem estatística aplicado anteriormente: na planilha Excel com o sufixo final, todos os valores de VAP inferiores a 15% foram zerados, preservando apenas aqueles que indicam variações mais expressivas e relevantes para a distinção dos estímulos.

4.6.2.2 Análise detalhada da comparação com o silêncio

Para obter uma visão mais detalhada das comparações entre os estímulos sonoros e identificar os canais do EEG e bandas de frequência mais relevantes, foram gerados gráficos de radar comparando cada estímulo sonoro com o silêncio. Esses gráficos foram construídos com base na planilha Excel com o sufixo final, que contém os valores de VAP após a seleção estatística e a definição do limiar mínimo de 15%, conforme descrito no item **4.6.2.1 Definição do limiar de VAP após seleção estatística**.

A estrutura do gráfico de radar (Figura 24) ficou da seguinte maneira:

- **Extremidades do gráfico:** Representam os 20 canais do EEG (FP1, FP2, F7, F3, FZ, F4, F8, T3, C3, CZ, C4, T4, T5, P3, PZ, P4, T6, O1, OZ, O2);
- **Níveis do centro ao exterior:** Correspondem aos valores de VAP, indicando a magnitude das variações percentuais significativas;

- **Itens coloridos:** Representam as sete bandas de frequência (Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído), preenchendo o gráfico conforme a distribuição dos valores de VAP.

Adicionalmente, cada gráfico inclui a contabilização do número de valores de VAP selecionados, isto é, aqueles superiores ao limiar de 15%. Considerando que cada tabela subjacente ao gráfico é composta por 20 linhas (canais de EEG) e 7 colunas (bandas de frequência), totalizando 140 elementos, o gráfico exibe a quantidade de VAPs distintos de zero, oferecendo uma métrica quantitativa da relevância das variações observadas em cada comparação.

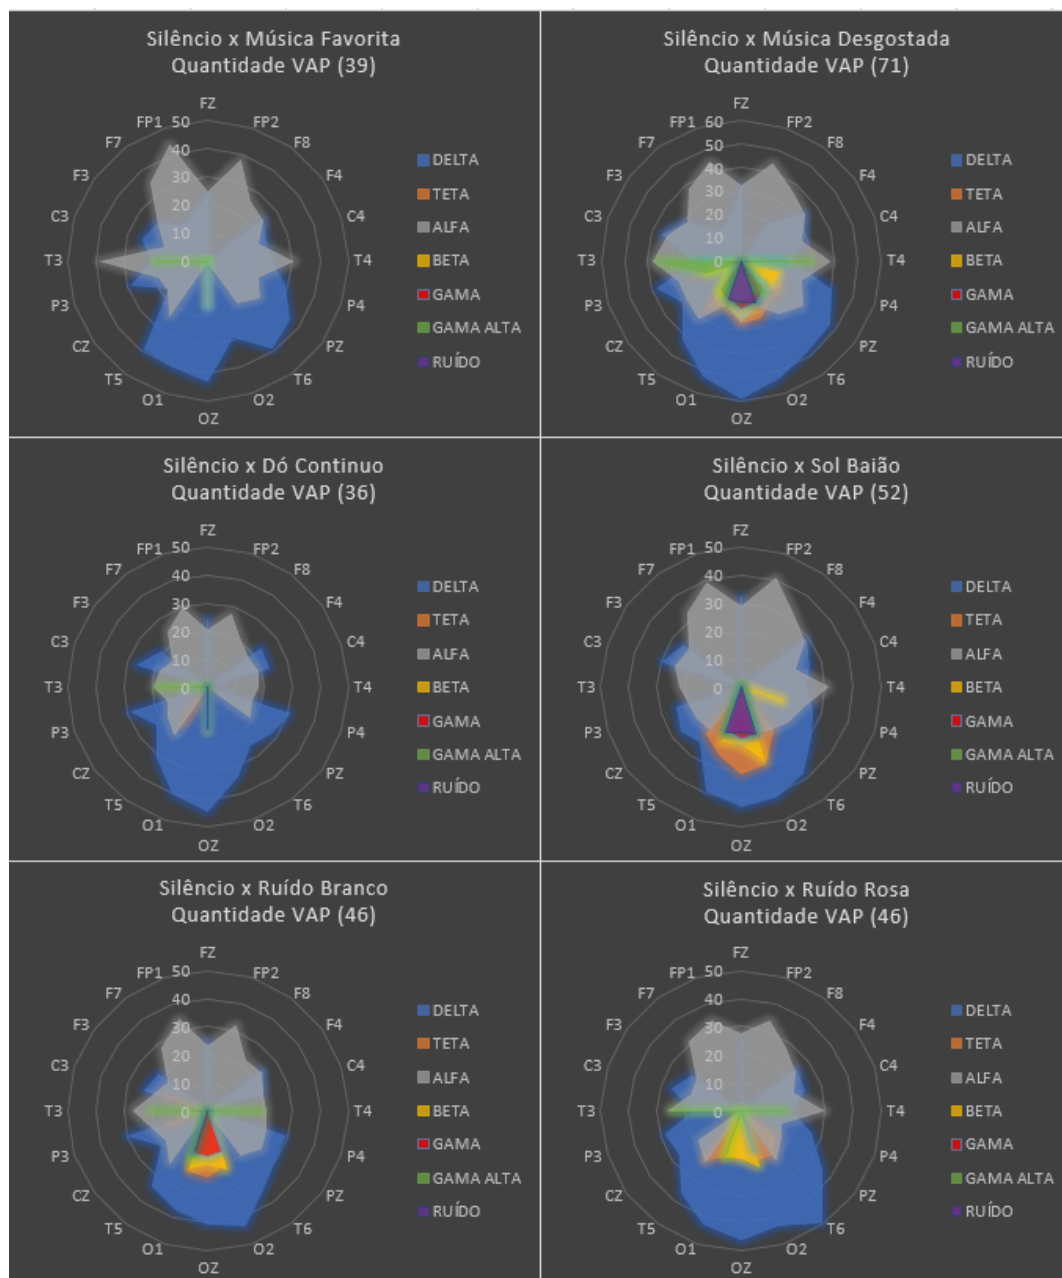


Figura 24 - VAP acima de 15% para PCP do estímulo Silêncio com os demais estímulos

Ao analisar a Figura 24, observa-se que as bandas de frequência Delta e Alfa apresentam valores de VAP acima de 20% em todas as comparações. Para a banda Delta, os valores mais relevantes do VAP concentram-se nos eletrodos occipitais e temporais, enquanto para a banda Alfa, os valores de VAP se destacam nos eletrodos frontais. Esses achados sugerem que a estimulação sonora tem um impacto direto na porcentagem de contribuição de potência (PCP), indicando que os estímulos sonoros provocam respostas neurofisiológicas mensuráveis nos pacientes.

Interpretação neurofisiológica:

- **Banda Delta:** A concentração de valores significativos nos eletrodos occipitais e temporais pode refletir a modulação da atividade cerebral em regiões associadas ao processamento visual e auditivo, respectivamente. As ondas Delta estão geralmente relacionadas ao sono profundo, mas em contextos de vigília, podem indicar mudanças na atividade cortical em resposta a estímulos externos (RAMOS *et al.*, 2020) (OLIVEIRA *et al.*, 2007);
- **Banda Alfa:** A predominância nos eletrodos frontais sugere que a banda Alfa está envolvida na modulação da atividade cognitiva e emocional durante a percepção de estímulos sonoros. As ondas Alfa são frequentemente associadas a estados de relaxamento e redução da ansiedade, mas também podem refletir processos de atenção e concentração (RAMOS *et al.*, 2020) (OLIVEIRA *et al.*, 2007).

4.6.2.3 Análise detalhada quando diferentes estímulos musicais são comparados

De forma análoga ao descrito no item **4.6.2.2 Análise detalhada da comparação com o silêncio**, foram elaborados gráficos de radar para comparar os demais estímulos sonoros entre si. A Figura 25 apresenta os gráficos das comparações mais relevantes, que possuem maior quantidade de VAPs diferentes de zero. Esses gráficos permitem visualizar as diferenças significativas na modulação neural entre diferentes estímulos musicais.

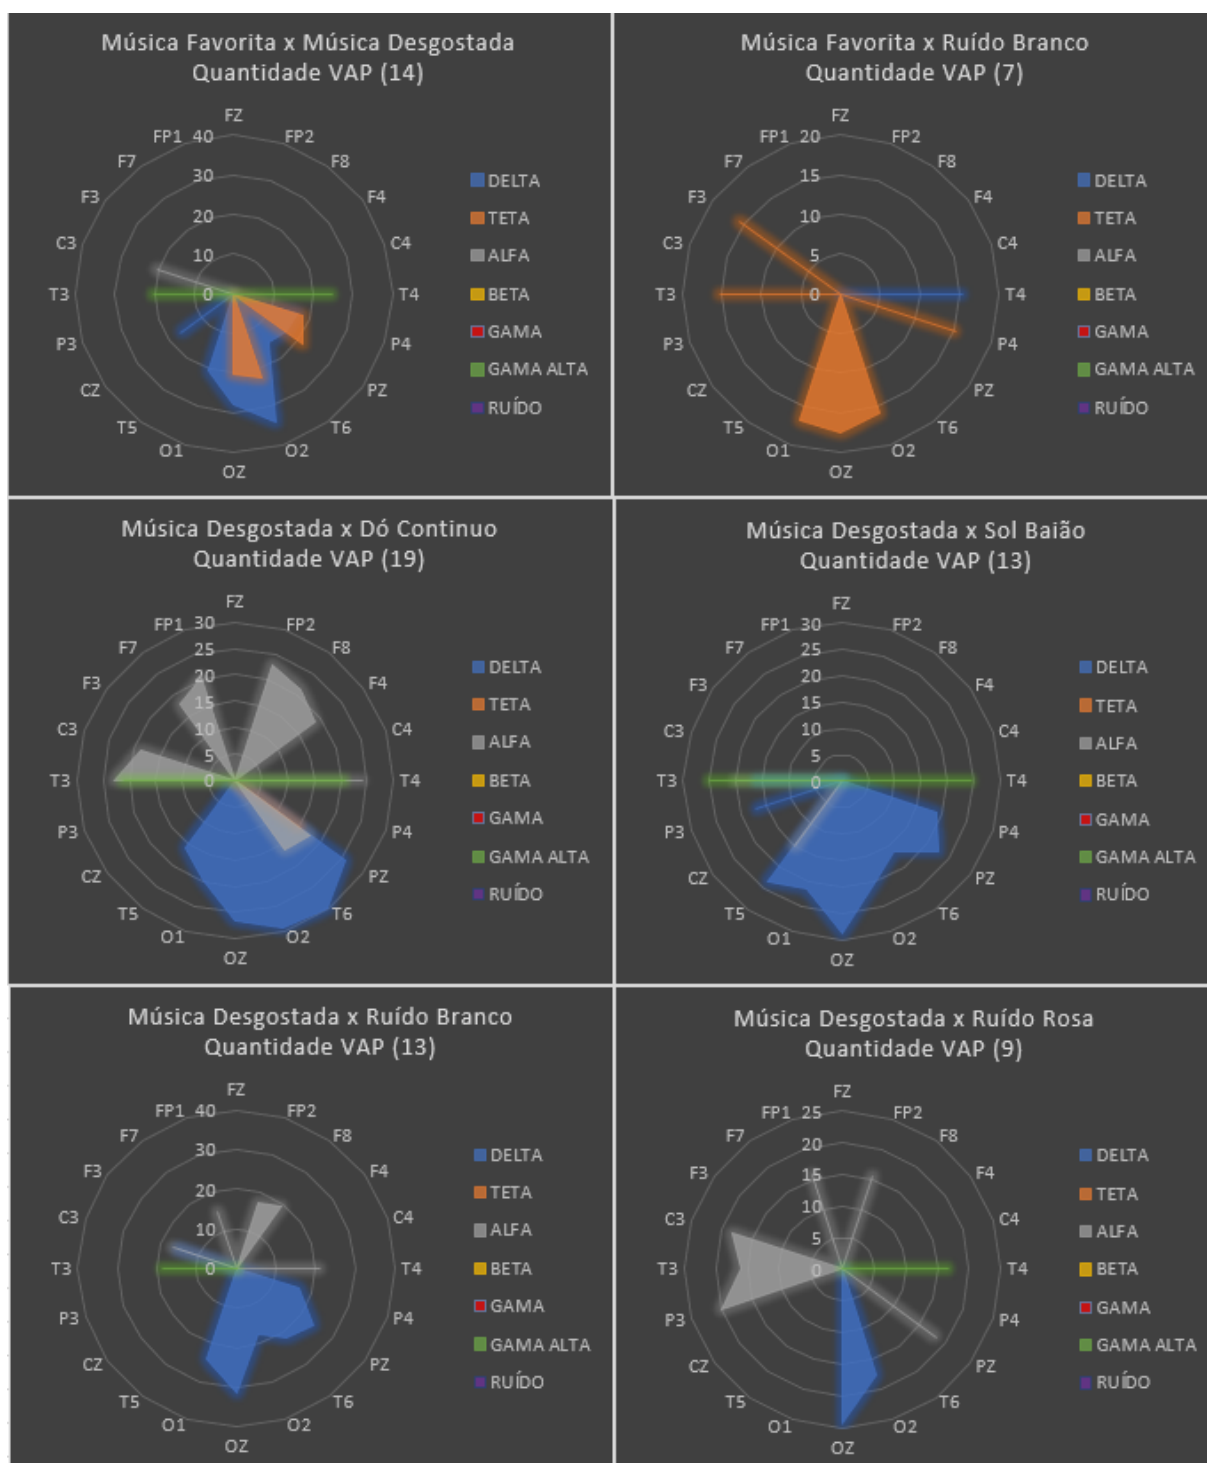


Figura 25 - VAP acima de 15% para PCP outras comparações relevantes

Conforme ilustrado na Figura 25 percebe-se que o estímulo sonoro “música desgostada” quando comparado aos demais estímulos apresentou maior quantidade de VAPs diferente de zero, e outra comparação relevante foi entre o estímulo música favorita e ruído branco. Quando se analisa as comparações com a música desgostada percebe-se que os maiores valores de VAP está aglutinado na banda de frequência

delta nos eletrodos occipitais. Vale ressaltar que também a banda de frequência alfa se destaca nas comparações com dó contínuo, ruído branco e rosa, nos eletrodos frontais e da região esquerda do cérebro. Evidencia-se também, a banda de frequência gama alta nos eletrodos da região temporal. Já nas comparações com o estímulo sonoro “música favorita” nota-se uma relevância na banda de frequência teta nos eletrodos occipitais e parietais.

4.7 CONSIDERAÇÕES FINAIS

Com base nos histogramas apresentados no item anterior, observa-se que, para o quantificador frequência mediana (FM), os valores de variação percentual (VAP) não alcançaram níveis significativos, permanecendo inferiores a 5%. Os histogramas indicam uma concentração de 100% dos valores nesse intervalo para todos os estímulos sonoros, sugerindo que este quantificador na metodologia adotada para o reconhecimento de padrões não se mostrou eficaz.

Em contraste, para o quantificador porcentagem de contribuição de potência (PCP), os valores de VAP exibem maior discrepância, atingindo até 50%, conforme demonstrado nos histogramas para todos os estímulos sonoros. Esse comportamento revela que o PCP apresenta um elevado potencial como ferramenta para o reconhecimento de padrões por meio do método proposto.

Analisando os gráficos de comparação entre os estímulos sonoros (Figura 24 e Figura 25), elaborados após a definição do limiar de variação percentual (VAP) conforme a seleção estatística, observa-se que o estímulo "silêncio" se diferenciou dos demais nas bandas de frequência Delta e Alfa. Ressalta-se que o estímulo "música desgostada" também exibiu uma discrepância significativa em relação aos outros estímulos sonoros nas mesmas bandas Delta e Alfa. Outra diferença notável foi constatada na comparação entre os estímulos "música favorita" e "ruído branco", na qual se verificou uma variação mais pronunciada na banda de frequência Teta.

No estudo (KUMAGAI; ARVANEH; TANAKA, 2017), argumenta-se que a lateralização hemisférica cerebral varia conforme o estímulo recebido. Os autores sugerem que a percepção musical nem sempre resulta em lateralização, mas que uma música não familiar pode elicitar uma resposta cortical mais intensa do que uma

música familiar. Esses achados corroboram os resultados deste trabalho, no qual se constatou que a "música desgostada" apresentou uma quantidade consideravelmente maior de valores de VAP significativos em comparação com os demais estímulos, evidenciando sua maior capacidade de diferenciação.

Diferente dos achados de (EHRlich *et al.*, 2019), que identificaram a potência da banda Gama no hemisfério direito e modulações da potência Beta frontal como elementos envolvidos em tarefas de interação, este estudo revela que o quantificador porcentagem de contribuição de potência (PCP) para as bandas Beta e Gama, sob estimulação musical em comparação com o "silêncio", apresenta baixa relevância, sendo mais pronunciado na região occipital.

Em (GROUSSARD *et al.*, 2010), foi conduzido um estudo sobre memória semântica, definida como a memória de conceitos independente das circunstâncias espaciais ou temporais de aprendizagem, que permite o reconhecimento de músicas e melodias ou a evocação de um forte sentimento de familiaridade. Nesse trabalho (GROUSSARD *et al.*, 2010), os autores observaram que a ativação dessa memória, sob estímulos musicais, ocorreu nas regiões temporal superior, frontal mediana e frontal inferior do hemisfério esquerdo, bem como na região frontal inferior do hemisfério direito. Diferentemente, o presente estudo destaca a relevância do PCP na banda de frequência Alfa nas regiões frontais e na banda Delta nas regiões occipitais, ao comparar o estímulo "silêncio" (ou repouso) com os demais estímulos sonoros.

De acordo com (MAITY *et al.*, 2015), a decomposição de sinais de EEG no domínio da frequência, utilizando a transformada discreta de wavelet nas bandas Alfa e Teta, seguida da análise por meio da técnica de flutuação multifractal sem tendência, revelou que uma estimulação musical simples impacta significativamente as dinâmicas cerebrais, manifestando-se em diferentes tipos de emoções. Nesse estudo (MAITY *et al.*, 2015), pequenos sons de drone elevaram a complexidade das bandas Teta e Alfa em todos os eletrodos frontais, um padrão também verificado no presente trabalho, no qual a aplicação de estímulos sonoros destacou a banda de frequência Alfa na região frontal.

Em (TSENG *et al.*, 2013), argumenta-se que a região pré-frontal do córtex é a mais apropriada para avaliar os efeitos da estimulação musical sobre respostas emocionais, por ser responsável pelas funções como controle cognitivo,

processamento emocional e atividades mentais cotidianas. Os autores observaram que essa região apresenta maior ativação com emoções positivas associadas ao prazer e menor ativação com emoções negativas, como ansiedade. Especificamente, a potência da banda Alfa nos hemisférios esquerdo e direito do córtex pré-frontal mostrou-se inversamente proporcional à intensidade emocional: a potência Alfa no hemisfério esquerdo diminui com músicas positivas, enquanto no hemisfério direito essa redução ocorre com músicas negativas, evidenciando uma assimetria funcional relacionada à valência emocional.

De maneira semelhante (FOLGIERI; BERGOMI; CASTELLANI, 2014), constatou-se que a ativação frontal está associada à intensidade das emoções evocadas pela música, reduzindo-se com sons relacionados a medo e frustração, e aumentando com sons que transmitem felicidade e satisfação.

Verifica-se a necessidade de mais estudos sobre estimulação musical para ampliar a compreensão dos benefícios potenciais na área da terapia musical cognitiva. A análise do quantificador de coerência permanece em desenvolvimento, uma vez que sua estrutura de dados difere das estruturas dos quantificadores PCP e FM.

CAPÍTULO 5 - APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL

O presente capítulo aborda a aplicação de técnicas de inteligência artificial (IA) no contexto do processamento e análise de sinais neurofisiológicos. A inteligência artificial, campo da ciência da computação dedicado ao desenvolvimento de sistemas capazes de simular capacidades humanas como aprendizado, raciocínio e reconhecimento de padrões, tem se mostrado uma ferramenta poderosa para solucionar problemas complexos em diversas áreas, incluindo a medicina e a engenharia biomédica. Neste capítulo, exploram-se arquiteturas e métodos de IA empregados para a classificação e interpretação dos dados de EEG coletados, destacando seus benefícios, desafios e resultados obtidos na pesquisa.

O processo de treinamento envolveu experimentação extensiva com o ajuste de hiperparâmetros e a aplicação de técnicas de otimização, buscando adaptar cada modelo aos desafios inerentes aos dados de EEG, tais como a natureza não estacionária, a alta suscetibilidade a ruídos e a variabilidade interindividual.

5.1 DEFINIÇÃO FORMAL DO PROBLEMA

Formalmente, os sinais de EEG podem ser representados como $X_j^{(e,w)}(s) \in \mathbb{X}$, onde $j = \{1, 2, \dots, n\}$ denota os pacientes, $e = \{1, 2, \dots, d\}$ os eletrodos, $w = \{1, 2, \dots, m\}$ o número de épocas/segmentos selecionadas pelo neurologista, e $s = \{1, 2, \dots, t\}$ as variações elétricas ao longo do tempo para cada eletrodo. Cada amostra X_j está associada a um rótulo $y_i \in Y$, que representa o resultado esperado (por exemplo: estimulação A, etiologia B, prognóstico C, etc.). Este estudo tem como objetivo aprender uma função de classificação baseada em modelos de IA, definida como $F: X \rightarrow y'$ a partir do conjunto de dados de EEG, tal que $y' \approx y$, permitindo assim a classificação de novos exames de EEG $X_u \notin \mathbb{X}$, cuja classe é desconhecida.

5.2 ARQUITETURAS

Inicialmente, foi utilizado como base o código fonte da dissertação de (BALDO JÚNIOR, 2023), que combina Redes Neurais Convolucionais (CNN) e Redes Neurais Recorrentes do tipo *Long Short-Term Memory* (LSTM) para a classificação de sinais de EEG. Esse modelo híbrido CNN-LSTM foi inicialmente projetado para processar sinais brutos de EEG e atributos adicionais, como idade, sexo e dados estatísticos do sinal, visando classificar a etiologia do coma ou prognóstico do paciente.

A arquitetura proposta por (BALDO JÚNIOR, 2023), é composta pelos seguintes elementos (Figura 26):

- **Paciente:** Representa o paciente ou voluntário submetido ao EEG;
- **Dados do Paciente:** Informações pertinentes ao voluntário ou paciente, constituídas por idade, sexo, prognóstico, etiologia do coma, etc;
- **Captura de Sinal:** Etapa na qual os eletrodos conectados ao escalpo cerebral do paciente são conectados ao aparelho que realiza a coleta das oscilações de tensões, capturando assim o EEG;
- **Seleção de Épocas:** O sinal coletado é dividido em épocas/segmentos de tempo, comumente de 2 segundos. Essas épocas/segmentos podem ser selecionadas por um neurologista especializado, que avalia a qualidade do exame e seleciona trechos com a menor quantidade de ruídos e que representem o estado do paciente. Normalmente, nesses estudos, são selecionadas 10 épocas/segmentos;
- **Extração de Características Estatísticas:** Extração de características estatísticas das épocas/segmentos selecionadas, como média, desvio padrão, maior amostra, menor amostra e variância;
- **Rede Neural:** Elemento responsável por extrair características do sinal, composto por uma camada convolucional (CNN) que extrai características relevantes do sinal de EEG bruto separado por épocas/segmentos. Em seguida, esses dados extraídos são processados por uma camada LSTM, que modela as dependências temporais nos sinais de EEG;
- **Camada de Achatamento (*Flatten*):** Agrupamento dos dados dos pacientes, dados estatísticos e a saída da rede neural;

- **Camada Densa (Fully Connected):** Os dados da camada de achatamento são a entrada da camada densa, que realiza a classificação do EEG, retornando a porcentagem do EEG analisado em determinada classe.

Essa arquitetura híbrida CNN-LSTM permite explorar tanto as características espaciais (CNN) quanto as temporais (LSTM) dos sinais de EEG. A inclusão de informações adicionais do paciente e características extraídas dos sinais de EEG, conforme demonstrado por (BALDO JÚNIOR, 2023), aprimoram o desempenho do modelo em tarefas de classificação de sinais de EEG.

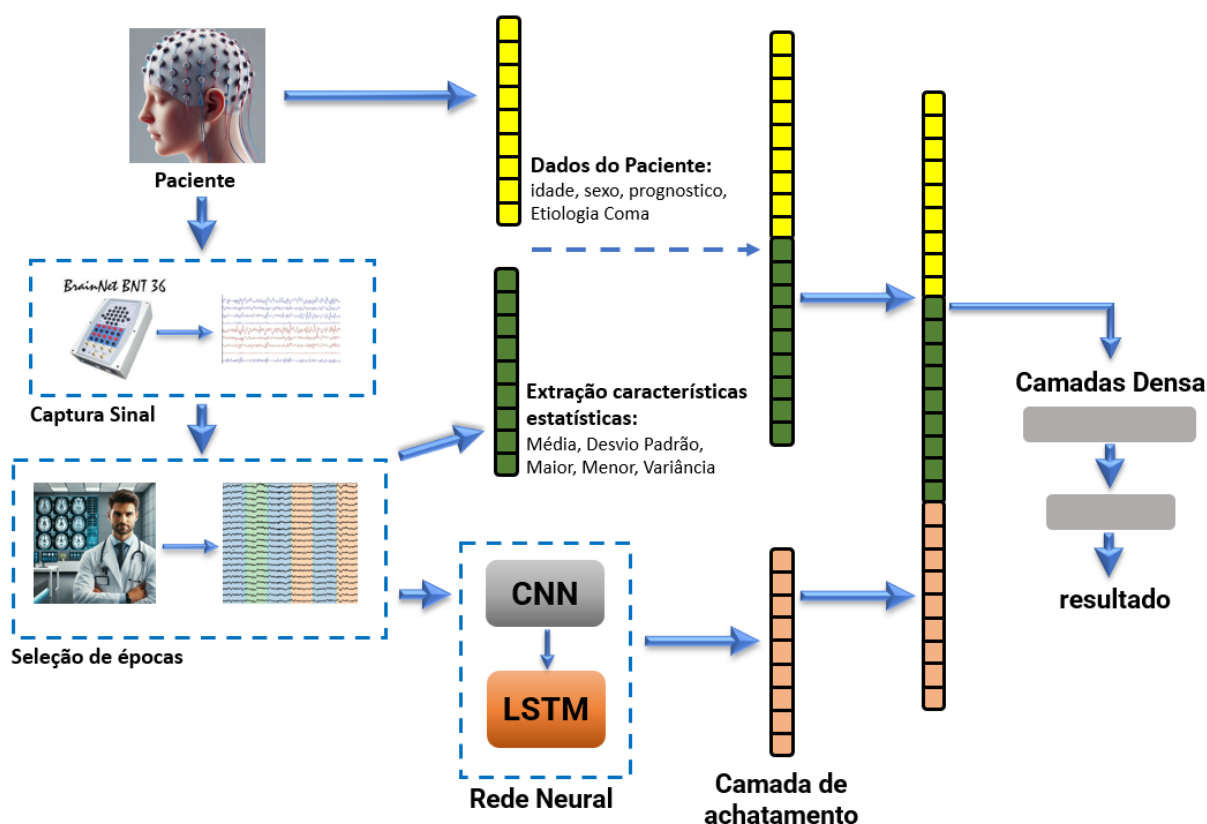


Figura 26 - Arquitetura IA CNN-LSTM base adaptado de (BALDO JÚNIOR, 2023)

Outra arquitetura descrita por (BALDO JÚNIOR, 2023) também foi empregada para fins de treinamento, distinguindo-se por não utilizar os dados adicionais do paciente nem os dados estatísticos extraídos do sinal de EEG. Nessa configuração, o modelo recebe apenas os sinais brutos de EEG como entrada, que são processados diretamente pelas camadas convolucionais e recorrentes, sem a inclusão de atributos complementares. Essa abordagem permite avaliar o impacto da ausência dessas informações adicionais no desempenho da classificação. A estrutura dessa arquitetura pode ser visualizada na Figura 27.

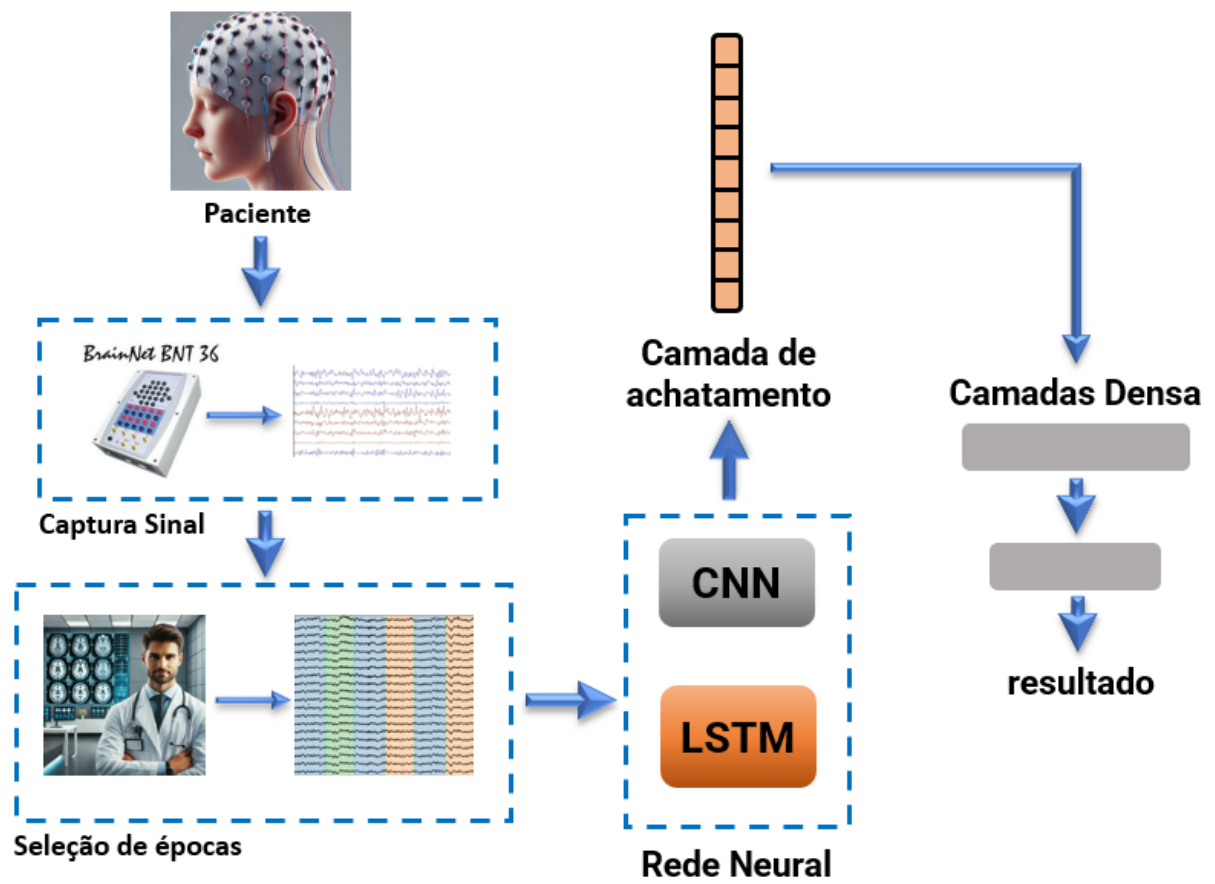


Figura 27 - Arquitetura CNN-LSTM somente com sinal puro adaptado de (BALDO JÚNIOR, 2023)

Além da arquitetura híbrida CNN-LSTM, para fins de comparação, foi implementada uma rede neural baseada em *Multi Layer Perceptron* (MLP). Esse modelo recebe como entrada os dados do paciente e/ou os dados estatísticos extraídos do sinal de EEG, retornando como resultado a probabilidade de a entrada pertencer a uma determinada classe. A estrutura dessa abordagem está ilustrada na Figura 28.

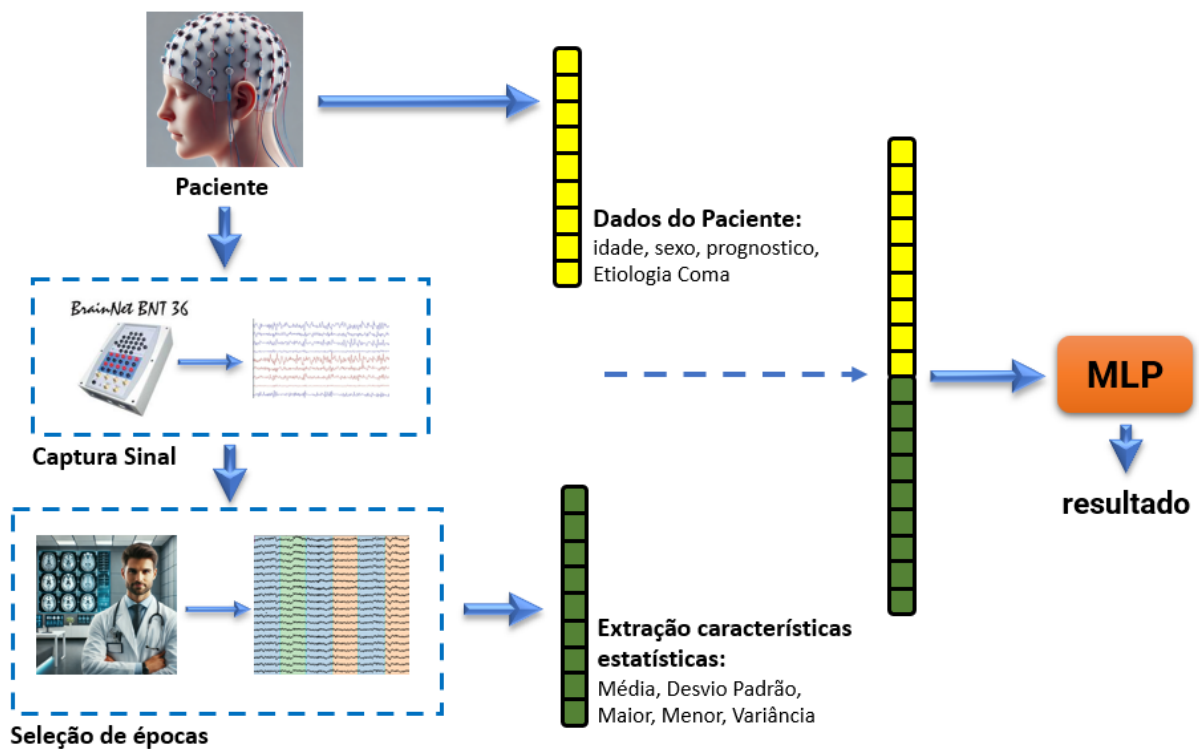


Figura 28 – Arquitetura utilizando *Multi Layer Perceptron* (MLP) adaptado de (BALDO JÚNIOR, 2023)

Para este trabalho, estas arquiteturas foram adaptadas, incorporando novos modelos de IA, como *Transformers*, com o objetivo de aprimorar a acurácia das classificações, bem como adicionar outros quantificadores extraídos do sinal de EEG e verificar a eficiência destes, testando regiões cerebrais e eletrodos mais eficazes para estas atividades. Com estas arquiteturas realizou-se os seguintes experimentos:

- Prognóstico Clínico (Classificação Binária [Favorável e Desfavorável]);
- *Transformer* e prognóstico clínico (Classificação Binária [Favorável e Desfavorável]);
- Etiologia do Coma (5 Categorias);
- Gosto Musical (Classificação Binária [Gostada e Desgostada]).

5.3 TREINAMENTO

O treinamento foi realizado utilizando a validação cruzada estratificada k-fold, uma técnica robusta para avaliar a capacidade de generalização de modelos de aprendizado de máquina, especialmente em cenários com classes desbalanceadas. A estratificação garante que cada partição de validação cruzada reflita a distribuição

global das classes, evitando avaliações de desempenho enviesadas (BENGIO; GRANDVALET, 2003). Essa abordagem consiste em dividir o conjunto de dados em k partes (*folds*), assegurando que cada *fold* mantenha a mesma proporção de classes do conjunto original. O modelo é treinado iterativamente k vezes, utilizando um *fold* diferente como conjunto de teste e os $k - 1$ *folds* restantes como conjunto de treinamento em cada iteração.

No presente estudo, foi empregada a validação cruzada estratificada 5-fold (Figura 29) com X (comumente 30) épocas por *fold*. Para cada época, utilizou-se um tamanho de lote (*batch size*) igual a um, sendo o número de passos por época definido como o produto do número de pacientes pelo número de segmentos selecionados. Essa configuração garante a consistência das dimensões de entrada ao longo de todas as iterações, assegurando uma convergência adequada e possibilitando uma comparação justa entre os modelos avaliados. Além disso, foi utilizado um gerador de dados personalizado para carregar as amostras individualmente, otimizando o fluxo de processamento e reduzindo a carga de memória.

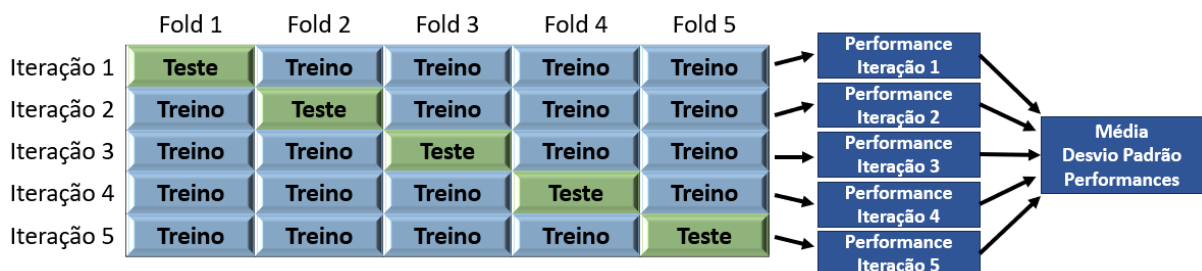


Figura 29 - Modelo k-fold de 5 adotado para treinamento das redes neurais

Durante os testes, a classificação final foi determinada pelo cálculo da moda das previsões obtidas para cada segmento, estratégia que aprimora a consistência da avaliação do desempenho do modelo. A medida final de desempenho dos modelos foi reportada como a média e o desvio padrão dos resultados obtidos em todos os *folds* (Figura 29), proporcionando uma avaliação confiável e generalizável.

5.4 MÉTRICAS DE PERFORMANCE

Para avaliar o desempenho dos modelos de classificação de EEGs, foram adotadas métricas que permitem uma análise abrangente da capacidade preditiva dos modelos, considerando tanto o desempenho global quanto o comportamento em

classes específicas, especialmente em cenários com classes desbalanceadas. A escolha criteriosa dessas métricas é essencial para garantir uma avaliação equilibrada dos modelos, reconhecendo a possível distribuição desigual das classes nas bases de dados de EEG.

A acurácia, definida como a proporção de classificações corretas em relação ao total de amostras, foi utilizada como uma métrica inicial para avaliar o desempenho geral dos modelos (SOKOLOVA; LAPALME, 2009). No entanto, em problemas de classificação de EEGs, onde classes desbalanceadas são comuns, a acurácia pode superestimar o desempenho de um modelo que favorece a classe majoritária, negligenciando erros nas classes minoritárias, conforme observado em estudos de classificação de EEGs para diagnóstico neurológico (ROY *et al.*, 2019).

Para mitigar essa limitação, foram empregadas outras métricas, como precisão e *recall* (revocação), que avaliam o desempenho do modelo em cada classe individualmente (POWERS, 2020). A precisão, também conhecida como valor preditivo positivo, mede a proporção de amostras classificadas como pertencentes a uma classe que realmente pertencem a essa classe, enquanto o *recall*, também conhecido como sensibilidade, indica a proporção de amostras de uma classe que foram corretamente identificadas. Essas métricas são particularmente úteis para avaliar a capacidade do modelo de identificar corretamente casos raros, como pacientes com maior chance de recuperação.

De forma inversa ao *recall*, a especificidade mede a proporção de amostras classificadas como **NÃO** pertencente a uma classe (conhecida como valor preditivo negativo) (POWERS, 2020).

Adicionalmente, o F1 score, que representa a média harmônica entre precisão e *recall*, foi utilizado para combinar essas duas métricas em uma medida única, oferecendo uma visão balanceada do desempenho por classe (GOUTTE; GAUSSIER, 2005). Em cenários desbalanceados, o F1 score (macro) foi calculado como a média dos F1 scores de cada classe, e o F1 score (*weighted*) pelo suporte (número de amostras) de cada classe, proporcionando uma métrica global mais representativa.

Para o cálculo dessas métricas, utiliza-se como base a matriz de confusão, ilustrada na Tabela 5 para o caso de uma classificação binária. Essa matriz permite visualizar o desempenho do modelo, apresentando as quantidades de verdadeiros

positivos, verdadeiros negativos, falsos positivos e falsos negativos, que servem de base para o cálculo das métricas de avaliação.

Tabela 5 - Exemplo de matriz de confusão de uma classificação binária

Classe Dado	Classificação Positiva	Classificação Negativa
Classe A	verdadeiro positivo (vp)	falso negativo (fn)
Classe B	falso positivo (fp)	verdadeiro negativo (vn)

vp fn

fp vn

As fórmulas matemáticas correspondentes a cada uma das métricas mencionadas são apresentadas na Tabela 6.

Tabela 6 - Formulas matemáticas das métricas

Métrica	Formula
Acurácia	$\frac{vp + vn}{vp + fn + fp + vn}$
Precisão	$\frac{vp}{vp + fp}$
Recall (revocação)	$\frac{vp}{vp + fn}$
Especificidade	$\frac{vn}{fp + vn}$
F1 score	$\frac{2 \times precisão \times recall}{precisão + recall}$

As métricas de desempenho selecionadas, incluindo acurácia, precisão, recall, especificidade, F1 score (macro e *weighted*) baseadas na matriz de confusão, proporcionaram uma avaliação equilibrada dos modelos de classificação de EEGs,

Essa abordagem, fundamentada em medidas que analisam tanto o desempenho global quanto o comportamento por classe, é essencial para identificar a capacidade dos modelos em detectar casos raros, como pacientes com maior chance de recuperação, garantindo uma análise confiável para aplicações clínicas.

5.5 QUANTIFICADORES ADICIONADOS PARA ANÁLISE

5.5.1 PCP

Detalhado no item 2.1.1 Porcentagem de Contribuição de Potência (PCP).

5.5.2 FM

Apresentado no item 2.1.2 Frequência Mediana (FM).

5.5.3 Coerência

Discutida no item 2.1.3 Coerência.

5.5.4 Eletrodos Região Frontal

A região frontal do cérebro, destacada em vermelho na Figura 30, abrange os eletrodos FP1, FP2, F7, F8, F3, F4 e Fz, conforme o sistema internacional 10-20 de posicionamento de eletrodos. Esses eletrodos estão localizados na parte anterior do couro cabeludo, cobrindo o lobo frontal, que desempenha um papel central em uma ampla gama de funções cognitivas e comportamentais. O lobo frontal é responsável por processos como raciocínio, planejamento, tomada de decisão, controle inibitório, regulação emocional, atenção, memória de trabalho, comportamento social e controle motor voluntário (FIRAT, 2019).

Áreas específicas dessa região, como o córtex pré-frontal, são cruciais para as funções executivas, que incluem a capacidade de organizar, monitorar e adaptar comportamentos para atingir objetivos (MILLER; COHEN, 2001), enquanto a área de

Broca contribui para a produção da linguagem (DRONKERS *et al.*, 2007) e o córtex motor gerencia os movimentos voluntários.




Figura 30 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região frontal destacada em vermelho. Os eletrodos FP1, FP2, F7, F8, F3, F4 e FZ correspondem à área frontal

5.5.5 Eletrodos Região Central

A região central do cérebro, destacada em amarelo na Figura 31, abrange os eletrodos C3, C4 e Cz, conforme o sistema internacional 10-20 de posicionamento de eletrodos. Esses eletrodos estão posicionados ao longo da linha média e das áreas laterais do couro cabeludo, cobrindo a região central do cérebro, que inclui o giro pré-central e pós-central, localizados respectivamente anterior e posterior ao sulco central (ou fissura de Rolando).

Essa região é responsável por funções sensoriais e motoras primárias: o giro pré-central (logo à frente do sulco central), que contém o córtex motor primário, gerencia os movimentos voluntários do corpo contralateral, enquanto o giro pós-central (logo atrás do sulco central), que abrange o córtex somatossensorial primário, processa informações sensoriais táteis, de pressão, dor e temperatura (KANDEL,

2012). Estes eletrodos centrais, são amplamente utilizados em estudos de imagética motora e em interfaces cérebro-computador (BCI), pois captam oscilações relacionadas à preparação, execução e imaginação de movimentos (WANG *et al.*, 2007).




Figura 31 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região central destacada em amarelo. Os eletrodos C3, C4 e CZ correspondem à área central, localizada ao longo da linha média e das áreas laterais do couro cabeludo

5.5.6 Eletrodos Região Occipital

A região occipital do cérebro, destacada em verde na Figura 32, abrange os eletrodos O1, O2 e OZ, conforme o sistema internacional 10-20 de posicionamento de eletrodos. Esses eletrodos estão posicionados na parte posterior do couro cabeludo, cobrindo o lobo occipital, que é primariamente responsável pelo processamento visual. O córtex visual primário (área de Brodmann 17), localizado no lobo occipital, desempenha um papel central na percepção visual, incluindo o reconhecimento de formas, cores, movimentos e profundidade (KANDEL, 2012).

Suas funções incluem a recepção e decodificação de estímulos visuais, mapeamento do campo visual, análise de cor, forma, distância, tamanho e

profundidade dos objetos, além do reconhecimento de faces e objetos familiares. A atividade elétrica registrada nos eletrodos occipitais reflete, portanto, o funcionamento do sistema visual e é fundamental tanto para a investigação de processos perceptivos quanto para a detecção de alterações neurológicas que afetam a visão.




Figura 32 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região occipital destacada em verde. Os eletrodos O1, O2 e OZ correspondem à área occipital, localizada na parte posterior do couro cabeludo, abrangendo o lobo occipital

5.5.7 Eletrodos Região Parietal

A região parietal do cérebro, destacada em azul na Figura 33, abrange os eletrodos P3, P4 e PZ, conforme o sistema internacional 10-20 de posicionamento de eletrodos. Esses eletrodos estão posicionados na parte superior e posterior do couro cabeludo, cobrindo o lobo parietal, que desempenha um papel essencial na integração sensorial e na percepção espacial.

O lobo parietal é responsável por funções como o processamento de informações somatossensoriais (como tato, temperatura, pressão e dor), a coordenação visuomotora, a orientação espacial, a atenção e a integração de

estímulos sensoriais para a construção de uma representação do ambiente (KANDEL, 2012).

Além disso, áreas específicas do lobo parietal, como o córtex parietal posterior, estão envolvidas na memória de trabalho e no processamento de tarefas que requerem atenção espacial (CORBETTA; SHULMAN, 2002). Permitindo o reconhecimento de objetos por meio do tato, a orientação espacial, a percepção da localização das partes do corpo e a integração de informações sensoriais com a visão e a audição. Além disso, o lobo parietal está envolvido em processos cognitivos como a atenção, a linguagem e a memória (CORBETTA; SHULMAN, 2002).




Figura 33 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região parietal destacada em azul. Os eletrodos P3, P4 e PZ correspondem à área parietal, localizada na parte superior e posterior do couro cabeludo, abrangendo o lobo parietal

5.5.8 Eletrodos Região Temporal

A região temporal do cérebro, destacada em laranja na Figura 34, abrange os eletrodos T3, T4, T5 e T6, conforme o sistema internacional 10-20 de posicionamento de eletrodos. Esses eletrodos estão posicionados nas áreas laterais do couro

cabeludo, cobrindo o lobo temporal, que desempenha um papel fundamental em funções como audição, linguagem, memória e emoção.

O lobo temporal contém o córtex auditivo primário (área de Brodmann 41 e 42), responsável pelo processamento de estímulos auditivos, e áreas associativas envolvidas na compreensão da linguagem, como a área de Wernicke no hemisfério dominante (KANDEL, 2012). Além disso, o lobo temporal medial, que inclui o hipocampo e a amígdala, é crucial para a formação de memórias declarativas e a regulação emocional (SQUIRE; ZOLA-MORGAN, 1991).




Figura 34 - Representação esquemática do sistema 10-20 de posicionamento de eletrodos para EEG, com a região temporal destacada em laranja. Os eletrodos T3, T4, T5 e T6 correspondem à área temporal, localizada nas partes laterais do couro cabeludo, abrangendo o lobo temporal

5.5.9 Common spatial pattern (CSP)

O *Common Spatial Pattern* (CSP) é uma técnica amplamente empregada na análise de sinais de EEG para identificar padrões espaciais discriminativos entre diferentes classes de sinais cerebrais, como estados motores ou cognitivos distintos (BLANKERTZ *et al.*, 2008). O algoritmo decompõe os sinais de EEG em componentes espaciais, otimizados para maximizar a variância de uma classe enquanto minimiza a

variância da outra, facilitando a distinção entre as condições neurológicas estudadas (RAMOSER; MULLER-GERKING; PFURTSCHELLER, 2000).

Matematicamente, o CSP calcula filtros espaciais a partir das matrizes de covariância dos sinais de EEG, resolvendo um problema de autovalores generalizado. Esses filtros projetam os sinais originais em um novo espaço, realçando as características mais discriminativas e permitindo a classificação subsequente. A eficácia do CSP na extração de características espaciais relevantes o torna uma ferramenta valiosa em interfaces cérebro-computador (BCI) e na análise de padrões cerebrais em diversos contextos clínicos e de pesquisa, incluindo a detecção de estados alterados de consciência e a classificação de sinais de EEG em pacientes com distúrbios neurológicos (LOTTE *et al.*, 2018).

5.5.10 Decomposição de Wavelet

A decomposição por *wavelets* é uma técnica de processamento de sinais que representa um sinal em termos de funções de base chamadas *wavelets*, que são oscilações localizadas no tempo e na frequência. Diferentemente da transformada de Fourier, que fornece apenas informações no domínio da frequência, a transformada wavelet discreta (DWT, *Discrete Wavelet Transform*) oferece uma análise multi-resolução, capturando características temporais e frequenciais simultaneamente (MALLAT, 2008). Isso é particularmente útil para sinais não estacionários, como EEG, que exibem variações dinâmicas ao longo do tempo. A DWT decompõe o sinal em coeficientes de aproximação (componentes de baixa frequência) e coeficientes de detalhe (componentes de alta frequência) em diferentes níveis de resolução, permitindo a extração de padrões.

A wavelet Daubechies 4 (Db4) é uma função *wavelet* ortogonal com suporte compacto, caracterizada por quatro coeficientes de filtro que definem sua capacidade de decompor sinais em componentes de baixa e alta frequência. Desenvolvida por Ingrid Daubechies, a Db4 possui quatro momentos nulos, o que permite a representação precisa de polinômios até o grau 3, tornando-a adequada para a análise de sinais complexos e não estacionários. Sua suavidade moderada, em comparação com *wavelets* mais simples, como a Haar, aliada à eficiência computacional, captura variações temporais e frequenciais, por exemplo, picos ou

ondas específicas, em diferentes escalas de resolução (DAUBECHIES, 1992). Dessa forma, a Db4 proporciona uma análise multirresolução robusta, isolando características do sinal que podem indicar alterações no estado neurológico, capturando dinâmicas espaço-temporais críticas frequentemente obscurecidas em sinais bruto.

5.6 ABREVIATURAS UTILIZADAS NO PROCESSAMENTO

Para melhorar a visualização das tabelas com os resultados, foram adotadas as seguintes abreviaturas (Tabela 7):

Tabela 7 - Abreviaturas utilizadas para os resultados dos modelos de IA

Abreviatura	Significado
MCL	Modelo utilizando uma camada convolucional (CNN) seguida de uma camada recorrente de LSTM
MMLP	Modelo utilizando <i>Multi Layer Perceptron</i> (MLP)
MT	Modelo utilizando camadas de <i>Transformer</i>
MCT	Modelo utilizando uma camada convolucional (CNN) seguida de camadas de <i>Transformer</i>
MCLT	Modelo utilizando uma camada convolucional (CNN), seguida de uma camada recorrente de LSTM, e por fim camadas de <i>Transformer</i>
CP	Representa o processamento utilizando características do paciente (sexo, idade, etiologia do coma), totalizando 3 atributos por época/segmento
CE	Representa o processamento utilizando características estatísticas do sinal (média, desvio padrão, maior amostra, menor amostra, variância), totalizando 5 atributos por eletrodo, e 100 atributos por época/segmento
CPCP	Representa o processamento utilizando características do quantificador de porcentagem de contribuição de potência (PCP) por banda de frequência, totalizando 4 a 7 atributos por eletrodo, e (80 a 140 atributos por época/segmento
CFM	Representa o processamento utilizando características do quantificador frequência mediana (FM) por banda de frequência, totalizando 4 a 7 atributos por eletrodo, e 80 a 140 atributos por época/segmento.
CC	Representa o processamento utilizando características do quantificador Coerência, totalizando 129 atributos por eletrodo, e 2580 atributos por época/segmento

Abreviatura	Significado
CPE	Representa o processamento utilizando características do paciente e estatísticas do sinal, totalizando 103 atributos por época/segmento.
CPPCP	Representa o processamento utilizando características do paciente e do quantificador de PCP
CPFM	Representa o processamento utilizando características do paciente e do quantificador de FM
CPC	Representa o processamento utilizando características do paciente e do quantificador de Coerência
CPEF	Representa o processamento utilizando características do paciente e utilizando somente os eletrodos da região frontal (conforme Figura 30)
CPEC	Representa o processamento utilizando características do paciente e utilizando somente os eletrodos da região central (conforme Figura 31)
CPEO	Representa o processamento utilizando características do paciente e utilizando somente os eletrodos da região occipital (conforme Figura 32)
CPEP	Representa o processamento utilizando características do paciente e utilizando somente os eletrodos da região parietal (conforme Figura 33)
CPET	Representa o processamento utilizando características do paciente e utilizando somente os eletrodos da região temporal (conforme Figura 34)
CCSPX	Representa o processamento utilizando características extraídas através do algoritmo <i>Common Spatial Pattern</i> (CSP) com X valores
CDW4	Representa o processamento utilizando características da Decomposição Wavelet, com 4 valores extraídos através do CSP
REA	Representa que o sinal foi reamostrado para frequência de 400 Hz com 801 pontos por época/segmento
SREA	Representa que o sinal NÃO foi reamostrado (SEM reamostragem) para frequência de 400 Hz com 801 pontos por época/segmento
SPV	Representa que o processamento foi realizado sem utilização de placa de vídeo
Espec.	Especificidade
ALL	Representa que o processamento foi realizado utilizando a base de dados completa, sem agrupar os exames pertencentes ao mesmo indivíduo, mesmo em cenários nos quais existem segmentos do mesmo exame associados a diferentes causalidades
First Half	Representa que o processamento foi realizado utilizando metade da base de dados, mantendo os segmentos de um mesmo exame associados exclusivamente a uma única causalidade (A ou B), preservando a proporção entre as causalidades e utilizando a primeira metade dos exames disponíveis.

Abreviatura	Significado
<i>Other Half</i>	Representa que o processamento foi realizado utilizando metade da base de dados, mantendo os segmentos de um mesmo exame associados exclusivamente a uma única causalidade (A ou B), preservando a proporção entre as causalidades e utilizando a outra metade dos exames disponíveis.
<i>Same Half</i>	Representa que o processamento foi realizado utilizando metade da base de dados, mantendo os segmentos de um mesmo exame associados as causalidades A e B.
<i>ALL Group</i>	Representa que o processamento foi realizado utilizando a base de dados completa, assegurando que todas as causalidades associadas a um mesmo exame estejam presentes no mesmo conjunto de treinamento. Essa abordagem visa evitar a fragmentação dos dados relacionados a um único paciente, garantindo a integridade das informações durante o aprendizado do modelo

5.7 CONFIGURAÇÃO DE EXECUÇÃO DOS TREINAMENTOS

Os experimentos foram realizados em um notebook AVELL equipado com um processador Intel Core i7-12700H (2,30 GHz), 32 GB de memória RAM e uma placa de vídeo NVIDIA GeForce RTX 3060 (6 GB de VRAM). No entanto, durante o processamento das redes neurais com CNN e *Transformer*, foi necessário desabilitar a placa de vídeo devido à ausência de algoritmos determinísticos no driver da GPU, o que resultou no seguinte erro: **[GPU MaxPool gradient ops do not yet have a deterministic XLA implementation]**. Esse ajuste garantiu a estabilidade do treinamento, embora tenha impactado o tempo de execução dos modelos.

5.8 PROGNÓSTICO CLÍNICO

5.8.1 Definição do problema

O prognóstico de pacientes em coma é um aspecto fundamental dos cuidados neurocríticos, influenciando diretamente a tomada de decisões médicas, o aconselhamento familiar e a alocação de recursos de saúde. A avaliação prognóstica busca determinar se o paciente recuperará a consciência (desfecho favorável) ou permanecerá em estado vegetativo persistente, ou ainda evoluirá para óbito (desfecho

desfavorável). Dentre as diversas ferramentas disponíveis para essa avaliação, a eletroencefalografia (EEG) destaca-se como um biomarcador essencial na predição de desfechos (WESTHALL *et al.*, 2016), fornecendo informações em tempo real sobre a função cerebral e o potencial de recuperação.

Os métodos prognósticos tradicionais baseiam-se em escores clínicos, reflexos do tronco encefálico e potenciais evocados somatossensoriais (SSEPs). No entanto, essas abordagens podem apresentar baixa sensibilidade em determinadas populações de pacientes (RUIJTER *et al.*, 2019). A análise do EEG oferece uma avaliação mais dinâmica da atividade cerebral, permitindo a detecção de padrões como reatividade a estímulos, supressão em surtos (*burst suppression*) e a presença de oscilações patológicas, fortemente correlacionadas à recuperação neurológica (SANDRONI *et al.*, 2020). Entretanto, a interpretação precisa e automatizada dos dados de EEG ainda constitui um desafio, dado que a atividade cerebral em pacientes comatosos é altamente complexa e varia significativamente ao longo do tempo.

Diante desse cenário, este trabalho propõe a utilização de técnicas de inteligência artificial para prever o prognóstico clínico dos pacientes, classificando-os em desfechos favoráveis ou desfavoráveis a partir dos exames de EEG. Essa abordagem visa aprimorar a acurácia e a objetividade na avaliação prognóstica, contribuindo para a tomada de decisões clínicas mais informadas e para a melhoria do manejo dos pacientes em coma.

5.8.2 Base de dados

A base de dados utilizada neste estudo foi coletada no Hospital de Clínicas da Universidade Federal de Uberlândia (HC-UFU) entre os anos de 2010 e 2020, especificamente na UTI Adulto, com aprovação do Comitê de Ética em Pesquisa da instituição (protocolo de pesquisa número 369/11 (**ANEXO A**) e 2.570.022 (**ANEXO B**)) (RAMOS, 2017) (RAMOS *et al.*, 2018).

Os registros de EEG foram obtidos utilizando o amplificador de sinais biológicos BrainNet BNT-EEG, que conta com 21 canais, sendo 20 dedicados à aquisição digital de sinais EEG e um canal adicional para registro de ECG, seguindo o padrão internacional de posicionamento de eletrodos 10-20. Foram aplicados filtros

passa-alta de 1 Hz e passa-baixa de 35 Hz, e taxas de amostragem iguais 100 Hz (35 exames), 200 Hz (16 exames), 400 Hz (7 exames) e 600 Hz (2 exames).

Para garantir a qualidade e a relevância dos dados, foram estabelecidos critérios de inclusão, que são listados a seguir:

- Apenas pacientes em estado de coma;
- Com idade igual ou superior a 18 anos,
- Escala de coma se aplicável, não deve ser superior a oito pontos;
- Os exames devem ter duração mínima de 20 minutos;
- Ser clinicamente viáveis, conforme avaliação de um neurologista especializado;
- Durante as aquisições, os pacientes não terem sido submetidos a estímulos externos;
- Cada registro deveria conter pelo menos dez épocas/segmentos de dois segundos livres de artefatos visuais, selecionadas por neurologistas especializado;
- No máximo três eletrodos poderiam ser considerados inadequados para o processamento, conforme apontado pelo neurologista ou devido a questões de sinal ruído de 60 Hz;
- A coleta do sinal de EEG deve utilizar um amplificador compatível com o formato empregado na pesquisa;
- Deve conter informações do paciente, como, número do prontuário médico, data da coleta, motivo da solicitação, sexo, idade, nível de consciência, etiologia do coma, e prognóstico (favorável ou desfavorável).

Para cada paciente, um neurologista selecionou 10 épocas/segmentos de 2 segundos dos registros de EEG, priorizando segmentos com o menor número possível de artefatos e representativos da condição neurológica do indivíduo. O conjunto de dados também inclui metadados clínicos relevantes, como etiologia do coma, idade, sexo e desfecho clínico, classificado como favorável (sobreviventes) ou desfavorável (óbitos).

A idade média dos pacientes foi de $49,16 \pm 19,18$ anos, sendo 44 do sexo masculino e 16 do sexo feminino. Para fins de treinamento dos modelos, foram consideradas apenas as nove primeiras épocas/segmentos de cada exame, de modo

a evitar viés na validação, sendo a predição final do paciente determinada pela moda das classificações dessas épocas/segmentos sendo FAVORÁVEL ou DESFAVORÁVEL.

Devido à heterogeneidade das frequências de amostragem presentes no conjunto de dados e às limitações de alguns modelos da literatura que não suportam taxas variáveis, os sinais e alguns treinamentos foram reamostrados para uma frequência padrão de 400 Hz. Para sinais com taxas inferiores, novas amostras foram geradas por interpolação; para sinais com taxas superiores, as amostras foram reduzidas (*downsampled*) para adequação à frequência alvo.

Esses procedimentos asseguraram a padronização e a qualidade dos dados, tornando-os adequados para a análise e o desenvolvimento dos modelos de classificação de EEG em pacientes com coma.

5.8.3 Resultados

Os resultados dos modelos treinados seguem descritos detalhadamente no **APÊNDICE I**.

5.8.4 Discussão

A análise dos modelos de inteligência artificial para o prognóstico de morte com base em sinais de EEG, apresentada no **APÊNDICE I**, revela variações significativas de desempenho entre diferentes abordagens, destacando a relevância da escolha do modelo e de sua configuração para otimizar as métricas como acurácia, F1 score, precisão, entre outras. Os modelos baseados em MCL (com camadas de CNN e LSTM), superam consistentemente os modelos MMLP (*Multilayer Perceptron*), especialmente quando o sinal não é reamostrado (SREA). Esses resultados evidenciam a capacidade superior da arquitetura MCL em capturar padrões temporais e espaciais complexos nos dados eletrofisiológicos, conforme destacado na Tabela 8 que mostra os modelos que apresentaram os melhores resultados, e na Figura 46 pode-se visualizar o comportamento das métricas dos modelos em termos de cada *fold* de treinamento.

Tabela 8 - Resultados do treinamento da base de dados Prognóstico Clínico com os melhores resultados, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CP SREA	0.87±0.04	0.86±0.04	0.92±0.10	0.83±0.15	0.87±0.04	533
MCL CC	0.88±0.09	0.88±0.09	0.97±0.06	0.80±0.19	0.88±0.09	1055
MCL CPEC	0.87±0.09	0.87±0.09	0.88±0.10	0.87±0.13	0.87±0.09	671
MCL CE Conv1D (64/128, kernel 5/3, para 128/256, kernel 3/7)	0.75±0.11	0.75±0.10	0.80±0.18	0.73±0.13	0.75±0.11	859
ERTNET (LIU <i>et al.</i> , 2024)	0.73±0.18	0.73±0.18	0.76±0.22	0.77±0.17	0.73±0.18	284

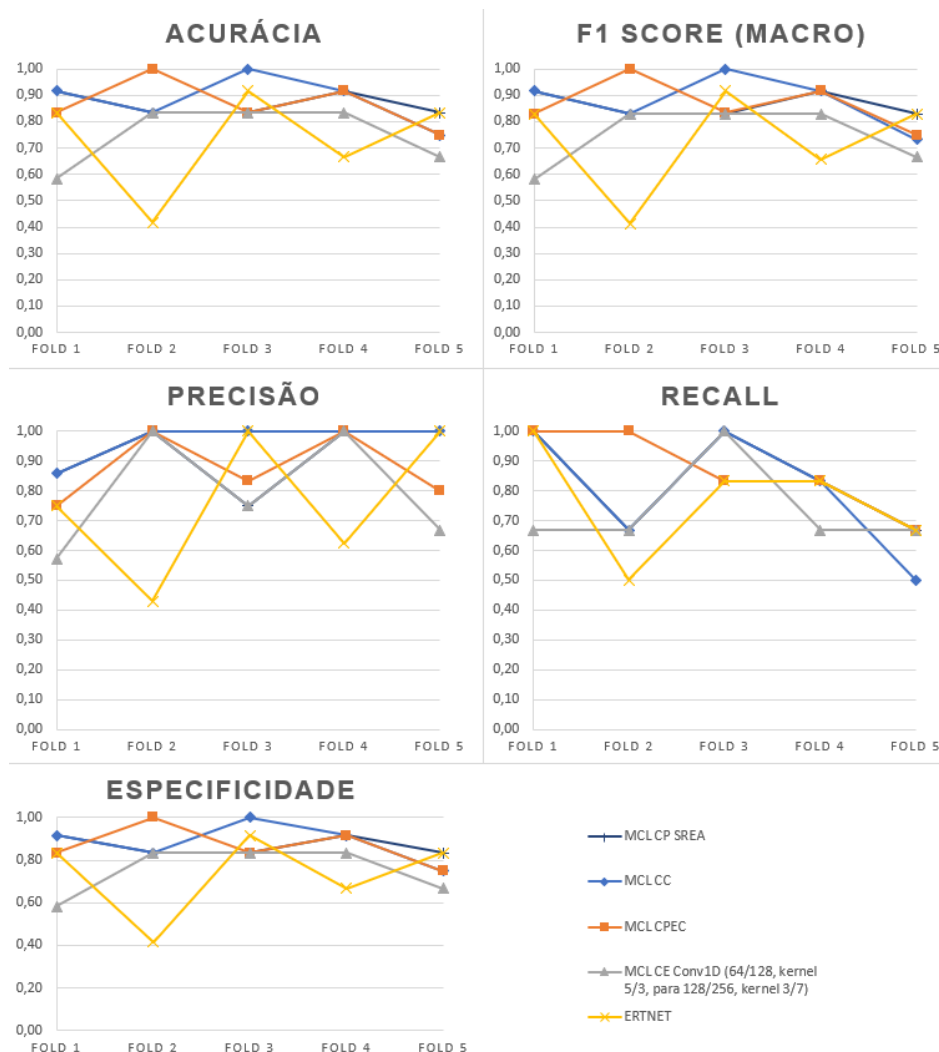


Figura 35 - Evolução de cada FOLD do treinamento da base de dados Prognóstico Clínico com os melhores resultados

O modelo CNN-LSTM com características de coerência (MCL CC), apresenta o melhor desempenho geral, com um F1 score (macro) de $0,88 \pm 0,09$ e precisão de $0,97 \pm 0,06$, embora exija um tempo de treinamento elevado (1055 segundos). Esses resultados indicam um trade-off entre desempenho preditivo e eficiência computacional, sugerindo que a inclusão do quantificador de coerência, calculado em tempo de execução, pode comprometer marginalmente a eficiência em comparação ao modelo *Multi Layer Perceptron* com características do paciente sem reamostragem do sinal (MMLP CP SREA) (**APÊNDICE I - Tabela 15**), que, apesar de ser o mais rápido, com treinamento de apenas 72 segundos, apresenta métricas inferiores, com acurácia de $0,67 \pm 0,09$. Essa relação ressalta a importância do equilíbrio entre precisão e eficiência computacional no contexto clínico.

A incorporação da *wavelet Daubechies 4* (Db4) (**APÊNDICE I - Tabela 18**), no modelo MCL CDW4, que apresentou acurácia de 0.75 ± 0.11 , evidencia a importância de utilizar *wavelets* para extrair características temporais e frequenciais em sinais EEG, especialmente devido à natureza não estacionária desses sinais. Em contraste, modelos baseados em arquiteturas mais complexas, como ResNet50 e EfficientNet (**APÊNDICE I - Tabela 19**) apresentaram desempenho inferior (acurácia de 0.45 ± 0.10 e 0.43 ± 0.24 , respectivamente), além de demandarem maior tempo de treinamento, indicando que a complexidade arquitetural nem sempre se traduz em melhor desempenho para essa tarefa específica.

A utilização de subconjuntos específicos de canais eletroencefalográficos, correspondentes a regiões cerebrais delimitadas, promove elevado desempenho preditivo e reduz significativamente a quantidade de dados processados, acelerando o treinamento dos modelos. Por exemplo, o modelo MCL CPEC, focado na região central, alcança acurácia de $0,87 \pm 0,09$ com tempo de treinamento de 671 segundos, em contraste com o modelo MCL CC, que utiliza todos os canais e obtém acurácia de $0,88 \pm 0,09$, mas exige 1055 segundos. Essa redução na dimensionalidade dos dados diminui a complexidade computacional, permitindo a análise de padrões eletrofisiológicos específicos de áreas cerebrais relevantes para o prognóstico, sem interferências de ruídos ou informações redundantes. Assim, a regionalização dos canais otimiza o equilíbrio entre precisão e eficiência, essencial para aplicações clínicas em tempo real.

5.9 TRANSFORMER E PROGNÓSTICO CLÍNICO

5.9.1 Definição do problema

O problema abordado nesta seção é o mesmo descrito na Seção **5.8 Prognóstico Clínico**, que consiste em prever o desfecho clínico (favorável ou desfavorável) de pacientes em coma a partir da classificação dos sinais de EEG. Entretanto, nesta etapa, adota-se uma abordagem diferenciada, empregando o modelo *Transformer* para explorar sua capacidade baseada em atenção de capturar padrões complexos nos sinais de EEG, visando aprimorar a precisão do prognóstico.

5.9.2 Base de dados

A base de dados utilizada nesta seção é a mesma apresentada em **5.8 Prognóstico Clínico**, que contém sinais de EEG de pacientes em coma.

5.9.3 Descrição do Modelo

Os Transformers têm demonstrado potencial significativo em aplicações de séries temporais e biomédicas devido à sua capacidade de capturar dependências de longo alcance e padrões espaço-temporais complexos.

Nesse contexto, foram propostas três arquiteturas:

1. **MT** (*Modelo Transformer*), baseada exclusivamente em camadas de *Transformer*, variando apenas o número de camadas;
2. Modelo *Transformer* com Características adicionais, idêntica ao MT, porém com a adição de características extras (e.g., idade, sexo, métricas estatísticas do sinal) antes da camada densa de classificação;
3. **MCT** (*Modelo CNN-Transformer*), composta por camadas convolucionais (CNN) seguidas de camadas de *Transformer*, sendo estruturalmente semelhante à arquitetura MCL.

A primeira arquitetura (MT), conforme ilustrada na Figura 36, estrutura-se em quatro componentes principais:

- **Registro de EEG:** Esta etapa consiste na conexão dos eletrodos ao couro cabeludo do paciente, registrando o sinal de EEG por meio de um dispositivo apropriado, conforme descrito anteriormente;
- **Seleção de segmentos e preparação dos dados:** Nessa fase, um neurologista analisa o registro de EEG e seleciona 10 segmentos de 2 segundos cada, garantindo mínima presença de artefatos e representatividade da condição neurológica do paciente;
- **Arquitetura baseada em *Transformer*:** construído com base no *TransformerEncoder*, composto por múltiplos mecanismos de *Self-Attention*, camadas *Feed-Forward* e camadas de normalização. Esse esquema permite a modelagem eficiente de dependências espaço-temporais nos sinais de EEG. Para avaliar o desempenho, foram realizados diversos treinamentos com ajustes em diferentes hiperparâmetros, como número de camadas de *TransformerEncoder*, quantidade de cabeças de atenção, dimensão da camada intermediária, taxa de *dropout* e número de épocas de treinamento;
- **Classificador:** A etapa de classificação consiste em uma camada de *GlobalAveragePooling* para redução da dimensionalidade dos dados, seguida de uma camada densa que realiza a classificação. Ao final, o modelo gera um vetor indicando as probabilidades de cada rótulo.

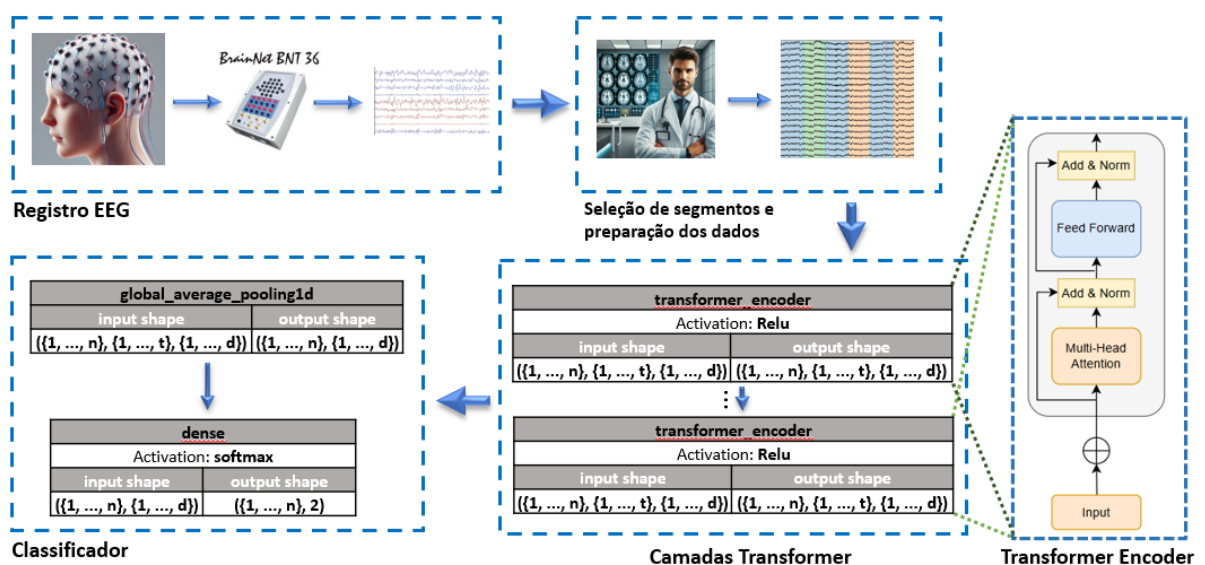


Figura 36 - Arquitetura IA (Modelo *Transformer* MT) utilizando *Transformers* através de sinais de EEG como entrada para camadas de *TransformerEncoder*

Para modelar a correlação entre os sinais de EEG e a classificação, o modelo proposto aprende representações latentes dos sinais ao capturar dependências temporais e espaciais. O conjunto de registros $X_j^{(e,w)}(s)$ é representado como uma sequência temporal multidimensional, na qual cada eletrodo é tratado como um canal independente. Essa sequência é processada diretamente por um bloco *TransformerEncoder*, que captura dependências de longo alcance entre os sinais ao longo do tempo e entre diferentes eletrodos, dispensando operações locais como convoluções. As camadas de saída do *TransformerEncoder* são calculadas conforme a Equação 10:

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_n)W^0 \quad (10)$$

Onde n denota o número de cabeças de atenção e $W^0 \in \mathbb{R}^{h \times d_v \times d_{model}}$. No qual cada cabeça de atenção é calculada de acordo com a Equação 11:

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V) \quad (11)$$

As matrizes de projeção são parametrizadas como $W_i^Q \in \mathbb{R}^{d_{model} \times d_k}$, $W_i^K \in \mathbb{R}^{d_{model} \times d_k}$, e $W_i^V \in \mathbb{R}^{d_{model} \times d_v}$. O próprio mecanismo de *self-attention* é definido pela Equação 12:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (12)$$

Onde Q (*queries/consultas*), K (*keys/chaves*) e V (*values/valores*) são representações do sinal de entrada, e d_k é a dimensão das chaves. A normalização por $\sqrt{d_k}$ melhora a estabilidade dos gradientes durante o treinamento.

Em resumo, o modelo processa uma matriz de entrada tridimensional de formato $(j \times w, s, e)$, em que j é o número de pacientes, w o número de segmentos por paciente, s o número de amostras por segmento e e o número de canais de EEG (eletrodos). Cada amostra na dimensão temporal atua como um *token* no contexto do *TransformerEncoder*, formando uma sequência de s tokens para cada segmento.

O módulo *TransformerEncoder* analisa esses *tokens* e emprega o mecanismo de atenção *MultiHead* com $d_{model} = e$. Essa dimensão é dividida entre N_H cabeças de atenção, cada uma operando em um subespaço de dimensão $d_k = d_v = \left\lfloor \frac{e}{N_H} \right\rfloor$,

considerando somente a parte inteira da divisão. Por meio desse mecanismo, o modelo captura relações temporais e espaciais, permitindo enfatizar as características mais relevantes, preservando o formato original da entrada ($j \times w, s, e$). Posteriormente, aplica-se o *globalAveragePooling* na dimensão temporal, reduzindo cada segmento a uma matriz de formato ($j \times w, e$). Por fim, uma camada densa transforma essa representação em uma matriz de saída de formato ($j \times w, Y$), onde Y representa a quantidade de categorias, fornecendo assim as probabilidades previstas para cada segmento pertencer às categorias da classificação.

A segunda arquitetura, denominada Modelo *Transformer* com características adicionais, conforme ilustrado na Figura 37, é bastante semelhante ao modelo MT. A principal diferença consiste na incorporação de informações extras, como idade, sexo e métricas estatísticas do sinal, que são adicionadas antes da camada densa de classificação, com o objetivo de aprimorar os resultados da classificação.

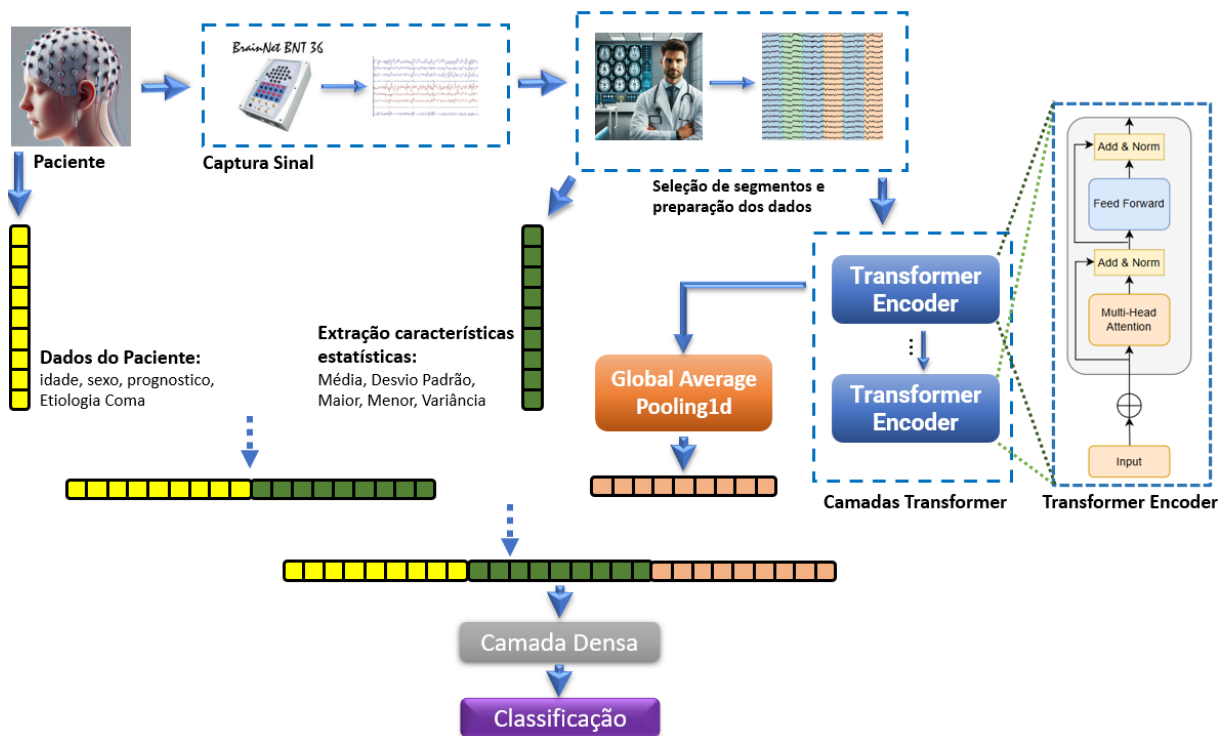


Figura 37 - Arquitetura IA (Modelo *Transformer* MT) utilizando Transformers através de sinais de EEG como entrada para camadas de *TransformerEncoder*, com as características extras adicionadas na camada densa

Por fim, a terceira arquitetura, denominada Modelo CNN-*Transformer* (MCT), também segue o mesmo design do Modelo *Transformer* com características adicionais. A única diferença é que, antes das camadas de *TransformerEncoder*, é inserida uma camada convolucional (CNN), conforme ilustrado na Figura 29. Essa

variação da arquitetura visa aprimorar o desempenho do modelo, buscando a melhor configuração possível para a tarefa.

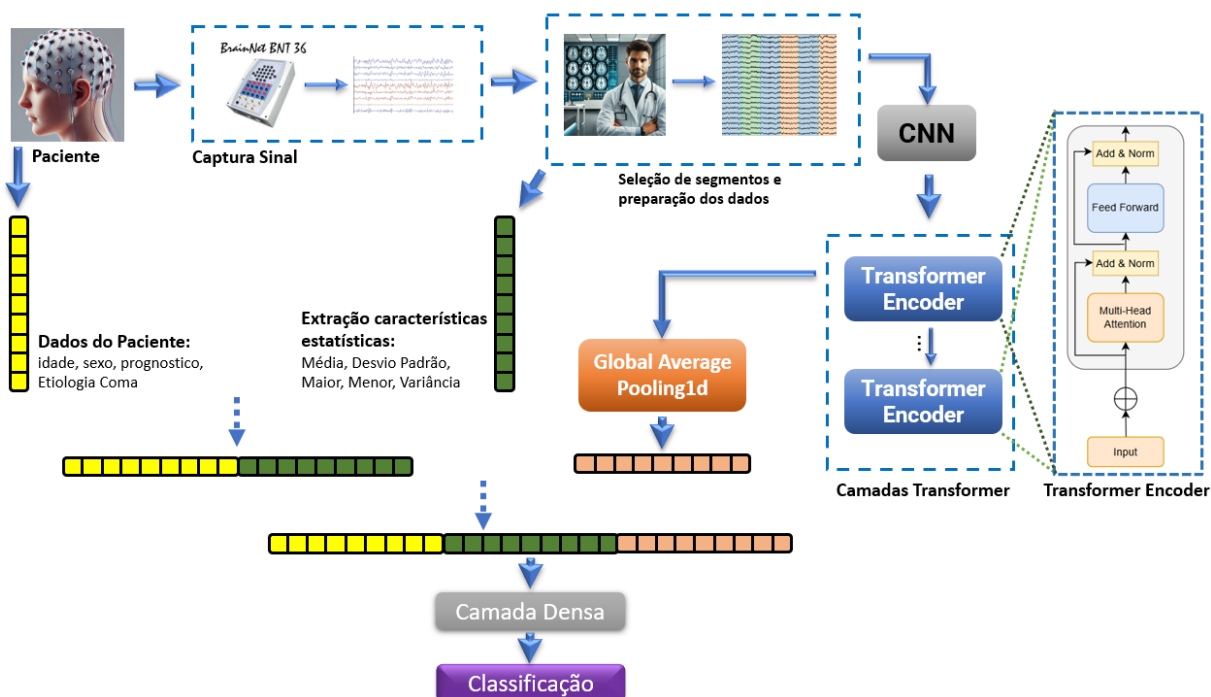


Figura 38 - Arquitetura IA (Modelo CNN-Transformer MCT) utilizando CNN e Transformers através de sinais de EEG como entrada para o CNN seguido das camadas de TransformerEncoder, com as características extras adicionadas na camada densa

Para utilizar o *Transformer* na infraestrutura existente, foi necessário realizar o *downgrade* do *Python* da versão 3.12 para 3.11, devido à incompatibilidade da biblioteca *TensorFlow Text* com a versão mais recente (3.12). Além disso, o processamento via CUDA (GPU) foi desabilitado porque as operações de gradiente do *MaxPool* não possuem implementação determinística com XLA (*Accelerated Linear Algebra*) quando usadas em arquiteturas CNN e *Transformer*.

Para melhor compreensão das tabelas de resultados, observe a legenda a seguir (Tabela 9):

Tabela 9 - Legenda para os hiperparâmetros do modelo *Transformer*

Nome Coluna	Descrição
N_L	Número de camadas (<i>layers</i>) de <i>Transformer</i>
INT_D	Dimensão da camada intermediária do <i>Transformer</i>
DOUT	<i>Dropout</i> do <i>Transformer</i>
N_H	Número de cabeças do <i>Transformer</i>
EPC	Número de épocas utilizadas no treinamento

5.9.4 Resultados

Os resultados dos modelos treinados seguem descritos detalhadamente no **APÊNDICE J**.

5.9.5 Discussão

Com base nas diversas configurações de treinamento avaliadas, esta seção discute os principais resultados obtidos com as arquiteturas baseadas em *TransformerEncoder*. A Tabela 10 apresenta uma síntese dos melhores desempenhos alcançados, destacando as combinações de hiperparâmetros que maximizam as métricas de desempenho. A análise detalhada desses resultados permite compreender como os hiperparâmetros de número de camadas (N_L), dimensão intermediária (INT_D), dropout ($DOUT$), número de cabeças de atenção (N_H), e quantidade de épocas de treinamento (EPC) influenciam o desempenho dos modelos, oferecendo insights para otimização futura e aplicações práticas. O comportamento das métricas dos modelos por *fold* de treinamento é visualizado na Figura 39 e Figura 40.

Tabela 10 - Resultado Prognostico Clinico usando Transformers variando os hiperparâmetros com os melhores resultados, em negrito se destaca o melhor modelo para MT e MCT

Modelo	N_H	INT_D	N_L	$DOUT$	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT	8	32	3	0.05	30	0.78±0.07	0.78±0.07	0.83±0.14	0.77±0.13	0.78±0.07	1284
MCT CP	8	32	3	0.1	30	0.80±0.10	0.80±0.10	0.82±0.10	0.77±0.17	0.80±0.10	1349
MCT CE	8	64	1	0.1	30	0.77±0.14	0.77±0.14	0.76±0.14	0.80±0.16	0.77±0.14	863
MCT CPCP	4	64	3	0.1	30	0.78±0.11	0.78±0.11	0.80±0.13	0.77±0.13	0.78±0.11	1976
MCT CFM	8	128	3	0.05	30	0.80±0.07	0.80±0.07	0.83±0.09	0.77±0.08	0.80±0.07	2014
MCT CC	4	64	1	0.1	30	0.87±0.09	0.86±0.09	0.95±0.10	0.80±0.19	0.87±0.09	1281
MCT CPE	4	256	3	0.05	30	0.78±0.09	0.78±0.09	0.76±0.07	0.83±0.11	0.78±0.09	1217
MCT CPPCP	8	256	3	0.05	30	0.83±0.05	0.83±0.05	0.83±0.02	0.83±0.11	0.83±0.05	1878
MCT CPFM SREA	4	128	3	0.05	30	0.87±0.04	0.87±0.04	0.94±0.08	0.80±0.13	0.87±0.04	736
MCT CPC	4	32	3	0.1	30	0.90±0.06	0.90±0.06	0.97±0.06	0.83±0.15	0.90±0.06	1526
MT	8	64	3	0.1	30	0.88±0.09	0.88±0.09	0.97±0.06	0.80±0.19	0.88±0.09	503
MT CP	4	256	3	0.05	30	0.87±0.07	0.87±0.07	0.96±0.08	0.77±0.08	0.87±0.07	426

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MT CE	8	256	3	0.05	30	0.85±0.10	0.84±0.10	0.93±0.13	0.80±0.19	0.85±0.10	685
MT CPCP	8	256	3	0.05	30	0.87±0.04	0.86±0.04	0.95±0.10	0.80±0.13	0.87±0.04	1000
MT CFM	8	256	3	0.05	30	0.83±0.05	0.83±0.05	0.96±0.08	0.70±0.07	0.83±0.05	950
MT CC	4	256	1	0.1	30	0.87±0.11	0.86±0.12	0.92±0.10	0.80±0.19	0.87±0.11	632
MT CPE	4	128	3	0.05	30	0.85±0.06	0.85±0.07	0.97±0.07	0.73±0.13	0.85±0.06	413
MT CPPCP	8	64	3	0.1	30	0.83±0.08	0.83±0.08	0.93±0.13	0.77±0.17	0.83±0.08	1046
MT CPFM SPV	4	64	3	0.1	30	0.83±0.09	0.83±0.10	0.89±0.10	0.77±0.17	0.83±0.09	2626
MT CPC	8	32	3	0.05	30	0.87±0.04	0.87±0.04	0.91±0.07	0.83±0.15	0.87±0.04	1161

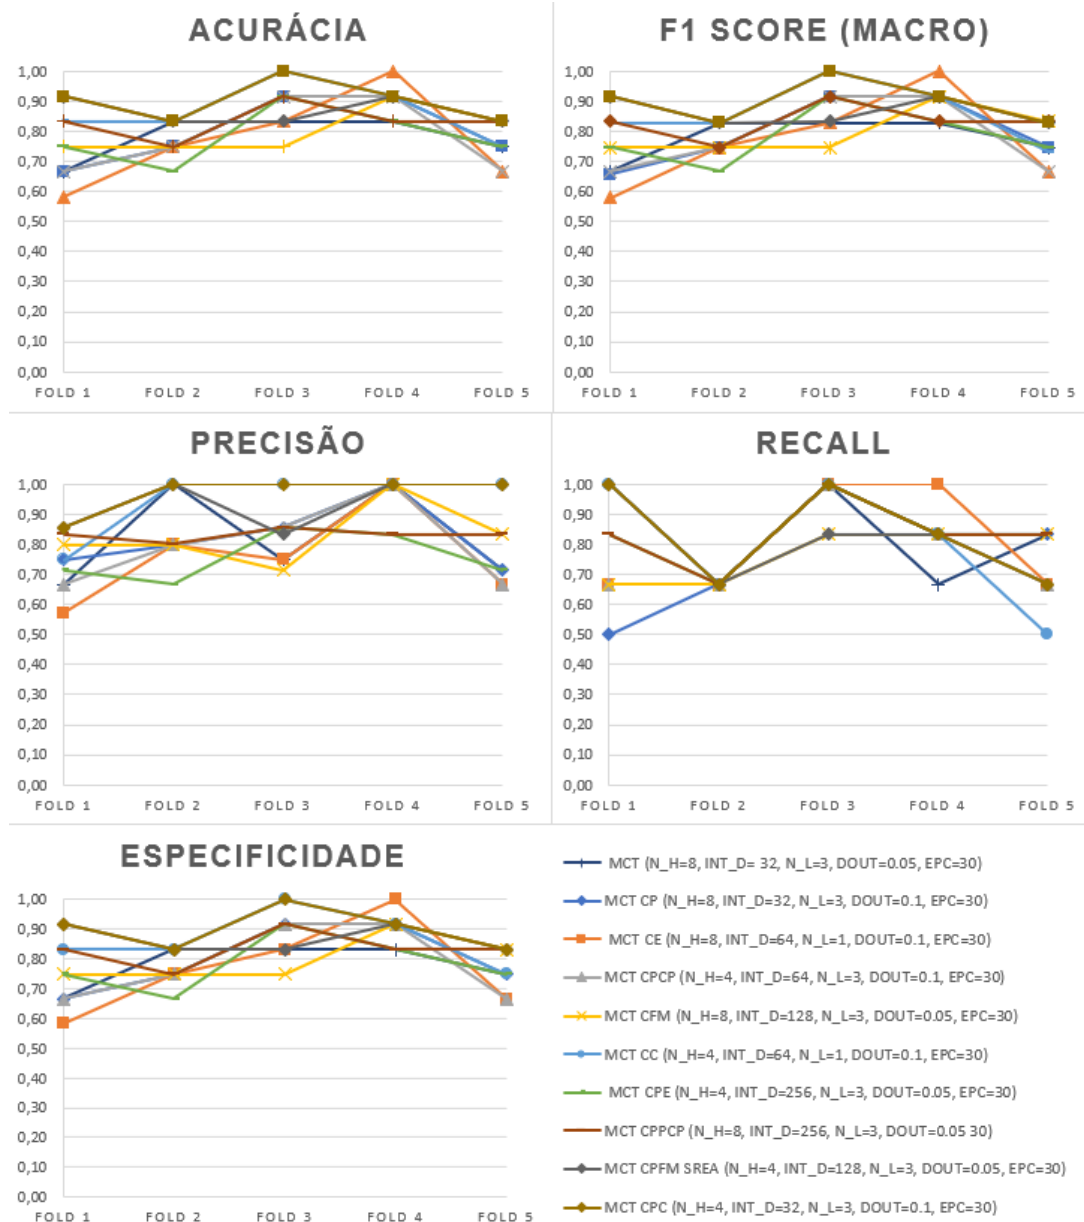


Figura 39 - Evolução de cada FOLD do treinamento da base de dados Prognóstico Clínico MCT com os melhores resultados

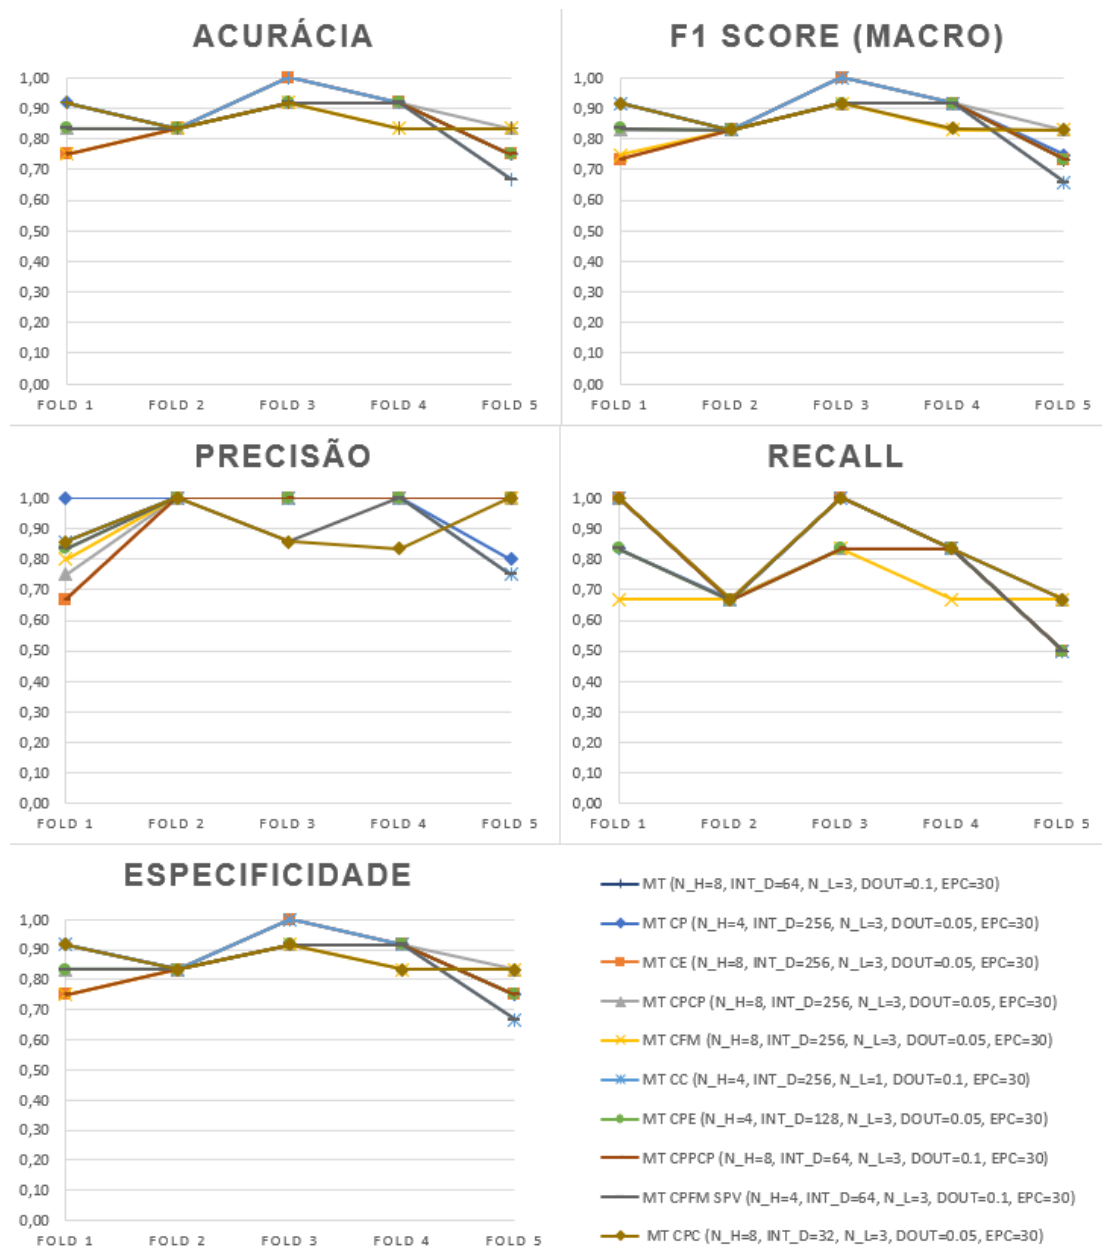


Figura 40 - Evolução de cada *FOLD* do treinamento da base de dados Prognóstico Clínico MT com os melhores resultados

Os modelos MCT e MT demonstraram desempenhos distintos dependendo das características processadas e configurações de hiperparâmetros. O modelo *CNN-Transformer* com características de paciente e coerência (MCT CPC) ($N_H = 4, INT_D = 32, N_L = 3, DOUT = 0,1, EPC = 30$) destacou-se como o modelo mais preciso, alcançando 0,90 de acurácia (com precisão de 0,97), porém com tempo de treinamento elevado (1526 segundos). Em contrapartida, o modelo *Transformer* (MT) padrão (sem características adicionais) obteve 0,88 de acurácia em apenas 503 segundos, evidenciando sua eficiência computacional.

Configurações com $N_L = 3$ e $INT_D \leq 128$ tendem a otimizar o desempenho, enquanto $N_H = 8$ não melhora consistentemente os resultados em comparação com $N_H = 4$. Nota-se que os modelos MCT tendem a exigir mais recursos computacionais para resultados comparáveis. Isso indica que, embora arquiteturas mais complexas (MCT) possam alcançar picos de precisão, as versões otimizadas (MT) oferecem um melhor custo-benefício para aplicações práticas.

Para analisar a dimensionalidade e a natureza esparsa dos dados de EEG, utilizou-se a técnica de visualização t-SNE (*t-distributed Stochastic Neighbor Embedding*), que reduz dados de alta dimensão para representações bidimensionais, preservando as relações de proximidade entre os pontos (VAN DER MAATEN; HINTON, 2008). Inicialmente, os dados brutos do sinal EEG associados ao melhor resultado MT foram visualizados com t-SNE (Figura 41), fornecendo uma percepção da distribuição original dos dados. Em seguida, aplicou-se a mesma técnica para visualizar a versão latente dos dados após a passagem pelas camadas do *TransformerEncoder* em cada *Fold*, evidenciando como o modelo promoveu uma segregação mais clara dos padrões, destacando seu papel na melhoria da separabilidade e representatividade dos dados para a tarefa de classificação. Essa evolução na distribuição dos dados pode ser visualizada na Figura 41, Figura 42 e Figura 43.




Figura 41 - Visualização t-SNE dos dados brutos do EEG e a visão latente após a aplicação das camadas de *TransformerEncoder* do melhor resultado do Modelo MT ($N_H = 8$, $INT_D = 64$, $N_L = 3$, $DOUT = 0,1$ e $EPC = 30$) para o primeiro *Fold*




Figura 42 - Visualização t-SNE latente após a aplicação das camadas de *TransformerEncoder* do melhor resultado do Modelo MT ($N_H = 8$, $INT_D = 64$, $N_L = 3$, $DOUT = 0, 1$ e $EPC = 30$) para o segundo e terceiro *Fold*




Figura 43 - Visualização t-SNE latente após a aplicação das camadas de *TransformerEncoder* do melhor resultado do Modelo MT ($N_H = 8$, $INT_D = 64$, $N_L = 3$, $DOUT = 0, 1$ e $EPC = 30$) para o quarto e quinto *Fold*

Os achados, consolidados na Tabela 10, Figura 41, Figura 42 e Figura 43, sugerem que a arquitetura *Transformer* é robusta para o prognóstico clínico com EEG, mas requer otimização cuidadosa de hiperparâmetros e seleção de características para atender às demandas clínicas.

5.10 ETIOLOGIA DO COMA

5.10.1 Definição do problema

A etiologia do coma abrange uma ampla variedade de condições subjacentes, tornando-se um desafio clínico significativo nos cuidados neurocríticos. Compreender as causas do coma é fundamental para um diagnóstico preciso, definição do tratamento adequado e comunicação eficaz com familiares dos pacientes. Entre os fatores etiológicos mais comuns estão o traumatismo cranioencefálico, desequilíbrios metabólicos, infecções do sistema nervoso central e lesões estruturais, como acidente vascular cerebral (AVC) ou tumores. Estudos recentes apontam o traumatismo cranioencefálico como uma das principais causas, seguido por AVC isquêmico e hemorragia intracerebral (MAHAJAN *et al.*, 2024).

No contexto brasileiro, é frequente que pacientes cheguem às unidades de emergência em coma sem identificação ou informações sobre a possível origem do quadro, como histórico de trauma recente, o que intensifica a necessidade de métodos diagnósticos que auxiliem o corpo clínico na identificação da causa primária, pois fundamenta a avaliação prognóstica e o desenvolvimento de intervenções terapêuticas direcionadas.

Os métodos tradicionais de diagnósticos em neurocríticos, como escores clínicos, avaliação de reflexos do tronco encefálico e potenciais evocados somatossensoriais (SSEPs), têm sido amplamente utilizados para investigar as causas do coma. Contudo, essas abordagens frequentemente carecem de sensibilidade e especificidade, especialmente em populações heterogêneas de pacientes (WARTENBERG *et al.*, 2019). A análise do EEG tem se destacado como uma ferramenta valiosa, oferecendo uma avaliação dinâmica e não invasiva da atividade cerebral.

Avanços recentes em aprendizado de máquina potencializaram a análise de EEG, permitindo a detecção de padrões sutis e complexos anteriormente negligenciados (NASCIMENTO JUNIOR *et al.*, 2025). Apesar dessas inovações, desafios importantes persistem para a interpretação automatizada e precisa dos dados de EEG, uma vez que a atividade cerebral em pacientes comatosos é altamente

variável e influenciada por múltiplos fatores, incluindo o momento da avaliação e a etiologia subjacente do coma.

Dessa forma, este estudo propõe a classificação da etiologia do coma a partir dos exames de EEG de pacientes em estado comatoso, considerando categorias como traumatismo cranioencefálico, coma metabólico, acidente vascular cerebral e outras. O objetivo é identificar a causa raiz do quadro clínico, contribuindo para o direcionamento mais eficaz do tratamento.

5.10.2 Base de dados

A base de dados utilizada nesta seção é a mesma apresentada em **5.8 Prognóstico Clínico**, que contém sinais de EEG de pacientes em coma.

Porém vale destacar a distribuição da etiologia do coma da base dados conforme a Tabela 11.

Tabela 11 - Distribuição da base dados em coma em termos de etiologia e desfecho clínico

Etiologia	Quantidade Pacientes	Desfecho		Rotulo	Total
		Favorável	Desfavorável		
Traumatismo Cranioencefálico	20	17	3	TCE	20
Coma Metabólico	18	5	13	CM	18
Acidente Vascular Cerebral	12	5	7	AVC	12
Encefalopatia pós anóxica	2	2	0	Outros	10
Neoplasia	2	0	2		
Distúrbios Hidroeletrolíticos	1	1	0		
Ferimento por arma de fogo	1	0	1		
Hematoma subdural crônico	1	0	1		
Hidrocefalia	1	0	1		
Encefalopatia hipóxica	1	0	1		
Neurocisticercose	1	0	1		
Total	60	30	30	-	60

5.10.3 Resultados

Os resultados dos modelos de inteligência artificial voltados para a classificação da etiologia do coma seguem descritos detalhadamente no **APÊNDICE K**, **APÊNDICE L**, **APÊNDICE M** e **APÊNDICE N**.

5.10.4 Discussão

Com base nos resultados apresentados na Tabela 12, esta seção discute a classificação da etiologia do coma utilizando diferentes configurações de modelos baseados em aprendizado profundo. Observa-se que o modelo CNN-LSTM com características do paciente e eletrodos frontais (MCL CPEF) alcançou a melhor acurácia ($0,63 \pm 0,14$) e F1 score (macro) ($0,59 \pm 0,16$), indicando maior capacidade de discriminação entre as diferentes causas do coma. Por outro lado, modelos como CNN-*Transformer* com características dos eletrodos temporais (MCT CET) ou com características do paciente e Frequência Mediana (MCT CPMF) apresentaram desempenho inferior, evidenciando as dificuldades inerentes à classificação etiológica nessa base de dados.

A análise dos hiperparâmetros, como número de cabeças de atenção, dimensão intermediária e taxa de *dropout*, demonstra sua influência significativa nos resultados, reforçando a importância do ajuste fino desses parâmetros para otimizar o desempenho. Além disso, os tempos de treinamento variaram consideravelmente entre os modelos, o que ressalta a necessidade de equilíbrio entre eficiência computacional e acurácia para aplicações clínicas práticas. Esses achados fornecem subsídios importantes para o desenvolvimento de sistemas assistivos que possam auxiliar no diagnóstico etiológico do coma.

Tabela 12 - Resultados do treinamento da base de dados Etiologia do Coma, melhores resultados, em negrito se destaca o melhor modelo

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CP						0.60±0.11	0.53±0.13	0.58±0.17	0.56±0.10	0.86±0.03	787
MCL CPMF						0.53±0.13	0.46±0.10	0.47±0.11	0.49±0.12	0.84±0.04	968
MCL CPEF						0.63±0.14	0.59±0.16	0.65±0.21	0.62±0.14	0.87±0.04	813
MCLT CPEF	4	64	1	0.1	30	0.58±0.15	0.56±0.17	0.62±0.20	0.57±0.17	0.86±0.05	871

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CPE	8	256	3	0.05	30	0.57±0.12	0.49±0.14	0.49±0.17	0.53±0.13	0.85±0.04	1758
MCT CPFM	8	256	3	0.05	30	0.52±0.14	0.44±0.07	0.45±0.06	0.47±0.12	0.83±0.05	1933
MCT CET	3	128	3	0.2	60	0.47±0.04	0.39±0.09	0.46±0.11	0.41±0.06	0.82±0.02	2333

Complementarmente, a Figura 44 apresenta o comportamento das métricas dos modelos com os melhores resultados em cada *fold* durante o treinamento, permitindo uma análise detalhada da consistência e variação do desempenho ao longo das diferentes divisões dos dados.

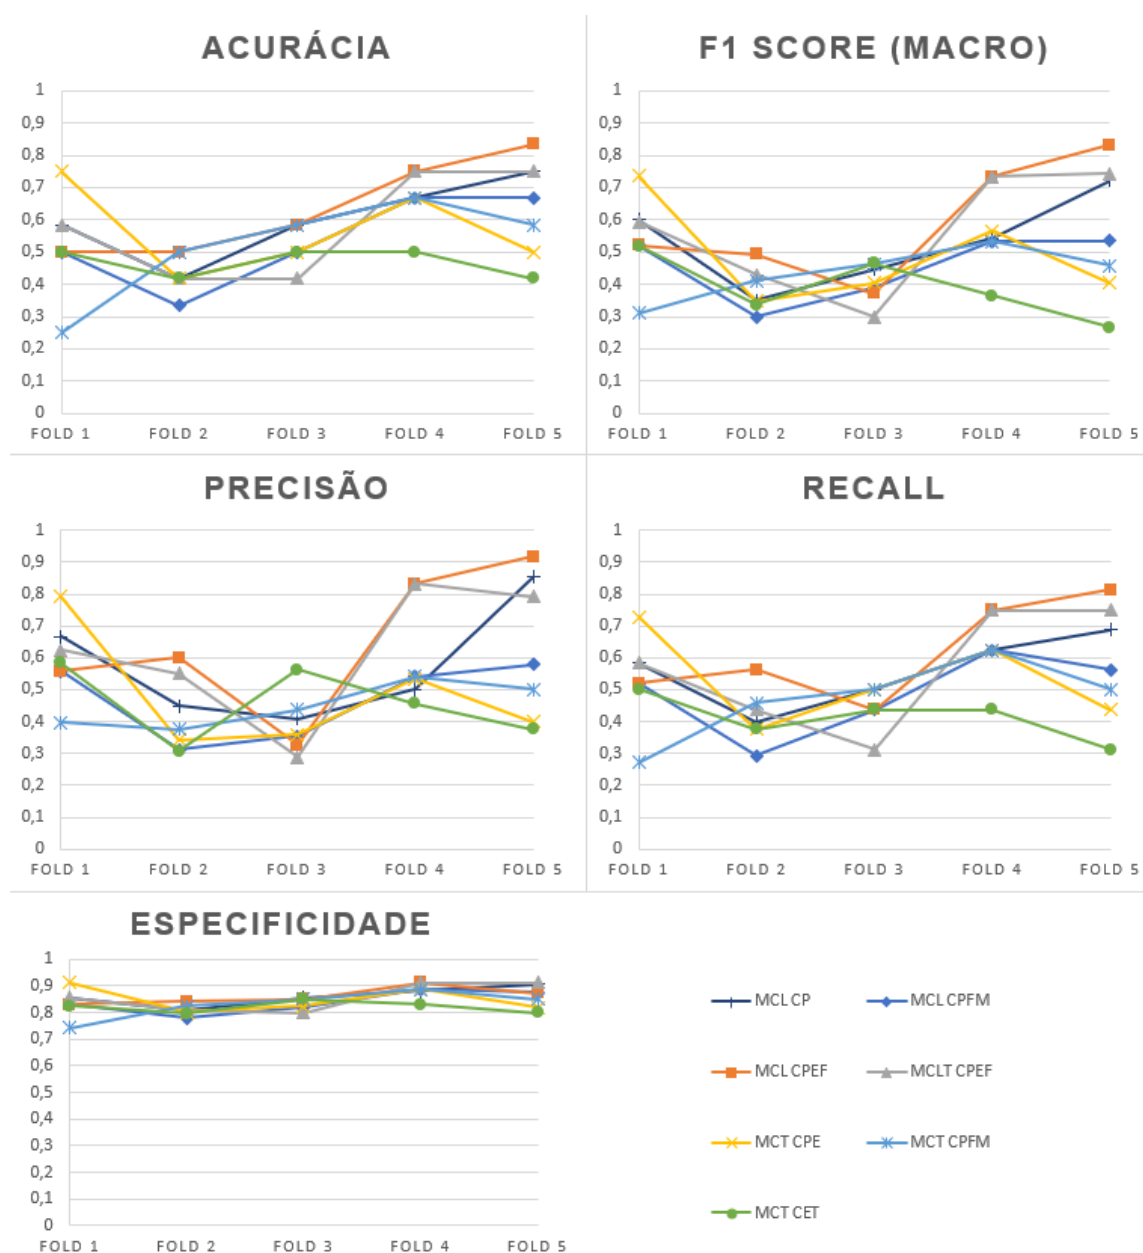


Figura 44 - Evolução de cada *FOLD* do treinamento da base de dados Etiologia do Coma melhores performances

Baseando-se na Tabela 13 que apresenta os resultados do treinamento realizados na base de dados da etiologia do coma, excluindo os exames rotulados como "outros". Observa-se que o modelo MCL CPEF se destacou, apresentando a melhor acurácia ($0,70 \pm 0,14$) e F1 score macro ($0,68 \pm 0,18$), indicando uma capacidade superior para distinguir as diferentes causas do coma quando os rótulos menos frequentes são removidos. O modelo MCL CPFM, MT e MCT CEC também apresentou desempenho competitivo, reforçando a eficácia da seleção de atributos e das configurações com ajuste refinado dos hiperparâmetros. Em contraste, modelos como MCT CET mostraram resultados inferiores, refletindo desafios na classificação devido à complexidade e variabilidade dos dados clínicos. Os tempos de treinamento permaneceram relativamente moderados, o que sugere um equilíbrio adequado entre precisão e eficiência computacional. Esses resultados enfatizam a importância da curadoria dos dados e da calibração dos modelos para otimizar o diagnóstico assistido por IA na etiologia do coma.

Tabela 13 - Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rótulo outros, melhores resultados, em negrito se destaca o melhor modelo

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPE						0.60±0.14	0.56±0.16	0.61±0.18	0.59±0.15	0.80±0.06	625
MCL CPFM						0.64±0.17	0.60±0.20	0.66±0.23	0.62±0.18	0.81±0.09	942
MCL CPEF						0.70±0.14	0.68±0.18	0.72±0.18	0.70±0.16	0.85±0.07	733
MT	8	128	3	0.2	60	0.62±0.19	0.62±0.19	0.68±0.17	0.64±0.20	0.81±0.10	832
MT CP	8	256	3	0.05	30	0.62±0.18	0.59±0.19	0.63±0.22	0.60±0.19	0.81±0.09	691
MT CPCP	8	128	3	0.2	60	0.60±0.17	0.59±0.16	0.69±0.18	0.63±0.19	0.81±0.08	1503
MCT CEC	3	128	3	0.2	60	0.64±0.16	0.60±0.16	0.67±0.20	0.63±0.16	0.82±0.08	1961

Adicionalmente, a Figura 45 ilustra a variação das métricas dos modelos com os melhores desempenhos sem os exames do rótulo "OUTROS" em cada *fold* ao longo do treinamento, possibilitando uma avaliação detalhada da consistência e das flutuações no desempenho em diferentes divisões dos dados.

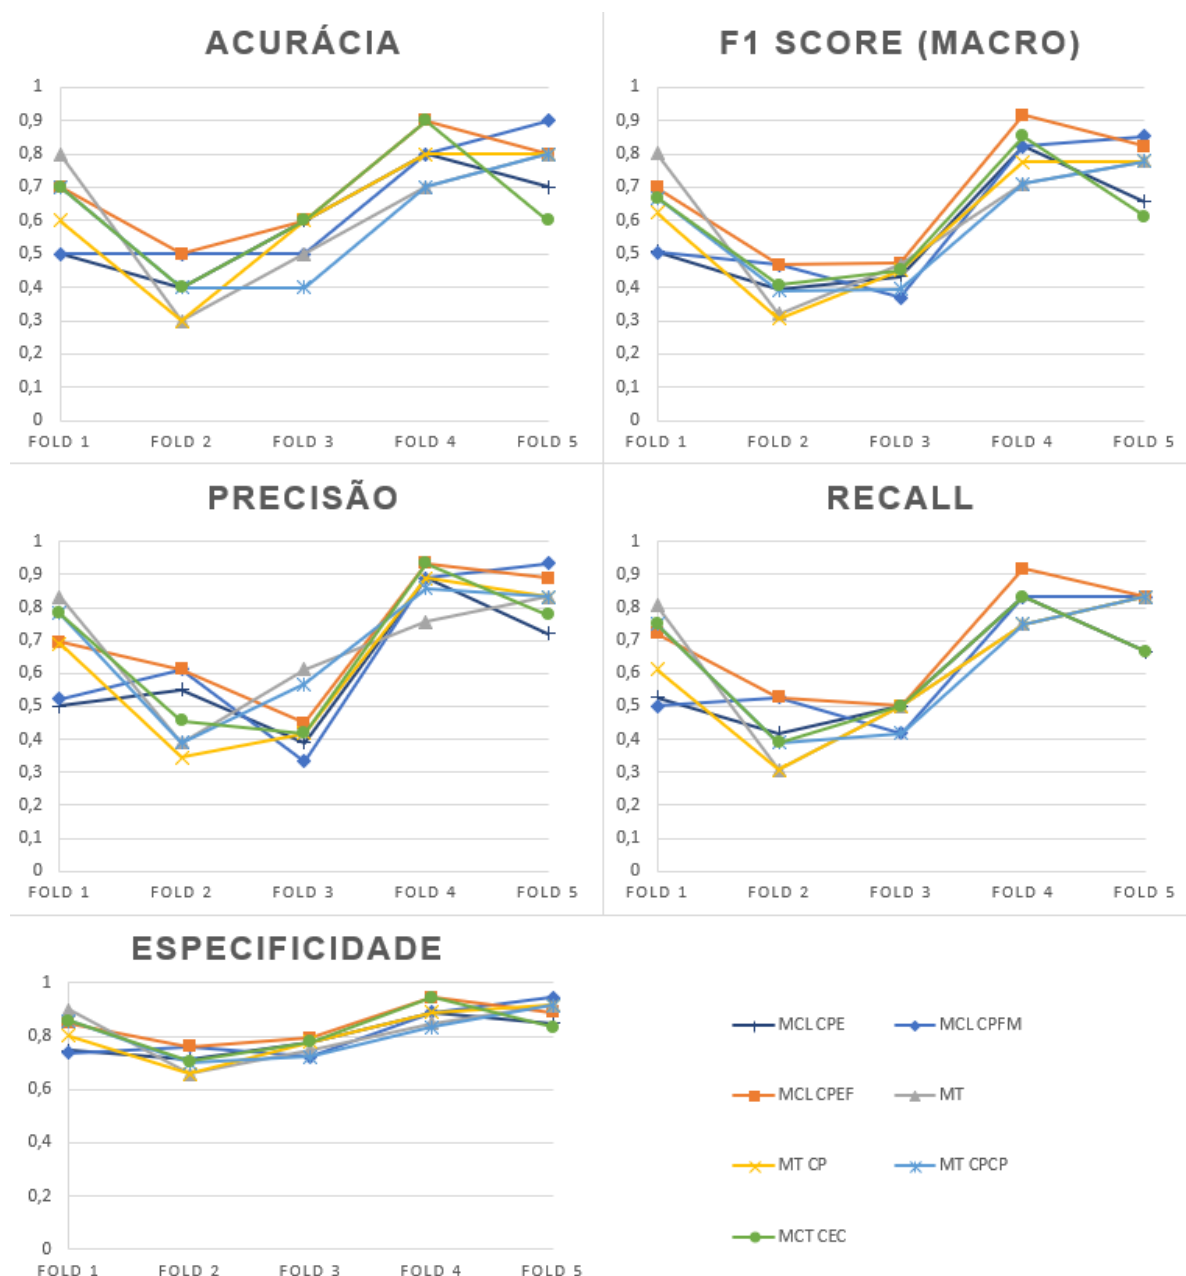


Figura 45 - Evolução de cada FOLD do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rótulo outros, melhores performances

A exclusão dos exames rotulados como "outros" reduziu a base de dados de 60 para 50 pacientes, eliminando casos com causas de coma menos frequentes e mais heterogêneas. Essa remoção resultou na simplificação do problema de classificação, que passou de 4 para 3 classes, diminuindo a variabilidade e o ruído associados a rótulos menos representativos. Assim, a redução do número de classes favoreceu a distinção entre as causas mais prevalentes, contribuindo para aprimorar a capacidade de aprendizagem e o desempenho dos modelos de classificação.

5.11 GOSTO MUSICAL

5.11.1 Definição do problema

O estudo das respostas cerebrais associadas ao gosto musical representa um desafio multidisciplinar, envolvendo neurociência, psicologia e ciência de dados. A música exerce um papel central na experiência humana, sendo capaz de evocar emoções intensas, memórias e estados afetivos distintos. No entanto, a forma como diferentes estilos ou faixas musicais impactam o cérebro de maneira individualizada ainda não é totalmente compreendida. A identificação neural de músicas favoritas (selecionadas individualmente pelo voluntário para induzir valência emocional positiva) e músicas desgostadas (escolhidas pelo voluntário para eliciar reações de aversão ou desconforto) pode fornecer insights valiosos sobre os mecanismos de processamento emocional e preferências pessoais, além de explorar as bases neurofisiológicas das emoções e suas aplicações em áreas como musicoterapia, neuromarketing e diagnóstico de distúrbios afetivos.

Tradicionalmente, a avaliação do gosto musical tem se baseado em autorrelatos e questionários subjetivos que, embora úteis, apresentam limitações quanto à objetividade e à padronização das respostas (NORTH; HARGREAVES, 2008). No contexto brasileiro, a diversidade cultural influencia fortemente as preferências musicais, o que potencializa a necessidade de métodos objetivos para analisar respostas emocionais. Nesse sentido, a análise do EEG surge como uma alternativa promissora, permitindo a investigação direta da atividade cerebral em tempo real durante a escuta musical. Contudo, a variabilidade interindividual e a complexidade dos padrões eletroencefalográficos associados a diferentes estados emocionais tornam a classificação automatizada um desafio significativo (ALLURI *et al.*, 2012).

Avanços em aprendizado de máquina têm possibilitado a identificação de padrões sutis em sinais de EEG, porém, os desafios mencionados anteriormente ainda dificultam a generalização de modelos preditivos para diferentes populações e gêneros musicais (HASANZADEH; ANNABESTANI; MOGHIMI, 2021; HE *et al.*, 2024; PANDEY *et al.*, 2021). A compreensão e a classificação precisas dessas respostas podem não apenas avançar o conhecimento científico sobre cognição musical, mas

também abrir caminho para aplicações em musicoterapia, entretenimento personalizado e interfaces cérebro-computador adaptativas.

Dessa forma, este trabalho propõe a utilização de exames de EEG como entrada para modelos de inteligência artificial, visando a classificação automatizada desses exames em músicas favoritas e músicas desgostadas.

5.11.2 Base de dados

A base de dados utilizada nesta seção é a mesma apresentada no **CAPÍTULO 4 - ANÁLISE DE PADRÕES DE ESTIMULAÇÃO MUSICAL** subitem 4.4 Base de dados, que contém sinais de EEG de indivíduos normais submetidos a estimulação musical.

5.11.3 Resultados

Os resultados dos modelos treinados seguem descritos detalhadamente no **APÊNDICE O, APÊNDICE P e APÊNDICE Q**.

5.11.4 Discussão

A análise comparativa dos modelos treinados para classificação de respostas neurais à estimulação musical (músicas favoritas vs. desgostadas) revela insights significativos sobre o desempenho de diferentes arquiteturas de redes neurais e estratégias de processamento de dados. A Tabela 14, apresentada a seguir, sintetiza os melhores desempenhos alcançados, destacando as combinações de modelos e configurações que maximizam as métricas de desempenho. E na Figura 46 pode-se visualizar o comportamento dos modelos em termos de cada *fold* de treinamento.

Tabela 14 - Resultados do treinamento base de dados Estimulação musical (Favorita e Desgostada) melhores performances, em negrito se destaca o melhor modelo

Modelo	N _H	INT_D	N _L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MMLP A//					30	0.53±0.09	0.52±0.09	0.53±0.07	0.67±0.14	0.53±0.09	223
MCL CFM A//					30	0.43±0.11	0.43±0.11	0.44±0.10	0.43±0.12	0.43±0.11	1540
MCL CPEC All					30	0.44±0.03	0.44±0.04	0.44±0.04	0.42±0.08	0.44±0.03	1484

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MMLP All Group					30	0.63±0.07	0.62±0.08	0.62±0.08	0.65±0.14	0.63±0.08	232
MCL CPC All Group					30	0.65±0.11	0.64±0.11	0.66±0.10	0.62±0.19	0.65±0.11	1616
MCL CPEC All Group					30	0.62±0.03	0.61±0.03	0.62±0.04	0.60±0.10	0.62±0.03	1560
MCL CPC All Group Aumento do Dropout para 0.5 nas camadas que usam 0.2 (kernel_regularizer=regularizers.l2(1e-4))					30	0.68±0.09	0.67±0.09	0.67±0.08	0.70±0.16	0.68±0.09	1577
MCT CP Same Half	8	64	1	0.3	30	0.42±0.14	0.41±0.14	0.43±0.16	0.37±0.07	0.42±0.14	846

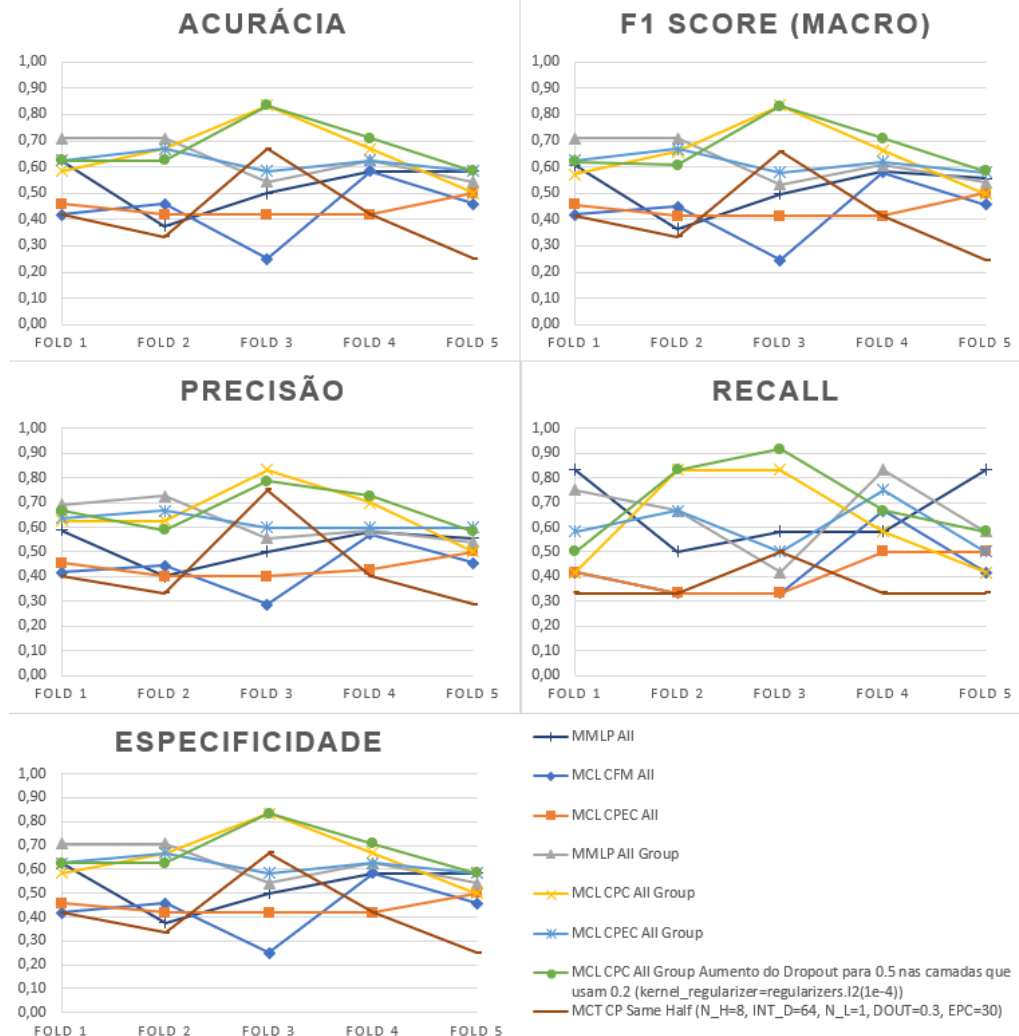


Figura 46 – Evolução de cada FOLD do treinamento base de dados Estimulação musical (Favorita e Desgostada) melhores performances

A interpretação dos resultados apresentados na Tabela 14 evidencia que o modelo MCL CPC *All Group*, que incorporou um aumento na taxa de *dropout* para 0,5 nas camadas originalmente configuradas com 0,2 (utilizando regularização L2 com coeficiente $1e^{-4}$), atingiu o melhor desempenho geral. Este modelo alcançou F1 score e precisão em torno de 67%, destacando-se pela combinação das características clínicas dos pacientes com medidas de coerência (CPC) associadas aos sinais de EEG. Esses resultados sugerem que ajustes cuidadosos nos hiperparâmetros, como a taxa de *dropout* e a regularização, podem contribuir significativamente para a melhoria da performance dos modelos nesta tarefa complexa.

Em comparação, os modelos *Multi Layer Perceptron* (MMLP), embora mais simples e eficientes em termos de tempo de treinamento (por exemplo, MMLP *All* com 223 segundos), apresentaram desempenhos inferiores (acurácia máxima de 63% para MMLP *All Group*). Isso indica que, apesar da eficiência computacional, os modelos MLP podem não ser suficientes para capturar a complexidade dos padrões emocionais em EEG, corroborando com a literatura que mostra a superioridade de redes mais profundas, como CNNs e LSTMs, em tarefas de classificação de emoções (GUO *et al.*, 2018).

Os modelos CNN-LSTM (MCL) com a configuração "*All Group*" apresentaram desempenhos superiores em comparação com as configurações "*All*" ou "*Same Half*", destacando a importância da estratégia de segregação dos dados para aprimorar a generalização dos modelos. Por exemplo, o modelo MCL CPC *All Group* alcançou uma acurácia de 65%, enquanto o modelo MCT CP *Same Half* obteve apenas 42%, sugerindo que a utilização de segmentos provenientes do mesmo voluntário tanto no treinamento quanto na validação pode introduzir vieses intraindividuais que comprometem a capacidade de generalização. Contudo, ao manter esses segmentos agrupados exclusivamente no conjunto de treinamento ou de validação, a performance dos modelos é significativamente melhorada.

Estes achados têm implicações no campo da neurociência afetiva e para aplicações práticas, como a terapia musical e o neuromarketing. A capacidade de classificar respostas emocionais a estímulos musicais com precisão pode auxiliar no desenvolvimento de intervenções personalizadas e na compreensão das bases neurais das preferências musicais. Mostrando que é possível identificar padrões

emocionais com um grau razoável de confiabilidade, o que pode ser útil em contextos terapêuticos para personalizar playlists musicais.

No entanto, os resultados também revelam limitações. A acurácia máxima alcançada é de aproximadamente 68%, o que, embora significativo, ainda deixa espaço para melhorias. Isso pode ser devido à variabilidade interindividual nas respostas emocionais ou à complexidade dos padrões neurais envolvidos.

Para futuras pesquisas, sugere-se investigar a influência de diferentes gêneros musicais e culturais, considerando a rica diversidade cultural brasileira. Essa abordagem pode fornecer insights valiosos sobre a capacidade de generalização dos modelos, além de contribuir para o desenvolvimento de sistemas mais robustos e adaptados à pluralidade de contextos presentes no país.

Em conclusão, os resultados obtidos demonstram que é possível classificar respostas emocionais a estímulos musicais com um grau razoável de precisão usando EEG e redes neurais, mas que ainda há espaço para otimização e refinamento das técnicas empregadas, especialmente no que diz respeito à eficiência computacional e à generalização para diferentes populações.

CAPÍTULO 6 - CONCLUSÕES E TRABALHOS FUTUROS

Destaca-se neste capítulo os aspectos da pesquisa e conclusões do trabalho apresentado nesta tese. Ademais, são apresentadas algumas sugestões para trabalhos futuros e a contribuição científica do presente trabalho.

6.1 CONCLUSÕES

Considerando o crescimento exponencial no interesse pelo entendimento dos processos mentais, o EEG tem se destacado como uma ferramenta poderosa para fornecer respostas importantes nesse campo. Para facilitar a identificação dessas respostas, há uma necessidade crescente de ferramentas automatizadas para processar os dados de EEG, preferencialmente de código aberto, que amplie o acesso das pessoas a essas análises. Diante disso, este trabalho propôs a transcrição do *software* de processamento de EEG desenvolvido pelo grupo de pesquisa na plataforma computacional para Python, uma linguagem de programação de código aberto.

Durante o processo de transcrição, foram identificadas necessidades específicas que resultaram em aprimoramentos significativos no *software* originalmente desenvolvido na plataforma computacional. Entre essas melhorias, destacam-se a inclusão de funções customizadas para o pré-processamento dos sinais, a definição de limiares para o descarte de canais ruidosos, a possibilidade de seleção dos quantificadores a serem calculados, bem como a configuração de parâmetros ajustáveis para o processamento, tais como o parâmetro *taumax*, a definição das épocas sequenciais e a escolha dos canais a serem analisados. Esses aprimoramentos tornaram a ferramenta mais robusta e flexível, permitindo ao grupo conduzir suas pesquisas de forma mais ágil e otimizar o processamento dos exames de EEG antes mesmo da conclusão da transcrição.

A transcrição do *software* para a linguagem Python teve como objetivo migrar o código para uma linguagem de programação *openSource* (de código aberto) gratuita. Na análise comparativa das duas versões, observou-se que a versão da

plataforma computacional apresentou desempenho superior, conforme evidenciado nos resultados do capítulo PROCESSAMENTO DO EEG. Especificamente, o pré-processamento e o processamento realizados em Python foram quase 60 vezes mais lentos, possivelmente devido à metodologia utilizada na transcrição, que incluiu a adaptação para o paradigma de programação orientado a objetos. Além disso, o arquivo final gerado em Python, que armazena os dados do EEG e os quantificadores extraídos, teve um tamanho quase cinco vezes maior que o correspondente na plataforma computacional. Técnicas adicionais, como algoritmos de compressão, podem ser aplicadas para reduzir esse tamanho e otimizar o armazenamento.

Para garantir a equivalência da transcrição da versão do *software* na plataforma computacional para Python, foi realizado um conjunto de testes de regressão que verificaram que o erro relativo da transcrição ficou na ordem de 10^{-12} , um valor irrelevante para o processo, com exceção do quantificador de coerência, que necessita de uma análise com outra abordagem. Além disso, a criação de uma interface gráfica acessível permitiu a adoção da plataforma por pesquisadores com diferentes níveis de experiência, acelerando o treinamento e a produção científica do grupo.

Ademais, visando compreender como as estimulações musicais influenciam a atividade elétrica cerebral, foram desenvolvidas rotinas estatísticas para destacar os eletrodos e as bandas de frequência mais relevantes na comparação entre diferentes estímulos. No *software* de suporte ao reconhecimento de padrões, verificou-se que o quantificador frequência mediana (FM) não foi eficaz. Por outro lado, o quantificador de porcentagem de contribuição de potência (PCP) revelou insights significativos, destacando diferenças substanciais entre os estímulos sonoros de silêncio e música desgostada em comparação com os demais estímulos. Essa discrepância foi mais pronunciada nas bandas de frequência delta e alfa, que apresentaram variações marcantes nos atributos extraídos pelo *software*, corroborando achados da literatura que evidenciam a importância dessas bandas na resposta cerebral à música.

Aprofundando na análise dos sinais de EEG, foram aplicadas diversas técnicas de inteligência artificial visando classificar bases de dados com o objetivo de desenvolver mecanismos automatizados que auxiliem o corpo clínico na tomada de decisões mais embasadas. Entre as metodologias empregadas destacam-se redes

neurais convolucionais (CNNs), redes de memória de longo curto prazo (LSTMs), perceptrons multicamadas (MLPs), *Transformers* e modelos híbridos.

Para a base de dados de pacientes em coma, na classificação do prognóstico entre favorável e desfavorável, destaca-se o modelo MCT CPC alcançando F1 Score (macro) de 90%. Na classificação da etiologia do coma, o modelo MCL CPEF obteve 63% de acurácia, e ao remover da base os exames pertencentes à categoria "outros", o desempenho do mesmo modelo manteve-se superior, alcançando 70% de acurácia. Por fim, na base de dados relativa à classificação da estimulação musical entre música gostada e desgostada, o modelo MCL CPC *All Group* com ajustes nos hiperparâmetros destacou-se com 67% de precisão.

Espera-se que este trabalho promova a disseminação de tecnologias abertas e reprodutíveis na área de análise de sinais neurofisiológicos, incentivando melhorias contínuas e avanços futuros.

6.2 TRABALHOS FUTUROS

Para a ferramenta de processamento de dados de EEG, os trabalhos futuros incluem:

- Otimizar o desempenho do processamento no *software* em Python, visando igualar ou superar a performance alcançada na implementação da plataforma computacional;
- Explorar o uso de algoritmos de compressão e formatos otimizados, como HDF5, para reduzir o tamanho dos arquivos gerados pelo *software* em Python.

No que diz respeito ao reconhecimento de padrões em múltiplos sinais, as direções futuras são:

- Automatizar o processo de reconhecimento, tornando-o mais eficiente e menos dependente de intervenção manual;
- Implementar rotinas capazes de lidar com formatos de dados de entrada distintos de PCP e FM, incluindo especialmente dados derivados de coerência.

Por fim, em relação à aplicação de inteligência artificial para a classificação de exames de EEG, os próximos passos consistem em:

- Aprofundar a compreensão sobre a relação entre os achados dos modelos e os fundamentos neurocientíficos subjacentes;
- Realizar testes estatísticos para verificar a diferença significativa entre os modelos de classificação avaliados na comparação dos resultados;
- Testar modelos de classificação pré-treinados, explorando o potencial de transferência de aprendizado para melhorar a performance em conjuntos de dados menores;
- Expandir a comparação incluindo novos modelos de aprendizado de máquina e *deep learning*;
- Validar a capacidade de generalização dos modelos aplicando-os a outras bases de dados abrangendo diferentes populações e condições clínicas.

6.3 CONSIDERAÇÕES FINAIS

Este trabalho contemplou a transcrição do *software* desenvolvido pelo grupo de pesquisa em uma plataforma computacional para a linguagem Python, incorporando melhorias que atendem às novas demandas do grupo. Além disso, foi implementado um mecanismo para auxiliar na busca de padrões entre múltiplos registros de EEG, bem como a aplicação de técnicas de inteligência artificial para a classificação dos sinais.

As aplicações desenvolvidas visam simplificar e otimizar o cotidiano dos trabalhos envolvendo EEG, tornando o processo mais automatizado e facilitando o reconhecimento de padrões relevantes.

Do ponto de vista científico, as principais contribuições deste trabalho incluem:

- a) Otimização do tempo do pesquisador, ao possibilitar o processamento paralelo dos registros de EEG e outras atividades, graças à automação dos procedimentos;
- b) Disponibilização de um *software openSource* para processamento de EEG, ampliando o acesso e possibilitando customizações futuras;
- c) Desenvolvimento de um mecanismo eficiente de reconhecimento de padrões e classificação dos exames de EEG;

- d) Implementação e avaliação de modelos de inteligência artificial que demonstraram boa performance e precisão na classificação dos sinais.

Estes avanços representam um passo importante para o aprimoramento das ferramentas de análise de EEG, com potencial aplicação clínica e pesquisa científica.

REFERÊNCIAS

- ALKHALDI, Mohammad; ABU JOUDEH, Layla; AHMED, Yaman B.; HUSARI, Khalil S. Artificial intelligence and telemedicine in epilepsy and EEG: A narrative review. **Seizure: European Journal of Epilepsy**, [S. l.], v. 121, n. 1, p. 204–210, 2024. DOI: 10.1016/j.seizure.2024.08.024.
- ALLURI, Vinoo; TOIVIAINEN, Petri; JÄÄSKELÄINEN, Iiro P.; GLERAN, Enrico; SAMS, Mikko; BRATTICO, Elvira. Large-scale brain networks emerge from dynamic processing of musical timbre, key and rhythm. **NeuroImage**, [S. l.], v. 59, n. 4, p. 3677–3689, 2012. DOI: 10.1016/j.neuroimage.2011.11.019.
- BAJWA, Junaid; MUNIR, Usman; NORI, Aditya; WILLIAMS, Bryan. Artificial intelligence in healthcare: transforming the practice of medicine. **Future healthcare journal**, England, v. 8, n. 2, p. e188–e194, 2021. DOI: 10.7861/fhj.2021-0095.
- BALDO JÚNIOR, Sergio. **Algoritmos genéticos e aprendizado profundo baseado em redes neurais recorrentes do tipo LSTM para auxílio ao diagnóstico médico**. 2023. Dissertação de Mestrado Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da Universidade de São Paulo, Ribeirão Preto, 2023. DOI: 10.11606/D.59.2023.tde-20062023-152537.
- BARBERA, Thomas; BURGER, Jacopo; D'AMELIO, Alessandro; ZINI, Simone; BIANCO, Simone; LANZAROTTI, Raffaella; NAPOLETANO, Paolo; BOCCIGNONE, Giuseppe; CONTRERAS-VIDAL, Jose Luis. On using AI for EEG-based BCI applications: problems, current challenges and future trends. [S. l.], 2025.
- BARBOSA, João Ludovico Maximiano. **Cadastro, Processamento e Visualização de Eletroencefalograma**. 2019. Dissertação de Mestrado do Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia, [S. l.], 2019.
- BASTOS, Aderson; RIOS, Emerson; CRISTALLI, Ricardo; MOREIRA, Trayahú. **Base de conhecimento em teste de software**. 3. ed. São Paulo: McGraw-Hill, 2012.
- BENGIO, Yoshua; GRANDVALET, Yves. No Unbiased Estimator of the Variance of K-Fold Cross-Validation. In: (S. Thrun, L. Saul, B. Schölkopf, Org.) **ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS 2003**, **Anais [...]**. : MIT Press, 2003.
- BITBUCKET. **Planos e preços**. 2021. Disponível em: <https://www.atlassian.com/br/software/bitbucket/pricing>. Acesso em: 27 jul. 2021.
- BLANKERTZ, Benjamin; TOMIOKA, Ryota; LEMM, Steven; KAWANABE, Motoaki; MULLER, Klaus-robert. Optimizing Spatial filters for Robust EEG Single-Trial Analysis. **IEEE Signal Processing Magazine**, [S. l.], v. 25, n. 1, p. 41–56, 2008. DOI: 10.1109/MSP.2008.4408441.
- BLUM, Sarah; DEBENER, Stefan; EMKES, Reiner; VOLKENING, Nils; FUDICKAR, Sebastian; BLEICHNER, Martin G. EEG Recording and Online Signal Processing on Android: A Multiapp Framework for Brain-Computer Interfaces on Smartphone. **BioMed Research International**, [S. l.], v. 2017, p. 1–12, Novembro, 2017. DOI: 10.1155/2017/3072870.
- BRADT, Joke; DILEO, Cheryl; MAGILL, Lucanne; TEAGUE, Aaron. Music interventions for improving psychological and physical outcomes in cancer patients. **Cochrane Database of Systematic Reviews**, [S. l.], 2016. DOI: 10.1002/14651858.CD006911.pub3.
- CARNEIRO, Murillo G.; RAMOS, Camila D.; DESTRO-FILHO, João-Batista; ZHU, Yutao; JI,

Donghong; ZHAO, Liang. High-Level Classification for EEG Analysis. *In: 2023 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN) 2023, Anais [...]. : IEEE, 2023. p. 1–8. DOI: 10.1109/IJCNN54540.2023.10191823.*

CHEN, Mei Lin; YAO, Lin; JIANG, Ning. Music Imagery for Brain-Computer Interface Control. *In: [s.l.: s.n.]. p. 293–300. DOI: 10.1007/978-3-319-58625-0_21.*

COMBRISSE, Etienne; VALLAT, Raphael; EICHENLAUB, Jean-Baptiste; O'REILLY, Christian; LAJNEF, Tarek; GUILLOT, Aymeric; RUBY, Perrine M.; JERBI, Karim. Sleep: An Open-Source Python Software for Visualization, Analysis, and Staging of Sleep Data. **Frontiers in Neuroinformatics**, [S. l.], v. 11, p. 1–11, September, 2017. DOI: 10.3389/fninf.2017.00060.

CORBETTA, Maurizio; SHULMAN, Gordon L. Control of goal-directed and stimulus-driven attention in the brain. **Nature Reviews Neuroscience**, [S. l.], v. 3, n. 3, p. 201–215, 2002. DOI: 10.1038/nrn755.

CORDER, Gregory W.; FOREMAN, Dale I. **Nonparametric Statistics: A Step-by-Step Approach**. Second ed. Hoboken: John Wiley & Sons, 2014.

DAUBECHIES, Ingrid. **Ten Lectures on Wavelets**. [s.l.] : Society for Industrial and Applied Mathematics, 1992. DOI: 10.1137/1.9781611970104.

DESTRO-FILHO, J. B.; FARIA, V. N. R. ANÁLISE DE SINAL MEA BASEADA EM TESTES ESTOCÁSTICOS DESCREVENDO A ESTRUTURA DE DENSIDADE DE PROBABILIDADE. **XI Simpósio de Engenharia Biomédica – SEB**, [S. l.], p. 20–23, 2018.

DRONKERS, N. F.; PLAISANT, O.; IBA-ZIZEN, M. T.; CABANIS, E. A. Paul Broca's historic cases: high resolution MR imaging of the brains of Leborgne and Lelong. **Brain**, [S. l.], v. 130, n. 5, p. 1432–1441, 2007. DOI: 10.1093/brain/awm042.

EHRlich, Stefan K.; AGRES, Kat R.; GUAN, Cuntai; CHENG, Gordon. A closed-loop, music-based brain-computer interface for emotion mediation. **PLOS ONE**, [S. l.], v. 14, n. 3, p. e0213516, 2019. DOI: 10.1371/journal.pone.0213516.

FIRAT, Rengin B. Opening the “Black Box”: Functions of the Frontal Lobes and Their Implications for Sociology. **Frontiers in Sociology**, [S. l.], v. 4, 2019. DOI: 10.3389/fsoc.2019.00003.

FOLGIERI, Raffaella; BERGOMI, Mattia G.; CASTELLANI, Simone. EEG-Based Brain-Computer Interface for Emotional Involvement in Games Through Music. *In: Digital Da Vinci*. New York, NY: Springer New York, 2014. p. 205–236. DOI: 10.1007/978-1-4939-0536-2_9.

FREEMAN, Walter J.; QUIROGA, Rodrigo Quian. **Imaging Brain Function With EEG**. New York, NY: Springer New York, 2013. DOI: 10.1007/978-1-4614-4984-3.

FRENCH, Christopher C. EEG Coherence and Hemisphere Asymmetry. [S. l.], 1982.

FU, Zhongzheng; ZHANG, Boning; HE, Xinrun; LI, Yixuan; WANG, Haoyuan; HUANG, Jian. Emotion recognition based on multi-modal physiological signals and transfer learning. **Frontiers in Neuroscience**, [S. l.], v. 16, 2022. DOI: 10.3389/fnins.2022.1000716.

GITHUB. **Get the complete developer platform**. 2024. Disponível em: <https://github.com/pricing>. Acesso em: 3 jan. 2024.

GOUTTE, Cyril; GAUSSIER, Eric. A Probabilistic Interpretation of Precision, Recall and F-

Score, with Implication for Evaluation. *In*: [s.l.: s.n.]. p. 345–359. DOI: 10.1007/978-3-540-31865-1_25.

GRAMFORT, Alexandre *et al.* MEG and EEG data analysis with MNE-Python. **Frontiers in Neuroscience**, [S. l.], v. 7, n. 7 DEC, p. 1–13, Dezembro, 2013. DOI: 10.3389/fnins.2013.00267.

GROUSSARD, M.; VIADER, F.; HUBERT, V.; LANDEAU, B.; ABBAS, A.; DESGRANGES, B.; EUSTACHE, F.; PLATEL, H. Musical and verbal semantic memory: Two distinct neural networks? **NeuroImage**, [S. l.], v. 49, n. 3, p. 2764–2773, 2010. DOI: 10.1016/j.neuroimage.2009.10.039.

GU, Xiaotong; CAO, Zehong; JOLFAEI, Alireza; XU, Peng; WU, Dongrui; JUNG, Tzyy-Ping; LIN, Chin-Teng. EEG-Based Brain-Computer Interfaces (BCIs): A Survey of Recent Studies on Signal Sensing Technologies and Computational Intelligence Approaches and Their Applications. **IEEE/ACM Transactions on Computational Biology and Bioinformatics**, [S. l.], v. 18, n. 5, p. 1645–1666, 2021. DOI: 10.1109/TCBB.2021.3052811.

GUO, Jinliang; FANG, Fang; WANG, Wei; REN, Fuji. EEG Emotion Recognition Based on Granger Causality and CapsNet Neural Network. *In*: 2018 5TH IEEE INTERNATIONAL CONFERENCE ON CLOUD COMPUTING AND INTELLIGENCE SYSTEMS (CCIS) 2018, **Anais [...]**. : IEEE, 2018. p. 47–52. DOI: 10.1109/CCIS.2018.8691230.

HASANZADEH, Fatemeh; ANNABESTANI, Mohsen; MOGHIMI, Sahar. Continuous emotion recognition during music listening using EEG signals: A fuzzy parallel cascades model. **Applied Soft Computing**, [S. l.], v. 101, p. 107028, 2021. DOI: 10.1016/j.asoc.2020.107028.

HE, Zhiyu; LI, Jiayu; MA, Weizhi; ZHANG, Min; LIU, Yiqun; MA, Shaoping. Introducing EEG Analyses to Help Personal Music Preference Prediction. [S. l.], 2024.

HUNTER, John; DALE, Darren; FIRING, Eric; DROETTBOOM, MICHAEL TEAM, Development Matplotlib. **matplotlib.mlab**. 2021. Disponível em: https://matplotlib.org/stable/api/mlab_api.html. Acesso em: 9 ago. 2021.

İNCE, Rûmeysa; ADANIR, Saliha Seda; SEVMEZ, Fatma. The inventor of electroencephalography (EEG): Hans Berger (1873–1941). **Child's Nervous System**, [S. l.], v. 37, n. 9, p. 2723–2724, 2021. DOI: 10.1007/s00381-020-04564-z.

ISLAM, Saidul; ELMEKKI, Hanae; ELSEBAI, Ahmed; BENTAHAR, Jamal; DRAWEL, Najat; RJOUB, Gaith; PEDRYCZ, Witold. A Comprehensive Survey on Applications of Transformers for Deep Learning Tasks. **Expert systems with applications**, [S. l.], 2023. DOI: 10.48550/arxiv.2306.07303.

ISMAIL FAWAZ, Hassan; FORESTIER, Germain; WEBER, Jonathan; IDOUMGHAR, Lhassane; MULLER, Pierre-Alain. Deep learning for time series classification: a review. **Data Mining and Knowledge Discovery**, [S. l.], v. 33, n. 4, p. 917–963, 2019. DOI: 10.1007/s10618-019-00619-1.

KAMRUD, Alexander; BORGHETTI, Brett; SCHUBERT KABBAN, Christine. The Effects of Individual Differences, Non-Stationarity, and the Importance of Data Partitioning Decisions for Training and Testing of EEG Cross-Participant Models. **Sensors**, [S. l.], v. 21, n. 9, p. 3225, 2021. DOI: 10.3390/s21093225.

KANDEL, Eric R. **Principles of Neural Science**. 5th. ed. [s.l.] : McGraw-Hill Education / Medical, 2012.

KLIMESCH, Wolfgang. EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis. **Brain Research Reviews**, [S. l.], v. 29, n. 2–3, p. 169–195, 1999. DOI: 10.1016/S0165-0173(98)00056-3.

KOELSCH, Stefan. Toward a Neural Basis of Music Perception – A Review and Updated Model. **Frontier in Psychology**, [S. l.], v. 2, 2011. DOI: 10.3389/fpsyg.2011.00110.

KOMMRUSCH, Steve. **Artificial Intelligence Techniques for Security Vulnerability Prevention**. , 2019.

KUMAGAI, Yuiko; ARVANEH, Mahnaz; TANAKA, Toshihisa. Familiarity Affects Entrainment of EEG in Music Listening. **Frontiers in Human Neuroscience**, [S. l.], v. 11, 2017. DOI: 10.3389/fnhum.2017.00384.

LAM, Yat Hei Vanessa; LUI, Leo. A Comparative Analysis of CNNs and RNNs for EEG-based Motor Imagery Classification in BCIs. **Journal of Student Research**, [S. l.], v. 12, n. 4, 2023. DOI: 10.47611/jsrhs.v12i4.5740.

LEVIN, April R.; LEAL, Adriana S. Ménde.; GABARD-DURNAM, Laurel J.; O'LEARY, Heather M. BEAPP: The batch electroencephalography automated processing platform. **Frontiers in Neuroscience**, [S. l.], v. 12, n. AUG, p. 1–13, Agosto, 2018. DOI: 10.3389/fnins.2018.00513.

LIMA, Izabella Nonato Oliveira. **Avaliação do EEG de pacientes comatosos sob estimulação musical**. 2020. Dissertação de Mestrado do Programa de Pós-graduação em Engenharia Elétrica Universidade Federal de Uberlândia, [S. l.], 2020.

LIU, Ruixiang; CHAO, Yihu; MA, Xuerui; SHA, Xianzheng; SUN, Limin; LI, Shuo; CHANG, Shijie. ERTNet: an interpretable transformer-based framework for EEG emotion recognition. **Frontiers in Neuroscience**, [S. l.], v. 18, 2024. DOI: 10.3389/fnins.2024.1320645.

LOPES DA SILVA, Fernando. EEG and MEG: Relevance to neuroscience. **Neuron**, [S. l.], v. 80, n. 5, p. 1112–1128, Dezembro, 2013. DOI: 10.1016/j.neuron.2013.10.017.

LOTTE, F.; BOUGRAIN, L.; CICHOCKI, A.; CLERC, M.; CONGEDO, M.; RAKOTOMAMONJY, A.; YGER, F. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. **Journal of Neural Engineering**, [S. l.], v. 15, n. 3, p. 031005, 2018. DOI: 10.1088/1741-2552/aab2f2.

LU, Wei; MA, Hua; TAN, Tien-Ping. CIT-EmotionNet: CNN Interactive Transformer Network for EEG Emotion Recognition. **arXiv.org**, [S. l.], 2023. DOI: 10.48550/arxiv.2305.05548.

MAGALHÃES, Kaliny A. C. O.; RODRIGUES, Amanda L.; RAMOS, Gaspar O.; DESTRO-FILHO, Joao Batista. No Revisão sobre as diretrizes para a estimulação cognitiva do tipo musical em interfaces cérebro-máquina. **Revista de Sistemas de Informação da FSMA**, [S. l.], v. 28, p. 45–57, 2021.

MAGUIRE, Melissa Jane. Music and epilepsy: A critical review. **Epilepsia**, [S. l.], v. 53, n. 6, p. 947–961, 2012. DOI: 10.1111/j.1528-1167.2012.03523.x.

MAHAJAN, Charu *et al.* A National Survey on Coma Epidemiology, Evaluation, and Therapy in India: Revisiting the Curing Coma Campaign Come Together Survey. **Neurocritical Care**, [S. l.], v. 40, n. 3, p. 941–952, 2024. DOI: 10.1007/s12028-023-01852-9.

MAITY, Akash Kumar; PRATIHAR, Ruchira; MITRA, Anubrato; DEY, Subham; AGRAWAL, Vishal; SANYAL, Shankha; BANERJEE, Archi; SENGUPTA, Ranjan; GHOSH, Dipak. Multifractal Detrended Fluctuation Analysis of alpha and theta EEG rhythms with musical

stimuli. **Chaos, Solitons & Fractals**, [S. l.], v. 81, p. 52–67, 2015. DOI: 10.1016/j.chaos.2015.08.016.

MALLAT, Stéphane G. **A Wavelet Tour of Signal Processing: The Sparse Way**. 3rd. ed. [s.l.] : Elsevier, 2008. DOI: 10.1016/B978-0-12-374370-1.X0001-8.

MARINHO, Taíssa Ferrari. **Recomendação da SBNC para localização de eletrodos e montagens de EEG**. São Paulo.

MARTINS, Ernane Rosa. **Ciência, Tecnologia e Inovação Experiências, Desafios e Perspectivas 3**. [s.l.] : Atena Editora, 2023. DOI: 10.22533/at.ed.536230504.

MICROSOFT. **Criar ou editar arquivos .csv para importação para o Outlook. Site oficial Microsoft para Suporte ao Word**. [s.d.]. Disponível em: <https://support.office.com/pt-br/article/criar-ou-editar-arquivos-csv-para-importação-para-o-outlook-4518d70d-8fe9-46ad-94fa-1494247193c7>. Acesso em: 20 out. 2018.

MILLER, Earl K.; COHEN, Jonathan D. An Integrative Theory of Prefrontal Cortex Function. **Annual Review of Neuroscience**, [S. l.], v. 24, n. 1, p. 167–202, 2001. DOI: 10.1146/annurev.neuro.24.1.167.

MOORE, K. S. A Systematic Review on the Neural Effects of Music on Emotion Regulation: Implications for Music Therapy Practice. **Journal of Music Therapy**, [S. l.], v. 50, n. 3, p. 198–242, 2013. DOI: 10.1093/jmt/50.3.198.

MORETTIN, Pedro A.; BUSSAB, Wilton de O. **Estatística básica**. 10. ed. São Paulo: Saraiva Uni, 2024.

NASCIMENTO JUNIOR, Odelmo O.; ASSIS, Dhara L. C.; DESTRO FILHO, João B.; ZHAO, Liang; CARNEIRO, Murillo G. Modeling EEG Data into Graphs for the Prognostic of Patients in Coma Using Graph Neural Networks. **BRACIS 2024**, [S. l.], p. 223–237, 2025. DOI: 10.1007/978-3-031-79038-6_16.

NIEDERMEYER, Ernst; SILVA, Fernando Lopes Da. **Electroencephalography: Basic Principles, Clinical Applications, and Related Fields**. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2004.

NORTH, Adrian; HARGREAVES, David. **The Social and Applied Psychology of Music**. [s.l.] : Oxford University Press, 2008. DOI: 10.1093/acprof:oso/9780198567424.001.0001.

OLIVEIRA, Inês; CARRIÇO, Luís; GUIMARÃES, Nuno; CHAMBEL, Teresa; TEIXEIRA, Carlos J. C. Análise dos Estados de Atenção Visual e Auditiva com Base na Análise de Electroencefalogramas. *In*: 2007, **Anais [...]**. [s.l.: s.n.]

ORACLE. **O que é Deep Learning?** [s.d.]. Disponível em: <https://www.oracle.com/br/artificial-intelligence/machine-learning/what-is-deep-learning/>. Acesso em: 31 dez. 2024.

PANDEY, Pankaj; AHMAD, Nashra; MIYAPURAM, Krishna Prasad; LOMAS, Derek. Predicting Dominant Beat Frequency from Brain Responses While Listening to Music. *In*: 2021 IEEE INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICINE (BIBM) 2021, **Anais [...]**. : IEEE, 2021. p. 3058–3064. DOI: 10.1109/BIBM52615.2021.9669750.

PERNET, Cyril *et al.* Issues and recommendations from the OHBM COBIDAS MEEG committee for reproducible EEG and MEG research. **Nature Neuroscience**, [S. l.], v. 23, n. 12, p. 1473–1483, 2020. DOI: 10.1038/s41593-020-00709-0.

POWERS, David M. W. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *[S. l.]*, 2020.

QIAN, Wenxia; TAN, Jianling; JIANG, Yuhao; TIAN, Yin. Deep learning with convolutional neural networks for EEG-based music emotion decoding and visualization. **Brain-Apparatus Communication: A Journal of Bacomics**, *[S. l.]*, v. 1, n. 1, p. 38–49, 2022. DOI: 10.1080/27706710.2022.2075241.

RAMACHANDRAN, Neenu P.; KURUP, Rajasree Ramachandra; ALPHONSE, Joshy; CHELLAIAH, Priya; NAIR, Manjusha; NAIR, Bipin. Design and Implementation of an Open-Source Browser-based Laboratory Platform for EEG Data Analysis. **2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)**, *[S. l.]*, p. 2313–2317, 2018. DOI: 10.1109/ICACCI.2018.8554786.

RAMEZANI, Maryam; TAKIAN, Amirhossein; BAKHTIARI, Ahad; RABIEE, Hamid R.; FAZAELI, Ali Akbar; SAZGARNEJAD, Saharnaz. The application of artificial intelligence in health financing: a scoping review. **Cost effectiveness and resource allocation: C/E**, England, v. 21, n. 1, p. 83, 2023. DOI: 10.1186/s12962-023-00492-2.

RAMOS, C. D. *et al.* COMPARAÇÃO QUANTITATIVA DO ELETROENCEFALOGRAMA (EEG) EM ESTADO DE COMA COM DIFERENTES DESFECHOS CLÍNICOS. *In: ANAIS DO V CONGRESSO BRASILEIRO DE ELETROMIOGRAFIA E CINESIOLOGIA E X SIMPÓSIO DE ENGENHARIA BIOMÉDICA 2018*, Uberlândia, Minas Gerais. **Anais [...]**. Uberlândia, Minas Gerais: Even3, 2018. DOI: 10.29327/cobecseb.78828.

RAMOS, Camila D.; TOMAIS, Rafael C.; ARAÚJO, Ana C. C. P. S.; PEREIRA, Gabrielle M.; F. JÚNIOR, Eustáquio; DESTRO-FILHO, João B.; CARRIJO, Gilberto A. ESTUDO QUANTITATIVO PILOTO PARA CARACTERIZAÇÃO DO EEG NORMAL REFERENTE À FREQUÊNCIA MEDIANA DO SINAL POR ELETRODO. **Anais do XIV CEEL**, *[S. l.]*, n. ISSN:2178-8308, p. 6, 2016.

RAMOS, Camila Davi. **Caracterização do eletroencefalograma normal em situação de vigília: elaboração da base de dados e análise quantitativa**. 2017. Dissertação de Mestrado do Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia, Uberlândia, 2017.

RAMOS, Camila Davi; LIMA, Izabella Nonato Oliveira; RODRIGUES, Amanda Luiza; MAGALHÃES, Kaliny Alice Carvalho de Oliveira; RODRIGUES, Aurélia Aparecida de Araújo; DESTRO-FILHO, João-Batista. Analysis of electroencephalography brain rhythms in the reading process. **Einstein (São Paulo)**, *[S. l.]*, v. 18, 2020. DOI: 10.31744/einstein_journal/2020AO5442.

RAMOS, GASPAR EUGÊNIO OLIVEIRA. **Estudo sobre estimulação musical com o eeg e atenuação do ruído na uti**. 2018. Dissertação de Mestrado do Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia, Uberlândia, 2018.

RAMOSER, H.; MULLER-GERKING, J.; PFURTSCHELLER, G. Optimal spatial filtering of single trial EEG during imagined hand movement. **IEEE Transactions on Rehabilitation Engineering**, *[S. l.]*, v. 8, n. 4, p. 441–446, 2000. DOI: 10.1109/86.895946.

Recommendations for the practice of clinical neurophysiology: guidelines of the International Federation of Clinical Neurophysiology. **Electroencephalography and clinical neurophysiology. Supplement**, Netherlands, v. 52, p. 1–304, 1999.

REZAEI, Sahar *et al.* Future of Alzheimer's detection: Advancing diagnostic accuracy through

the integration of qEEG and artificial intelligence. **NeuroImage**, [S. l.], v. 317, p. 121373, 2025. DOI: 10.1016/j.neuroimage.2025.121373.

RODRIGUES, Isabely Pereira; ORNELLAS, Bruna de Castro; RIBEIRO, Caline dos Santos; ALMEIDA, Gabriel de Souza; NASCIMENTO, Erika Fabris Do. Potencialidades da musicoterapia no tratamento oncológico: uma revisão narrativa. **Brazilian Journal of Health Review**, [S. l.], v. 8, n. 1, p. e76522, 2025. DOI: 10.34119/bjhrv8n1-056.

ROSA, LAUCSEN DA, Diego. **Sistema de Processamento de Sinais Biomédicos: Filtragem de Sinais de Eletroencefalograma**. 2009. Dissertação de Mestrado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina, Florianópolis, 2009.

ROY, Yannick; BANVILLE, Hubert; ALBUQUERQUE, Isabela; GRAMFORT, Alexandre; FALK, Tiago H.; FAUBERT, Jocelyn. Deep learning-based electroencephalography analysis: a systematic review. **Journal of Neural Engineering**, [S. l.], v. 16, n. 5, p. 051001, 2019. DOI: 10.1088/1741-2552/ab260c.

RUIJTER, Barry J. *et al.* Early electroencephalography for outcome prediction of postanoxic coma: A prospective cohort study. **Annals of Neurology**, [S. l.], v. 86, n. 2, p. 203–214, 2019. DOI: 10.1002/ana.25518.

SANDRONI, Claudio *et al.* Prediction of poor neurological outcome in comatose survivors of cardiac arrest: a systematic review. **Intensive Care Medicine**, [S. l.], v. 46, n. 10, p. 1803–1851, 2020. DOI: 10.1007/s00134-020-06198-w.

SCHMITZ, Daniel. **Tudo que você queria saber sobre Git e GitHub, mas tinha vergonha de perguntar**. 2015. Disponível em: <https://tableless.com.br/tudo-que-voce-queria-saber-sobre-git-e-github-mas-tinha-vergonha-de-perguntar/>. Acesso em: 7 out. 2018.

SCHOMER, Donald L.; LOPES DA SILVA, Fernando H. (ORG.). **Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields**. 7th. ed. [s.l.] : Oxford University Press, 2017. v. 1 DOI: 10.1093/med/9780190228484.001.0001.

SOKOLOVA, Marina; LAPALME, Guy. A systematic analysis of performance measures for classification tasks. **Information Processing & Management**, [S. l.], v. 45, n. 4, p. 427–437, 2009. DOI: 10.1016/j.ipm.2009.03.002.

SQUIRE, Larry R.; ZOLA-MORGAN, Stuart. The Medial Temporal Lobe Memory System. **Science**, [S. l.], v. 253, n. 5026, p. 1380–1386, 1991. DOI: 10.1126/science.1896849.

SRINIVASAN, Ramesh; WINTER, William R.; DING, Jian; NUNEZ, Paul L. EEG and MEG coherence: Measures of functional connectivity at distinct spatial scales of neocortical dynamics. **Journal of Neuroscience Methods**, [S. l.], v. 166, n. 1, p. 41–52, 2007. DOI: 10.1016/j.jneumeth.2007.06.026.

TANDLE, A.; JOG, Nandini; DHARMADHIKARI, A.; JAISWAL, Suyog; SAWANT, Vishal. Study of valence of musical emotions and its laterality evoked by instrumental Indian classical music: An EEG study. In: 2016 INTERNATIONAL CONFERENCE ON COMMUNICATION AND SIGNAL PROCESSING (ICCSP) 2016, **Anais [...]**. : IEEE, 2016. p. 0327–0331. DOI: 10.1109/ICCSP.2016.7754149.

TANDLE, Avinash L.; JOSHI, Manjusha S.; DHARMADHIKARI, Ambrish S.; JAISWAL, Suyog V. Mental state and emotion detection from musically stimulated EEG. **Brain informatics**, [S.

I., v. 5, n. 2, p. 14, 2018. DOI: 10.1186/s40708-018-0092-z.

TONNER, P. H.; BEIN, B. Classic electroencephalographic parameters: Median frequency, spectral edge frequency etc. **Best Practice & Research Clinical Anaesthesiology**, [*S. I.*], v. 20, n. 1, p. 147–159, 2006. DOI: 10.1016/j.bpa.2005.08.008.

TRANG, Nguyen Thi Hoang; LINH, Tran Thanh Duy; VU, Do Quoc; LOAN, Bui Thi Hong; VINH, Nguyen Nhu; DANG, Tran Ngoc. Artificial intelligence-based approaches for sleep-related breathing events identification using EEG and ECG signals. **Sleep and Breathing**, [*S. I.*], v. 29, n. 5, p. 276, 2025. DOI: 10.1007/s11325-025-03442-9.

TSENG, K. C.; BOR-SHYH LIN; CHANG-MU HAN; PSI-SHI WANG. Emotion recognition of EEG underlying favourite music by support vector machine. *In*: 2013 1ST INTERNATIONAL CONFERENCE ON ORANGE TECHNOLOGIES (ICOT) 2013, **Anais [...]** : IEEE, 2013. p. 155–158. DOI: 10.1109/ICOT.2013.6521181.

VAN DER MAATEN, Laurens; HINTON, Geoffrey. Visualizing Data using t-SNE. **Journal of Machine Learning Research**, [*S. I.*], v. 9, p. 2579–2605, 2008.

VASWANI, Ashish; SHAZEER, Noam; PARMAR, Niki; USZKOREIT, Jakob; JONES, Llion; GOMEZ, Aidan N.; KAISER, Lukasz; POLOSUKHIN, Illia. Attention Is All You Need. **Neural Information Processing Systems**, [*S. I.*], 2017.

VON WEGNER, Frederic; LAUFS, Helmut. Information-Theoretical Analysis of EEG Microstate Sequences in Python. **Frontiers in Neuroinformatics**, [*S. I.*], v. 12, p. 1–10, Junho, 2018. DOI: 10.3389/fninf.2018.00030.

WAN, Zhijiang; LI, Manyu; LIU, Shichang; HUANG, Jiajin; TAN, Hai; DUAN, Wenfeng. EEGformer: A transformer-based brain activity classification method using EEG signal. **Frontiers in Neuroscience**, [*S. I.*], v. 17, 2023. DOI: 10.3389/fnins.2023.1148855.

WANG, Ruofan; WANG, Jiang; YU, Haitao; WEI, Xile; YANG, Chen; DENG, Bin. Power spectral density and coherence analysis of Alzheimer's EEG. **Cognitive neurodynamics**, [*S. I.*], v. 9, n. 3, p. 291–304, 2015. DOI: 10.1007/s11571-014-9325-x.

WANG, Y.; HONG, B.; GAO, X.; GAO, S. Design of electrode layout for motor imagery based brain-computer interface. **Electronics Letters**, [*S. I.*], v. 43, n. 10, p. 557–558, 2007. DOI: 10.1049/el:20070563.

WARTENBERG, Katja E. *et al.* Gap Analysis Regarding Prognostication in Neurocritical Care: A Joint Statement from the German Neurocritical Care Society and the Neurocritical Care Society. **Neurocritical Care**, [*S. I.*], v. 31, n. 2, p. 231–244, 2019. DOI: 10.1007/s12028-019-00769-6.

WESTHALL, Erik *et al.* Standardized EEG interpretation accurately predicts prognosis after cardiac arrest. **Neurology**, [*S. I.*], v. 86, n. 16, p. 1482–1490, 2016. DOI: 10.1212/WNL.0000000000002462.

WILBUR, Michael; SIVAGNANAM, Amutheezan; AYMAN, Afiya; SAMARANAYEKE, Samitha; DUBEY, Abhishek; LASZKA, Aron. **Artificial Intelligence for Smart Transportation**. , 2023.

WILL, Udo; BERG, Eric. Brain wave synchronization and entrainment to periodic acoustic stimuli. **Neuroscience Letters**, [*S. I.*], v. 424, n. 1, p. 55–60, 2007. DOI: 10.1016/j.neulet.2007.07.036.

WILLETT, Francis R. *et al.* A high-performance speech neuroprosthesis. **Nature**, [*S. I.*], v. 620,

n. 7976, p. 1031–1036, 2023. DOI: 10.1038/s41586-023-06377-x.

YANG, Zengyao; SU, Qiruo; XIE, Jieren; SU, Hechong; HUANG, Tianrun; HAN, Chengcheng; ZHANG, Sicong; ZHANG, Kai; XU, Guanghua. Music tempo modulates emotional states as revealed through EEG insights. **Scientific Reports**, [S. l.], v. 15, n. 1, p. 8276, 2025. DOI: 10.1038/s41598-025-92679-1.

YAO, Xiuzhen; LI, Tianwen; DING, Peng; WANG, Fan; ZHAO, Lei; GONG, Anmin; NAN, Wenya; FU, Yunfa. Emotion Classification Based on Transformer and CNN for EEG Spatial–Temporal Feature Learning. **Brain Sciences**, [S. l.], v. 14, n. 3, p. 268, 2024. DOI: 10.3390/brainsci14030268.

ZHANG, Hongyu *et al.* Brain–computer interfaces: the innovative key to unlocking neurological conditions. **International Journal of Surgery**, [S. l.], v. 110, n. 9, p. 5745–5762, 2024. DOI: 10.1097/JS9.0000000000002022.

ZHANG, Xiayin *et al.* The combination of brain-computer interfaces and artificial intelligence: applications and challenges. **Annals of Translational Medicine**, [S. l.], v. 8, n. 11, p. 712–712, 2020. DOI: 10.21037/atm.2019.11.109.

APÊNDICE A - Programas / Funções *Software* de Processamento de EEG Versão Plataforma computacional

A seguir, são apresentadas as funções implementadas no *software* de processamento de EEG, conforme desenvolvido na dissertação de mestrado de (BARBOSA, 2019). Cada função desempenha um papel específico na extração, análise e manipulação dos dados de EEG, contribuindo para a eficiência e reprodutibilidade do processamento.

1 readFilePLG

Realiza a leitura de arquivos no formato PLG (*.plg), correspondentes a exames de eletroencefalograma (EEG), permitindo que os dados registrados sejam interpretados e processados na plataforma computacional.

2 customizeRecordEEG

Personaliza o registro do EEG ao traduzir os nomes dos canais com base em uma variável de tradução e reorganizá-los conforme uma lista de ordenação definida como parâmetro. Esse processo assegura a padronização e a correta disposição dos canais, facilitando a análise e interpretação dos dados.

3 translateChannelNamesByPrefixComparator

Realiza a tradução dos nomes dos canais de EEG com base em um mapeamento fornecido como parâmetro. O mapeamento consiste em uma matriz de duas colunas, onde a primeira coluna contém os prefixos a serem traduzidos e a segunda coluna define os respectivos valores traduzidos.

Cabe ressaltar que o mapeamento não precisa ser um para um, ou seja, a tradução pode ser consolidada em um único valor, mesmo que a matriz de entrada contenha múltiplas linhas. Esse processo permite maior flexibilidade e padronização na nomenclatura dos canais, facilitando a análise e interpretação dos dados.

4 sortChannelsByListNames

Realiza a ordenação dos canais de EEG com base nos nomes contidos nas variáveis *xn*, *nameChannels* e *typeChannels*, seguindo a lista de ordenação fornecida

como parâmetro. Esse procedimento assegura que os canais sejam organizados de forma padronizada e consistente, facilitando a análise e processamento dos dados.

5 splitChannels

Separa os canais de EEG com base em uma lista de referência fornecida como parâmetro, retornando duas listas distintas: uma contendo os canais especificados no parâmetro e outra com os canais restantes. Esse processo permite a organização e categorização dos canais, facilitando análises segmentadas e comparativas conforme a necessidade do estudo.

6 findTypeChannel

Localiza a posição da primeira ocorrência de um tipo de canal específico, conforme o argumento fornecido. Caso o tipo de canal seja encontrado, a função retorna sua posição na lista; caso contrário, retorna -1. Esse procedimento permite a identificação rápida e eficiente de canais específicos, auxiliando na organização e manipulação dos dados de EEG.

7 findNameChannel

Busca a posição da primeira ocorrência de um nome de canal específico, conforme o argumento fornecido. Se o canal for encontrado, a função retorna sua posição na lista; caso contrário, retorna -1. Esse procedimento permite a identificação eficiente de canais, facilitando a manipulação e organização dos dados de EEG.

8 verifyAllValuesInInterval

Verifica se todos os valores de uma matriz fornecida como argumento estão dentro de um intervalo especificado como parâmetro. Caso todos os elementos satisfaçam a condição, a função confirma a validade dos dados; caso contrário, identifica a presença de valores fora do intervalo. Esse procedimento é essencial para controle de qualidade e integridade dos dados, garantindo que os valores estejam dentro dos limites esperados para a análise de EEG.

9 epochSeparator

Função responsável pela segmentação das épocas do EEG, permitindo a divisão do sinal com base em intervalos de tempo previamente definidos. Recebe

como argumentos o tamanho da época e uma *string* no formato MM:SS|MM:SS|MM:SS, em que cada MM:SS representa o instante inicial de uma época. Esse processo assegura a consistência na extração das épocas, garantindo a integridade dos dados para análises subsequentes.

10 validateChannels

Este programa tem como objetivo validar o sinal EEG com base no nível de ruído detectado nos eletrodos. Para isso, realiza um cálculo fundamentado na densidade espectral de potência, determinando:

- O nível do sinal em porcentagem na faixa de 1-40 Hz;
- O nível de ruído na faixa de 58-62 Hz.

Para que um sinal seja totalmente aprovado, os eletrodos devem atender à seguinte condição: o valor máximo de potência na faixa de ruído deve ser igual ou inferior à metade do valor máximo de potência na faixa do sinal, garantindo consistência no processo de validação dos sinais de EEG.

11 computeMeanZeroPowerSignalRXTXFtestXMXFxmFilteredAndNormAndFrequency

Este programa tem como objetivo calcular métricas específicas do sinal EEG, incluindo:

- Média Zero;
- Potência do Sinal;
- Rx e Tx;
- XM e XF;
- fTest;
- XM Filtrado;
- M Normalizado.

Esses cálculos são essenciais para a análise quantitativa do sinal EEG, permitindo a extração de informações relevantes para diferentes aplicações em processamento de sinais e neurociência.

12 computePCPsaveInMatAndExcel

Este programa tem como objetivo calcular a Porcentagem da Contribuição de Potência (PCP) para cada faixa de frequência definida, incluindo:

- Delta, Teta, Alfa, Beta, Gama, Super Gama e Ruído.

Os valores calculados são armazenados em um arquivo especificado como referência. Além disso, caso a opção FLAG de geração de Excel esteja ativada, o programa também exporta os resultados para um arquivo no formato Excel, facilitando a análise e interpretação dos dados.

13 computeFMSaveInMatAndExcel

O cálculo da Frequência Mediana é realizado para cada faixa de frequência pré-definida, incluindo:

- Delta, Teta, Alfa, Beta, Gama, Super Gama e Ruído.

Os valores obtidos são armazenados em um arquivo especificado como referência. Além disso, caso a opção FLAG de geração de Excel esteja ativada, os resultados também são exportados para um arquivo no formato Excel, facilitando a análise e organização dos dados.

14 computeCoherenceLeftWithRightHeadSaveMatAndExcel

O sinal EEG segmentado em épocas é submetido à análise de coerência utilizando a função 'mscohere' da plataforma computacional. Para esse processo, foram criadas duas matrizes:

- *leftHEAD*, correspondente aos eletrodos do lado esquerdo do escalpo cerebral (FP1, F7, F3, T3, C3, T5, P3 e O1);
- *rightHEAD*, correspondente aos eletrodos do lado direito do escalpo cerebral (FP2, F8, F4, T4, C4, T6, P4 e O2).

Com base nessas matrizes, foram calculadas as coerências entre pares de eletrodos simétricos, considerando as seguintes combinações: FP1-FP2, F7-F8, F3-F4, T3-T4, C3-C4, T5-T6, P3-P4 e O1-O2. Os valores obtidos são armazenados no arquivo especificado como referência. Além disso, caso a opção FLAG de geração de

Excel esteja ativada, os resultados também são exportados para um arquivo no formato Excel, permitindo uma análise mais acessível e organizada dos dados.

15 processRecords

Este programa realiza a leitura de um arquivo CSV, estruturado de acordo com um formato específico, cujo exemplo pode ser visualizado no **APÊNDICE C**. Cada linha desse arquivo representa um exame de EEG a ser processado, gerando um arquivo de dados correspondente, no qual são armazenados os cálculos realizados conforme os parâmetros fornecidos.

O arquivo CSV contém as seguintes colunas:

- **Coluna A (Nome Arquivo)** – Nome do arquivo .PLG a ser processado (sem a extensão);
- **Coluna B (Duração Épocas)** – Duração das épocas em segundos;
- **Coluna C (Qtd Épocas)** – Número de épocas a serem segmentadas;
- **Colunas D a M (EpX)** – Instante de início de cada época, no formato mm:ss (minutos:segundos);
 - A quantidade de colunas de épocas é definida pelo valor do campo "Qtd Épocas".
- **Coluna N (Qtd Ruidosos)** – Número de canais identificados como ruidosos pelo médico. Se houver mais de três canais ruidosos, o exame deve ser descartado;
 - A quantidade de colunas para canais ruidosos é determinada pelo valor do campo "**Qtd Ruidosos**".
- **Colunas O a Q (Canal Ruidoso X)** – Lista de canais ruidosos identificados (ex.: FP1, FP2, F7, F3, CZ, P4, etc.);
- **Coluna R (Normal/Coma)** – Identifica se o exame é Normal (100 Hz) ou Coma (30 Hz);
 - Qualquer valor diferente de "COMA" será considerado como "NORMAL".

- **Coluna S (Filtro)** – Define a frequência máxima para o processamento do exame;
- **Coluna T (Nome Saída)** – Nome do arquivo de dados gerado após o processamento da linha correspondente;
- **Coluna U (Gera Excel)** – Define se devem ser gerados arquivos Excel para os cálculos de PCP, FM e Coerência.
 - Deve-se utilizar "NAO" para um processamento mais rápido.

Cada linha do arquivo CSV representa um exame a ser processado, e os cálculos realizados incluem:

- Conversão do arquivo .PLG para o especificado pela plataforma computacional;
- Segmentação das épocas do EEG;
- Validação do exame, verificando se o nível de ruído (58-62 Hz) excede o valor do sinal;
- Cálculo da Porcentagem da Contribuição de Potência (PCP);
- Cálculo da Frequência Mediana (FM);
- Cálculo da Coerência entre hemisfério esquerdo e hemisfério direito;
- Cálculo da Variação da Potência Cerebral (VPC);
- Cálculo da Porcentagem de Segmentos Não Gaussianos (PSNG);
- Cálculo da Porcentagem de Segmentos Não Estacionários (PSNE).

Ao final da execução, é gerado um arquivo de saída no formato Result_X.CSV, onde X representa o nome do arquivo de entrada. Esse arquivo é salvo no mesmo diretório do arquivo CSV original, juntamente com os arquivos de dados correspondentes.

O arquivo Result_X.CSV mantém os mesmos dados do arquivo de entrada, porém com a adição das seguintes colunas, conforme exemplificado no **APÊNDICE D**:

- **Coluna V (Conversão?)** – Indica se a conversão do arquivo .PLG para o formato esperado pela plataforma computacional foi bem-sucedida (SIM/NAO);
- **Coluna W (Canais Ruidosos)** – Lista dos canais identificados como ruidosos na validação por *software*;
- **Coluna X [Exame Válido (Pouco Ruído?)]** – Indica se o exame contém até três canais ruidosos (SIM/NAO);
- **Coluna Y (PCP)** – Confirma se o cálculo do PCP foi realizado com sucesso (SIM/NAO);
- **Coluna Z (Frequência Mediana)** – Confirma se o cálculo da FM foi realizado com sucesso (SIM/NAO);
- **Coluna AA (Coerência)** – Confirma se o cálculo da coerência foi realizado com sucesso (SIM/NAO);
- **Coluna AB (FreqMax Adotada)** – Informa o valor da frequência máxima adotada nos cálculos.

Nota: Todos os arquivos .PLG a serem processados devem estar no mesmo diretório que o arquivo CSV de entrada.

16 readFileCSVForProcessRecords

Realiza a leitura de um arquivo CSV, seguindo a mesma estrutura definida para o programa 15 processRecords. Esse processo assegura a correta interpretação dos dados, permitindo que as informações sejam extraídas e processadas de acordo com os parâmetros estabelecidos no arquivo.

17 saveFileMAT

Realiza a conversão do arquivo .PLG para o formato específico da plataforma computacional, armazenando os valores dos atributos e quantificadores extraídos. Esse processo permite que os dados sejam estruturados de forma compatível para análises subsequentes, garantindo a integridade e acessibilidade das informações.

18 updateFreqMaxAccordingWithBands

Define as novas bandas ou faixas de frequência com base na frequência máxima do exame, retornando também os nomes das bandas ajustadas e a nova frequência máxima permitida.

O algoritmo exclui as faixas que ultrapassam o limite definido, assegurando que apenas as bandas integralmente contidas dentro da frequência máxima estabelecida sejam mantidas. Caso a frequência máxima ocorra dentro de uma faixa, seu valor será ajustado para o limite inferior dessa faixa, garantindo a consistência dos intervalos de análise.

Além disso, a frequência máxima não pode exceder metade da frequência de amostragem nem ser superior a 100 Hz. Quando um novo valor de frequência máxima é definido, as faixas preservadas serão aquelas cujo limite superior permaneça abaixo desse novo valor ajustado.

19 groupEpochsByFrequencies

O programa agrega os valores de frequência de cada época, consolidando-os em uma estrutura do tipo *cell* na plataforma computacional. Esse processo permite a unificação das informações de todas as épocas, possibilitando uma análise abrangente e organizada dos dados de EEG.

20 brainPowerVariation

Realiza o cálculo da Variação da Potência Cerebral (VPC), analisando as flutuações da potência do sinal EEG ao longo do tempo. Esse parâmetro é essencial para avaliar mudanças dinâmicas na atividade cerebral, auxiliando na interpretação de padrões associados a diferentes estados cognitivos e fisiológicos.

21 MRT

Executa o Teste Razão Média (MRT – *Mean Ratio Test*), um método estatístico utilizado para comparar as funções de distribuição espectral de subconjuntos de amostras. Esse teste permite avaliar a estacionariedade do sinal EEG, identificando possíveis variações na distribuição espectral ao longo do tempo (DESTRO-FILHO; FARIA, 2018).

22 myfunc

Executa o teste não paramétrico de Jarque-Bera (JB), um método estatístico amplamente utilizado para verificar a normalidade de uma distribuição. Esse teste apresenta boas propriedades assintóticas de poder e desempenho eficiente em amostras finitas. A construção do teste de gaussianidade baseia-se no princípio do método multiplicador de Lagrange (LM – *Lagrange Multiplier*), permitindo a avaliação da simetria e curtose da distribuição dos dados (DESTRO-FILHO; FARIA, 2018).

23 psngAndPsne

Computa a Porcentagem de Segmentos Não Gaussianos (PSNG), baseada nos resultados do teste de Jarque-Bera (JB), que avalia a normalidade da distribuição dos dados. Além disso, calcula a Porcentagem de Segmentos Não Estacionários (PSNE), determinada a partir do teste Razão Média (MRT – *Mean Ratio Test*), que analisa a estacionariedade do sinal EEG. Esses parâmetros são fundamentais para caracterizar a natureza estatística dos segmentos do sinal, auxiliando na identificação de padrões irregulares e variações dinâmicas.

24 isEqualsErrorRelative

Compara duas variáveis fornecidas como parâmetro, verificando se seus valores são iguais dentro de um limiar de erro relativo, também especificado como parâmetro. Essa abordagem permite considerar pequenas variações numéricas, garantindo maior precisão na validação de dados e robustez na análise de igualdade.

25 isEqualsExamsProcessedErrorRelative

Compara dois exames processados a partir dos arquivos de dados gerados, verificando se apresentam equivalência dentro de um erro relativo aceitável, definido como parâmetro. Essa verificação assegura a consistência dos resultados, permitindo a detecção de diferenças numéricas sutis e garantindo maior precisão na validação da reprodutibilidade dos dados.

26 isEqualsFriedman

Compara duas variáveis fornecidas como parâmetro, verificando sua equivalência linha a linha por meio do teste de Friedman. Esse teste estatístico não

paramétrico avalia diferenças entre distribuições emparelhadas, permitindo a detecção de variações significativas entre os conjuntos de dados.

27 validateFriedmanCellVector

Compara dois vetores do tipo *cell* (A e B) na plataforma computacional, avaliando sua equivalência estatística por meio do teste de Friedman.

28 isEqualExamsProcessedFriedman

Compara dois arquivos gerados a partir de processamentos anteriores, avaliando sua equivalência estatística com base em um p-valor aceitável. Essa verificação permite identificar diferenças estatisticamente significativas entre os resultados, assegurando maior precisão na validação da reprodutibilidade dos dados.

29 testCompareExameByCsv

Realiza a leitura de um arquivo CSV, no qual a primeira coluna contém o arquivo de referência e a segunda coluna especifica o arquivo a ser comparado. Ao final do processamento, são gerados dois arquivos de resultado, apresentando, linha a linha, a saída da comparação baseada no erro relativo e no teste estatístico de Friedman. Essa abordagem permite uma avaliação detalhada da equivalência dos dados, assegurando maior precisão na análise estatística das diferenças entre os arquivos comparados.

APÊNDICE B - Descrição das variáveis importantes do *Software* de Processamento de EEG Versão Plataforma computacional

A seguir, são descritas as principais variáveis geradas pelo processamento do EEG durante a execução da função `processRecords`, conforme documentado em (BARBOSA, 2019). Essas variáveis representam os principais parâmetros e quantificadores extraídos, sendo fundamentais para a análise e interpretação dos dados processados.

1 `nameChannels` (vetor de `cellstr`)

Vetor de tamanho L , onde L representa a quantidade de canais EEG no registro (comumente, $L = \text{numberChannels} = 20$). Os nomes dos canais possuem correspondência direta com as variáveis "`xn`" e "`typeChannels`", seguindo a ordem:

Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1, Oz, O2.

2 `typeChannels` (vetor `cellstr`)

Vetor de tamanho L , onde L representa a quantidade de canais EEG no registro (comumente, $L = \text{numberChannels} = 20$). Esse vetor armazena o tipo correspondente a cada canal, que pode assumir valores como EEG, FOTO, EKG, entre outros. Os tipos dos canais possuem correspondência direta com as variáveis "`xn`" e "`nameChannels`", garantindo a correta identificação e categorização dos sinais registrados.

3 `xn` (matriz de escalares)

Matriz de dimensão $L \times N$, onde L representa a quantidade de canais EEG e N corresponde ao tempo discreto do registro. Essa matriz contém o sinal EEG convertido para o formato específico da plataforma computacional, onde:

- As L linhas correspondem aos canais identificados no vetor "`nameChannels`";
- As N colunas representam os instantes de tempo discretizados.

Cada elemento da matriz está expresso em microvolts (μV), representando a amplitude do sinal EEG em um determinado instante. A organização da matriz segue

a convenção: $L = \text{numberChannels}$ (número de canais EEG) e $N =$ número de amostras temporais.

4 numberChannels (escalar)

Número total de canais na matriz "xn", onde numberChannels é igual a L , representando a quantidade de canais EEG no registro.

5 N (escalar)

Número total de amostras por canal, representando a quantidade de instantes temporais discretizados registrados para cada canal EEG. Esse parâmetro define a resolução temporal do sinal, sendo fundamental para a análise e processamento dos dados adquiridos.

6 T (escalar)

Período de amostragem, expresso em segundos, determinado com base na taxa de amostragem do sinal EEG. Esse valor representa o intervalo de tempo entre amostras consecutivas.

7 Fa (escalar)

Frequência de amostragem da aquisição do sinal EEG, expressa em hertz (Hz). Esse parâmetro define o número de amostras coletadas por segundo, influenciando diretamente a resolução temporal do registro e a fidelidade da representação do sinal cerebral.

8 t (vetor de escalares)

Vetor de tempo, expresso em segundos, com dimensão N , correspondente à quantidade de amostras do sinal EEG. Esse vetor é utilizado para a representação temporal dos dados, permitindo a correta plotagem e análise da evolução do sinal ao longo do tempo.

9 totalTime (escalar)

Tempo total do exame, expresso em segundos, correspondente à duração completa do registro EEG. Esse parâmetro é obtido a partir do número total de

amostras (N) e da frequência de amostragem, sendo fundamental para a análise temporal do sinal.

10 freqMax (escalar)

Frequência de corte, expressa em hertz (Hz), correspondente ao filtro passa-baixa que deve ser aplicado ao sinal EEG. O valor do corte varia conforme a condição do exame, sendo definido como 100 Hz para exames normais e 30 Hz para exames em coma. Esse parâmetro é essencial para a eliminação de altas frequências indesejadas, preservando apenas as componentes relevantes do sinal.

11 variablesInformation (matriz de cellString)

Fornece uma descrição resumida das variáveis armazenadas no arquivo dos dados, detalhando seus significados e funções no processamento do sinal EEG. Essas variáveis representam os principais parâmetros extraídos e calculados, sendo fundamentais para a análise e interpretação dos dados registrados.

12 dayOfConversion (string)

Registra a data de conversão do arquivo PLG para o arquivo de dados, permitindo o rastreamento do momento em que o processamento foi realizado. Esse dado é essencial para a organização, auditoria e reprodutibilidade dos resultados.

13 remainingChannels (matriz de escalares)

Armazena os registros de canais do EEG convertidos para o formato da plataforma computacional, que não estão presentes na lista especificada em listChannels. A matriz gerada possui dimensão $LR \times N$, onde:

- LR representa a quantidade de canais EEG que não pertencem a listChannels (comumente $LR = 1$, correspondente ao canal FOTO);
- N corresponde ao número total de amostras, cujos valores estão expressos em microvolts (μV) e representam a amplitude do sinal em cada instante.

Essa estrutura permite o armazenamento separado de canais auxiliares, garantindo a integridade dos dados principais e preservando informações relevantes para análises complementares.

14 remainingChannelsName (vetor cellstr)

Lista os nomes dos canais presentes no exame .PLG, mas que não estão incluídos na relação especificada em listChannels. Esse vetor possui dimensão LR, onde LR representa a quantidade de canais EEG restantes.

Cada elemento desse vetor tem correspondência direta com as variáveis "remainingChannelsType" e "remainingChannels", assegurando a correta identificação dos canais auxiliares que foram excluídos da lista principal.

15 remainingChannelsType (vetor cellstr)

Armazena os tipos dos canais presentes no exame .PLG, mas que não fazem parte da lista definida em listChannels. Esse vetor possui dimensão LR, onde LR representa a quantidade de canais EEG restantes.

Cada elemento desse vetor tem correspondência direta com as variáveis "remainingChannels" e "remainingChannelsName", garantindo a correta categorização dos canais auxiliares excluídos da lista principal.

16 epochsValues (vetor de cell)

Vetor de dimensão nEpochs, onde nEpochs representa o número de épocas definidas pelo usuário (comumente 10 épocas). Cada posição desse vetor contém uma célula que armazena uma matriz de dimensão $L \times \text{NAE}$, onde:

- L corresponde à quantidade de canais EEG no registro (comumente $L = 20$);
- NAE representa o número de amostras por época, calculado como $f_a \times \text{duração da época (segundos)}$, onde f_a é a frequência de amostragem.

Essa estrutura permite a segmentação e organização dos dados EEG por épocas, facilitando a análise temporal do sinal.

17 epochsTimes (vetor de cell)

Vetor que armazena a representação dos instantes de tempo associados a cada época, com dimensão nEpochs, onde nEpochs corresponde ao número de épocas definidas pelo usuário.

Cada posição desse vetor contém uma célula que armazena um vetor de tamanho NAE, onde:

- NAE representa o número de amostras por época, determinado por $f_a \times \text{duração da época (em segundos)}$, sendo f_a a frequência de amostragem;
- Cada célula contém o conjunto de instantes de tempo associados aos dados registrados na respectiva época.

Essa estrutura permite a associação precisa entre os dados do EEG e os instantes de tempo correspondentes, facilitando a análise temporal do sinal.

18 epochsValuesZerosInNoiseChannel (vetor de cell)

Semelhante a epochsValues, porém com os valores dos canais considerados ruidosos substituídos por zeros. A remoção dos dados ocorre tanto para os canais identificados como ruidosos durante o processamento quanto para aqueles classificados como ruidosos na avaliação médica.

Essa abordagem permite a manutenção da estrutura dos dados temporais, ao mesmo tempo que elimina a influência de canais comprometidos.

19 PCP (vetor de cell)

Vetor de dimensão nFrequencies, onde nFrequencies corresponde ao número de faixas de frequência analisadas (comumente nFrequencies = 7, abrangendo Delta, Teta, Alfa, Beta, Gama, Super Gama e Ruído).

Cada elemento desse vetor contém uma matriz de dimensão $L \times \text{nEpochs}$, onde:

- L representa a quantidade de canais EEG do registro (comumente $L = 20$);
- nEpochs corresponde ao número de épocas do exame (comumente nEpochs = 10).

Essa matriz armazena valores escalares que representam a contribuição de potência de cada ritmo cerebral em cada época, possibilitando a análise da distribuição espectral do sinal EEG ao longo do tempo.

20 powerSignal (matriz de escalares)

Matriz de dimensão $L \times nEpochs$, onde:

- L representa a quantidade de canais EEG do registro (comumente $L = 20$);
- $nEpochs$ corresponde ao número de épocas do exame (comumente $nEpochs = 10$).

Essa matriz armazena a potência total de cada época para cada canal EEG, permitindo a análise da distribuição de energia do sinal ao longo do tempo e a comparação entre diferentes períodos do exame.

21 frequenciesNamePCP (vetor de cellstr)

Vetor de dimensão $nFrequencies$, armazenando os nomes das faixas de frequência associadas à variável PCP. Os valores contidos nesse vetor correspondem às principais bandas do EEG, sendo:

- Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído.

Os nomes das frequências são idênticos aos armazenados na variável "frequenciesName", garantindo consistência na nomenclatura utilizada no processamento e análise do sinal EEG.

22 frequenciesPCP (matriz de escalares)

Matriz de dimensão $nFrequencies \times 2$, armazenando os intervalos de frequência (em Hz) associados à variável PCP. Cada linha dessa matriz corresponde a uma das faixas de frequência analisadas, apresentando os limites inferior e superior de cada banda espectral.

Essa matriz possui uma relação direta com as linhas da variável "frequenciesNamePCP", garantindo consistência na definição das faixas espectrais utilizadas no processamento do EEG.

23 FM (vetor de cell)

Vetor de dimensão $nFrequencies$, onde $nFrequencies$ corresponde ao número de faixas de frequência analisadas (comumente $nFrequencies = 7$, abrangendo Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído).

Cada elemento desse vetor contém uma matriz de dimensão $L \times nEpochs$, onde:

- L representa a quantidade de canais EEG do registro (comumente $L = 20$);
- $nEpochs$ corresponde ao número de épocas do exame (comumente $nEpochs = 10$).

Essa matriz armazena valores escalares que representam a Frequência Mediana de cada ritmo cerebral ao longo das épocas, possibilitando a análise da distribuição espectral do sinal EEG e suas variações temporais.

24 frequenciesNameFM (vetor de cellstr)

Vetor de dimensão $nFrequencies$, armazenando os nomes das faixas de frequência (em Hz) associadas à variável FM. As frequências representadas incluem:

- Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído.

Os valores contidos nesse vetor são idênticos aos da variável "frequenciesName", garantindo consistência na nomenclatura das bandas espectrais utilizadas na análise da Frequência Mediana do sinal EEG.

25 frequenciesFM (matriz de escalares)

Matriz de dimensão $nFrequencies \times 2$, armazenando os intervalos de frequência (em Hz) associados à variável FM. Cada linha dessa matriz corresponde a uma das faixas de frequência analisadas, apresentando os limites inferior e superior de cada banda espectral.

Essa matriz possui uma relação direta com as linhas da variável "frequenciesNameFM", garantindo consistência na definição das faixas espectrais utilizadas no processamento do EEG.

26 COR_PairsOfElectrodes (vetor de cell)

Vetor de dimensão $nPairsOfElectrodes$, onde $nPairsOfElectrodes$ representa o número de pares de eletrodos analisados na coerência (comumente $nPairsOfElectrodes = 8$).

Cada elemento desse vetor contém uma matriz de dimensão $nEpochs \times Y$, onde:

- $nEpochs$ corresponde à quantidade de épocas selecionadas no exame (comumente $nEpochs = 10$);
- Y representa o número de frequências geradas pela função 'mscohere' da plataforma computacional, utilizada para o cálculo da coerência.

Cada matriz armazena os valores de coerência calculados para um par específico de eletrodos, seguindo a seguinte ordenação:

1. FP1 – FP2
2. F7 – F8
3. F3 – F4
4. T3 – T4
5. C3 – C4
6. T5 – T6
7. P3 – P4
8. O1 – O2

Essa estrutura permite a análise detalhada da conectividade funcional entre pares de eletrodos, facilitando a interpretação das relações entre diferentes regiões cerebrais ao longo das épocas do exame.

27 CORRELATION (vetor de cell)

Vetor de dimensão $nFrequencies$, onde $nFrequencies$ representa o número de faixas de frequência analisadas (comumente $nFrequencies = 7$, abrangendo Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído).

Cada elemento desse vetor contém um vetor de cells de dimensão $nPairsOfElectrodes$, onde $nPairsOfElectrodes$ corresponde ao número de pares de eletrodos formados pela combinação dos eletrodos do hemisfério esquerdo com os do hemisfério direito (comumente $nPairsOfElectrodes = 8$).

Cada elemento do vetor de pares armazena uma matriz de dimensão $nEpochs \times NY$, onde:

- $nEpochs$ representa a quantidade de épocas selecionadas no exame (comumente $nEpochs = 10$);
- NY corresponde à quantidade de frequências analisadas por banda ou faixa de frequência, conforme a variável Y de "COR_PairsOfElectrodes".

Essa estrutura possibilita a análise da coerência entre pares de eletrodos para cada banda de frequência, fornecendo informações sobre a conectividade funcional do cérebro ao longo do tempo.

28 frequenciesNameCORR (vetor de cellstr)

Vetor de dimensão $nFrequencies$, armazenando os nomes das faixas de frequência associadas à variável CORRELATION. Essas faixas incluem:

- Delta, Teta, Alfa, Beta, Gama, Supergama e Ruído.

Os valores contidos nesse vetor são idênticos aos da variável "frequenciesName", garantindo consistência na nomenclatura das bandas espectrais utilizadas na análise de coerência do sinal EEG.

29 frequenciesCORR (matriz de escalares)

Matriz de dimensão $nFrequencies \times 2$, armazenando os intervalos de frequência (em Hz) associados à variável CORRELATION. Cada linha dessa matriz corresponde a uma das faixas de frequência analisadas, apresentando os limites inferior e superior de cada banda espectral.

Essa matriz possui uma relação direta com as linhas da variável "frequenciesNameCORR", garantindo consistência na definição das faixas espectrais utilizadas no processamento do EEG.

30 F_cor (vetor de escalares)

Vetor de frequências em hertz (Hz), com dimensão Y , gerado pela função 'mscohere' da plataforma computacional. Esse vetor contém os valores de frequência

analisados durante o cálculo da coerência, sendo essencial para a interpretação dos resultados espectrais do sinal EEG.

APÊNDICE C - Arquivo .CSV de entrada para o processRecords

Nome Arquivo PLG	Duração Epocas (seg)	Qtd. Epocas	Ep1	Ep2	Ep3	Ep4	Ep5	Ep6	Ep7	Ep8	Ep9	Ep10	Qtd Ruídos	Canal Ruído 1	Canal Ruído 2	Canal Ruído 3	Normal /Coma	Filtro	Nome Saída	Gerar Excel
0011901'	2	10	01:49	01:51	01:53	01:55	01:58	02:00	02:14	02:23	02:41	02:45					COMA	35	C0011901_ME_OUTROS	SIM
0013501'	2	10	12:28	12:30	12:32	12:34	12:36	12:38	12:42	12:49	12:56	13:13	3	FP1	FP2	F4	COMA	35	C0013501_ME_COMA_METABOLICO	SIM
0303001'	2	10	03:56	03:58	04:05	04:07	04:26	05:13	06:06	06:21	08:27	09:29					COMA	35	C0303001_ME_OUTROS	SIM
0372501'	2	10	15:44	16:11	17:23	17:44	18:21	18:36	18:48	18:50	19:00	19:02	3	F4	F8	Oz	COMA	35	C0372501_ME_OUTROS	SIM
0373701'	2	10	09:53	09:55	09:57	10:01	10:03	10:28	10:35	11:02	11:52	12:17	2	T5	F7		COMA	35	C0373701_COMA_METABÓLICO	SIM
0375201'	2	10	10:36	10:38	10:40	10:42	10:44	11:23	11:28	11:35	12:16	12:23	1	Oz			COMA	35	C0375201_ME_COMA_METABÓLICO	SIM
0726001'	2	10	00:32	00:34	00:36	00:38	00:46	01:00	01:39	02:05	02:45	03:01	2	FP2	F4		COMA	35	C0726001_ME_OUTROS	SIM
0932801'	2	10	00:01	00:03	00:05	00:07	00:22	00:27	00:44	01:04	01:15	01:38	1	FP2			COMA	35	C0932801_ME_OUTROS	SIM
1045901'	2	10	02:54	02:56	02:58	03:00	03:10	04:36	05:23	06:30	06:50	09:23					COMA	35	C1045901_ME_AVE	SIM
1048001'	2	10	00:48	00:50	00:52	00:54	01:33	02:24	03:03	05:00	07:26	07:39					COMA	35	C1048001_ME_TCE	SIM
1054001'	2	10	00:56	04:04	04:37	05:43	06:08	06:54	07:25	07:27	07:29	07:31					COMA	35	C1054001_ME_AVE	SIM

APÊNDICE D - Arquivo .CSV de resultado do processamento do APÊNDICE C apenas com as colunas adicionais

Nome Arquivo PLG	Conversão?	Canais Ruidosos	Exame Valido (POUCO RUIDO)?	PCP	Frequência Mediana	Coerência	FreqMax Adotada
0011901'	SUCCESS		SIM	SIM	SIM	SIM	30.00
0013501'	SUCCESS		SIM	SIM	SIM	SIM	30.00
0303001'	SUCCESS	F7	SIM	SIM	SIM	SIM	30.00
0372501'	SUCCESS	F7	NAO	SIM	SIM	SIM	30.00
0373701'	SUCCESS	F7	SIM	SIM	SIM	SIM	30.00
0375201'	SUCCESS	F7	SIM	SIM	SIM	SIM	30.00
0726001'	SUCCESS		SIM	SIM	SIM	SIM	30.00
0932801'	SUCCESS		SIM	SIM	SIM	SIM	30.00
1045901'	SUCCESS		SIM	SIM	SIM	SIM	30.00
1048001'	SUCCESS		SIM	SIM	SIM	SIM	30.00
1054001'	SUCCESS		SIM	SIM	SIM	SIM	30.00
1054501'	SUCCESS		SIM	SIM	SIM	SIM	30.00

APÊNDICE E - Arquivo .CSV de entrada para o processRecords após melhorias

Nome Arquivo PLG	Funcao Filtro	Limiar de erro	Duracao Epocas (segundos)	Qtd Epocas	Ep1	Ep2	Ep3	Ep4	Ep5	Medico Canais Ruidosos	Filtro Passa Baixa	Quantificadores	Parametros	Canais a Processar	Gerar Excel	Nome Saida
'0005201'	teste		2	5	3:14	3:16	3:18	3:20	3:23	O2,FP1		PCP,VPC	Taumax=30	O2	NAO	Vteste
1109101'	teste		2	5	9:55	9:57	9:59	10:01	05:57	O2	35	FM,PSNG		O2,FP1	NAO	Vpassou
'0013201'	teste		2	5	04:25	04:42	04:53	05:06	05:16			TODOS			NAO	V78
'0013201'	teste		2	SEQUENCIAL=8	04:25							COERENCIA			NAO	VSEQ

APÊNDICE F - Exemplo de um arquivo Excel de saída de cálculo do teste de Friedman

	SILENCIO								MUSICA FAVORITA								MUSICA DESGOSTADA										
	DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO				
FP1	0,023652	0,000236	0,001586	7,7E-08	0,143918	0,023652	0,081125		0,09896	0,322199	0,278263	0,053266	0,509275	7,5E-05	0,509275		0,065992	0,924886	1	0,008294	0,108984	0,539991	0,203092				
FP2	0,081125	1,29E-07	0,042658	5,03E-05	0,004033	0,571608	5,92E-08		0,09896	0,053266	0,257899	0,777297	0,539991	0,00721	0,131428		0,450701	0,299694	0,571608	0,000236	0,604078	0,396144	0,157299				
F7	0,813664	0,186858	0,01621	1,16E-05	0,143918	0,157299	1,44E-05		0,777297	0,4795	0,962401	0,089686	0,186858	0,008294	0,345779		0,37043	0,065992	0,509275	0,089686	0,089686	0,509275	0,203092				
F3	0,345779	0,005414	7,52E-06	0,089686	0,143918	0,053266	3,35E-05		0,171602	0,203092	0,345779	0,962401	0,887537	0,081125	5,03E-05		0,509275	0,571608	0,637352	0,924886	0,571608	0,962401	0,777297				
FZ	0,038063	0,018422	2,72E-05	0,345779	0,22033	0,509275	3,84E-06		0,422907	0,4795	0,4795	0,203092	0,396144	0,186858	0,000817		0,850436	0,450701	0,22033	0,22033	0,962401	0,143918	0,422907				
F4	0,001348	0,002979	0,012474	0,238593	0,203092	0,000817	9,37E-06		0,741413	0,073239	0,813664	0,4795	0,671373	0,004033	0,033895		1	0,962401	0,777297	0,012474	0,604078	0,706082	0,850436				
F8	0,539991	0,004678	0,012474	0,108984	0,850436	0,010909	1,44E-10		0,008294	0,009522	0,887537	0,345779	0,053266	0,002183	0,000284		0,571608	0,299694	0,539991	0,014234	0,059346	0,813664	0,081125				
T3	0,604078	0,059346	4,54E-08	1,06E-10	0,038063	0,005414	1,07E-14		0,108984	0,038063	0,005414	0,396144	0,777297	0,000134	0,053266		0,4795	0,026719	0,571608	0,00034	0,014234	0,008294	2,72E-05				
C3	0,887537	0,038063	8,86E-09	0,131428	0,047715	0,422907	0,00034		0,741413	0,345779	0,450701	0,539991	0,322199	0,539991	0,030124		0,089686	0,887537	0,604078	0,850436	0,01621	0,038063	0,014234				
CZ	0,924886	0,004678	9,37E-06	0,637352	0,571608	0,396144	0,000407		0,22033	0,059346	0,018422	0,604078	0,850436	0,924886	0,053266		0,257899	0,924886	0,157299	0,37043	0,962401	0,038063	0,539991				
C4	0,813664	0,008294	0,000817	0,637352	0,059346	0,119795	0,000486		0,009522	0,009522	0,081125	0,299694	0,741413	0,020895	0,171602		0,509275	0,422907	0,143918	0,850436	0,143918	0,108984	0,012474				
T4	0,509275	0,001143	0,00034	6,03E-06	4,11E-05	0,000284	3,48E-16		0,023652	0,741413	0,509275	0,171602	0,604078	0,012474	4,54E-08		0,962401	0,813664	0,345779	0,089686	0,026719	0,059346	2,21E-05				
T5	0,850436	0,000967	1,92E-06	0,257899	0,171602	0,322199	0,089686		0,038063	0,887537	0,257899	0,004678	0,018422	0,22033	0,887537		0,322199	0,089686	0,059346	0,278263	0,059346	0,143918	0,000967				
P3	0,601029	0,002745	1,24E-06	0,234654	0,183165	0,81212	0,008933		0,140566	0,634514	0,128203	0,010256	0,73931	0,849189	0,775468		0,087011	0,568366	0,962084	0,703718	0,419004	0,096145	0,057233				
PZ	0,171602	0,171602	3,84E-06	0,924886	0,008294	0,741413	0,006254		0,010909	0,777297	0,143918	1	0,278263	0,023652	0,637352		0,257899	0,186858	0,278263	0,450701	0,01621	0,671373	0,026719				
P4	0,777297	0,005414	2,43E-06	0,637352	0,014234	0,065992	0,00347		0,143918	0,073239	0,157299	0,539991	0,396144	0,065992	0,157299		0,396144	0,37043	0,038063	0,604078	0,37043	0,131428	0,09896				
T6	0,604078	0,004033	6,61E-14	0,637352	0,047715	0,00721	0,00034		0,01621	0,741413	0,023652	0,131428	0,299694	0,006254	0,020895		0,131428	0,157299	0,299694	0,924886	0,008294	0,37043	0,000284				
O1	0,706082	0,023652	3,21E-14	0,008294	0,119795	0,203092	0,008294		0,203092	0,157299	0,065992	0,012474	0,850436	0,278263	0,396144		0,033895	1,44E-05	0,004678	0,813664	0,278263	0,345779	0,09896				
OZ	1	0,005414	1,54E-08	0,171602	0,450701	0,047715	0,000967		0,059346	0,186858	0,038063	0,042658	0,131428	0,278263	0,450701		0,009522	0,00721	0,203092	0,924886	0,073239	0,706082	0,026719				
O2	0,924886	0,002553	1,54E-12	0,741413	0,004678	0,345779	1,92E-06		0,047715	0,4795	0,143918	0,030124	0,741413	0,038063	0,01621		0,073239	0,000689	0,000284	0,741413	0,777297	0,671373	0,741413				
	DO CONTINUO								SOL BAIÃO								RUIDO BRANCO										
	DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO				
FP1	0,005414	0,000817	0,081125	0,257899	0,396144	0,157299	0,119795		0,143918	0,924886	0,238593	0,813664	0,012474	0,637352	8,86E-09		0,741413	0,119795	0,322199	0,203092	0,257899	0,450701	0,108984				

FP2	0,850436	9,99E-08	0,37043	0,539991	0,143918	0,09896	0,604078		1	0,887537	0,777297	0,37043	0,108984	0,020895	4,11E-05		0,671373	0,108984	0,119795	0,604078	0,637352	0,089686	0,238593
F7	0,157299	0,539991	0,4795	0,345779	0,396144	0,671373	0,539991		0,020895	0,09896	0,059346	0,042658	0,924886	0,637352	3,06E-06		0,020895	0,741413	0,000196	0,000111	0,962401	0,637352	0,157299
F3	0,671373	0,081125	0,37043	0,924886	0,396144	0,604078	0,038063		0,4795	0,322199	0,539991	0,962401	0,671373	0,203092	0,000162		0,604078	0,539991	0,203092	0,257899	0,422907	0,171602	0,09896
FZ	0,604078	0,119795	0,777297	0,706082	0,09896	0,278263	0,37043		0,539991	0,813664	0,706082	0,509275	0,238593	0,604078	4,11E-05		0,257899	0,539991	0,37043	0,887537	0,604078	0,777297	0,023652
F4	0,813664	0,030124	0,637352	0,396144	0,509275	0,257899	0,038063		0,671373	0,238593	0,637352	0,322199	0,706082	0,033895	0,001348		0,924886	0,322199	0,450701	0,741413	0,509275	0,4795	0,186858
F8	0,777297	0,023652	0,033895	0,604078	0,238593	0,026719	0,539991		0,539991	0,539991	1	0,203092	0,396144	0,962401	0,010909		0,450701	0,047715	0,962401	0,509275	0,604078	0,604078	0,813664
T3	0,073239	0,299694	0,089686	0,924886	0,962401	0,887537	0,01621		0,131428	0,042658	0,4795	0,000407	0,005414	0,637352	1,92E-06		0,813664	0,671373	0,962401	0,396144	0,637352	0,706082	0,741413
C3	0,509275	0,081125	0,004678	0,278263	0,813664	0,604078	0,637352		0,065992	0,813664	0,450701	0,571608	0,509275	0,089686	0,000196		0,257899	0,131428	0,850436	1	0,4795	0,924886	0,238593
CZ	0,887537	0,257899	0,081125	0,37043	0,37043	0,073239	0,850436		0,053266	0,422907	0,089686	0,257899	0,706082	0,22033	0,000817		0,171602	0,322199	0,741413	0,299694	0,396144	0,539991	0,033895
C4	0,813664	0,047715	0,119795	0,065992	0,671373	0,033895	0,850436		0,108984	0,539991	0,637352	0,422907	0,539991	0,278263	0,001143		0,033895	0,637352	0,962401	0,924886	0,186858	0,604078	0,299694
T4	0,887537	0,001863	0,299694	0,059346	0,37043	0,09896	0,186858		0,962401	0,924886	0,509275	0,345779	0,006254	0,143918	7,76E-13		0,887537	0,322199	0,450701	0,186858	0,047715	0,539991	0,000967
T5	1	0,065992	0,171602	0,053266	1	0,4795	0,777297		0,4795	0,962401	0,671373	1	0,238593	0,345779	0,000817		0,322199	0,813664	0,422907	0,450701	0,119795	0,850436	0,422907
P3	0,849189	0,096145	0,153826	1	0,253904	0,274227	0,4758		0,003734	0,634514	0,601029	0,703718	0,366405	0,703718	0,318132		0,032418	0,536577	0,253904	0,849189	0,536577	0,21646	0,106029
PZ	0,257899	0,813664	0,081125	0,018422	0,571608	0,962401	0,887537		0,004678	0,450701	0,741413	0,203092	0,887537	0,018422	0,053266		0,006254	0,962401	0,278263	0,203092	0,131428	0,143918	0,186858
P4	0,706082	0,238593	0,813664	0,887537	0,422907	0,671373	0,131428		0,962401	0,030124	0,637352	0,038063	0,396144	0,257899	0,065992		0,186858	0,157299	0,604078	0,671373	0,299694	0,604078	0,089686
T6	0,813664	0,010909	0,023652	0,042658	0,238593	0,020895	0,850436		0,741413	0,238593	0,257899	0,278263	0,637352	0,00347	0,203092		0,081125	0,047715	0,026719	0,962401	0,299694	0,009522	0,073239
O1	0,4795	1	0,00347	0,450701	0,089686	0,322199	0,22033		0,850436	0,396144	0,706082	0,604078	0,924886	0,22033	0,012474		0,509275	0,422907	0,924886	0,089686	0,422907	0,924886	0,962401
OZ	0,322199	0,065992	0,157299	0,571608	0,671373	0,157299	0,962401		0,604078	0,604078	0,238593	0,171602	0,637352	0,637352	0,005414		0,777297	0,706082	0,171602	0,604078	0,322199	0,278263	0,09896
O2	0,604078	0,131428	0,030124	0,422907	0,01621	0,706082	0,033895		0,887537	0,706082	0,924886	0,278263	0,509275	0,887537	6,15E-05		0,962401	0,706082	0,924886	0,604078	0,604078	0,322199	0,000579

APÊNDICE G - Exemplo de um arquivo Excel de saída do cálculo do VAP

	SILENCIO								MUSICA FAVORITA							MUSICA DESGOSTADA							
	DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO
FP1	0,595768	0,87009	0,259956	0,316259	0,090268	0,016973	0,001812		1,194153	0,070018	0,165669	0,135871	0,034423	0,027143	0,000894		0,231098	0,010624	0,061997	0,0845	0,117522	0,003494	0,001135
FP2	0,841157	0,968848	0,118659	0,185927	0,247707	0,003693	0,002762		0,580901	0,22257	0,033174	0,04875	0,021857	0,019032	4,56E-05		0,060831	0,111802	0,07541	0,127447	0,101485	0,005587	0,001354
F7	0,100812	0,447685	0,111703	0,249798	0,1016	0,003482	0,003384		0,680415	0,234233	0,129694	0,071264	0,103651	0,016715	0,001167		0,118884	0,326511	0,028536	0,078738	0,072481	0,006861	0,000265
F3	0,802337	0,593241	0,233814	0,21623	0,12919	0,012364	0,001566		0,746025	0,081298	0,125294	0,049551	0,052737	0,016366	0,000884		0,55486	0,302941	0,085922	0,074153	0,116635	0,00278	0,001606
FZ	1,220249	1,103765	0,351018	0,148131	0,170803	0,002096	0,003182		0,002474	0,237588	0,015623	0,137978	0,020239	0,014218	0,001528		0,465123	0,040607	0,183472	0,20062	0,102097	0,013392	0,000587
F4	1,417652	0,782454	0,161873	0,039497	0,11543	0,012444	0,00183		0,063204	0,388215	0,219216	0,191286	0,105064	0,01787	0,000302		0,421018	0,230413	0,126361	0,248263	0,006502	0,001409	0,000873
F8	0,334084	0,827649	0,304923	0,266913	0,117089	0,025826	0,004453		1,054843	0,458895	0,270228	0,053122	0,235478	0,030943	0,001809		0,344164	0,11265	0,252466	0,159937	0,328428	0,00464	0,002178
T3	0,093229	0,490714	0,617214	0,571319	0,17662	0,035254	0,006291		1,203961	0,78414	0,365087	0,295182	0,146858	0,049381	0,001092		0,769734	0,873576	0,138364	0,529608	0,454545	0,058112	0,007222
C3	0,38463	0,742916	0,571433	0,050461	0,069973	0,012148	0,001677		0,715608	0,213236	0,158208	0,049848	0,015907	0,010285	0,001518		0,987762	0,26985	0,068035	0,006757	0,103764	0,02064	0,001428
CZ	0,155539	0,501053	0,353531	0,127143	0,010999	0,010564	0,001519		0,674348	0,378654	0,418251	0,188961	0,01085	0,009193	0,000578		0,655418	0,37478	0,28438	0,092795	0,123028	0,004543	0,000501
C4	0,1149	0,926192	0,440222	0,075633	0,169607	0,017318	0,002063		1,118511	0,442846	0,206013	0,014186	0,025011	0,01859	7,29E-05		1,006737	0,121336	0,308309	0,131486	0,123531	0,009319	0,001649
T4	0,506144	1,195034	0,579707	0,768204	0,450421	0,030686	0,007142		1,099557	0,396413	0,132582	0,16891	0,050356	0,024892	0,001509		0,230889	0,097096	0,014971	0,144818	0,191009	0,037895	0,0044
T5	0,560703	1,336285	0,728461	0,032832	0,085702	0,0094	0,001098		0,742546	0,141332	0,149544	0,454682	0,314168	0,015863	0,000119		0,51543	0,743569	0,273174	0,178521	0,272147	0,00149	0,002192
P3	0,150899	0,896863	0,357998	0,055094	0,087976	0,000151	0,000322		0,623005	0,151914	0,091214	0,154402	0,024343	0,001802	0,000471		0,76816	0,219163	0,385205	0,062172	0,088874	0,022102	0,001664
PZ	0,079334	1,089736	0,417561	0,222579	0,173357	0,002935	0,00152		1,519129	0,053681	0,185168	0,065906	0,234743	0,016068	0,001271		0,891543	0,518816	0,25812	0,036177	0,254184	0,000318	0,002268
P4	0,134106	0,624801	0,573596	0,168705	0,213661	0,005233	0,00274		1,227517	0,300564	0,077168	0,104916	0,119754	0,007457	0,000268		0,797669	0,271167	0,354279	0,055187	0,085058	0,010509	0,000969
T6	0,988035	1,444386	0,774728	0,099487	0,010429	0,020192	0,002907		1,219627	0,071788	0,173884	0,169421	0,255772	0,02589	0,00079		0,494893	0,805922	0,166282	0,292263	0,335911	0,003357	0,002607
O1	0,369817	1,284894	0,888519	0,07282	0,192045	0,00125	0,002317		1,330678	0,611184	0,227753	0,208227	0,027222	0,00764	0,000563		1,344151	1,313259	0,265216	0,098713	0,010549	0,004665	0,001223
OZ	0,423165	1,34282	0,896317	0,103013	0,237875	0,000982	0,002816		1,440096	0,40746	0,28609	0,118972	0,150678	0,003382	5,45E-05		1,112802	0,715989	0,210891	0,039545	0,051141	0,005216	0,000682
O2	0,309195	0,903936	0,983046	0,024451	0,276322	0,002082	0,003779		0,919053	0,398915	0,16237	0,042094	0,110923	0,019403	0,000658		0,912628	1,285001	0,323655	0,06671	0,101271	0,003086	8,19E-05
	DO CONTINUO								SOL BAIÃO								RUIDO BRANCO						
	DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO
FP1	0,447944	0,341924	0,220192	0,121369	0,053172	0,014114	0,000847		0,695204	0,163582	0,094191	0,014467	0,183254	0,005627	0,005041		0,283336	0,164912	0,17573	0,064163	0,0625	0,001605	0,001857

FP2	0,529909	0,532468	0,086499	0,037606	0,109096	0,009019	6,86E-05		0,62466	0,175922	0,074199	0,010213	0,130491	0,011509	0,001132		0,116832	0,20357	0,125418	0,001216	0,089289	0,003109	0,00086
F7	0,346904	0,063395	0,062869	0,081247	0,01079	0,002239	0,000701		1,000394	0,223703	0,148901	0,101051	0,189399	0,00101	0,0049		0,909085	0,139506	0,225636	0,112774	0,07076	0,003473	0,0023
F3	0,141458	0,361458	0,001337	0,008538	0,222151	0,007366	0,000928		0,09173	0,16033	0,268447	0,001646	0,131059	0,009493	0,001023		0,517405	0,007924	0,473686	0,138305	0,035881	0,01138	5,3E-05
FZ	0,464325	0,775563	0,220138	0,00634	0,063881	0,008185	0,001143		0,38335	0,402509	0,030137	0,09582	0,128795	0,007968	0,002313		0,363202	0,353108	0,248688	0,006618	0,02272	0,003215	0,000982
F4	0,29671	0,369615	0,107807	0,001829	0,169761	0,009487	0,001003		0,049861	0,344562	0,075958	0,077206	0,127267	0,009883	0,0014		0,092518	0,014144	0,319019	0,09697	0,039905	0,004177	0,000149
F8	0,735243	0,470208	0,254305	0,125643	0,068538	0,027662	0,000342		0,374512	0,428027	0,082814	0,058121	0,030476	0,007218	0,002235		0,863534	0,441858	0,121161	0,027924	0,102587	0,004878	0,000235
T3	0,597538	0,232402	0,255019	0,116072	0,03695	0,003419	0,002558		0,409832	0,625987	0,118319	0,265963	0,236044	0,004996	0,004924		0,163193	0,020952	0,031362	0,038097	0,043077	0,010327	0,001016
C3	0,459737	0,327146	0,328723	0,071575	0,028159	0,003703	0,001011		1,023983	0,02448	0,207627	0,056285	0,159498	0,003784	0,002451		0,672346	0,225111	0,197379	0,077311	0,040365	0,001678	0,000378
CZ	0,075136	0,394335	0,111311	0,070107	0,016064	0,011671	4,53E-05		0,733234	0,095264	0,273148	0,04291	0,116912	0,010924	0,001532		0,416341	0,250703	0,406172	0,130543	0,011328	0,009224	0,001011
C4	0,164537	0,623829	0,039067	0,021268	0,064435	0,010019	0,000486		0,647657	0,341934	0,197793	0,187541	0,068268	0,00884	0,000613		0,781091	0,160558	0,423352	0,00399	0,10271	0,003673	0,000313
T4	0,102984	1,046021	0,286487	0,30926	0,179574	0,01421	0,001966		0,043864	0,391885	0,099063	0,326702	0,15255	0,01942	0,005157		0,299527	0,334281	0,051934	0,193941	0,241403	0,007814	0,001544
T5	0,139532	0,526217	0,291303	0,2494	0,033486	0,00715	0,000695		0,297032	0,028615	0,055306	5,89E-05	0,094145	0,000681	0,001854		0,403071	0,074227	0,069307	0,137174	0,242611	0,005311	0,001118
P3	0,018526	0,446499	0,21215	0,24841	0,006818	0,003056	0,000501		1,038688	0,364912	0,006174	0,002845	0,052479	0,008434	0,001463		0,72319	0,293195	0,365115	0,186871	0,053797	0,01036	0,001369
PZ	0,017068	0,372099	0,091748	0,197411	0,118126	0,012751	0,001875		0,714679	0,630758	0,117346	0,158355	0,028001	0,007435	0,000174		1,097002	0,071788	0,301508	0,263256	0,242506	0,005477	0,001099
P4	0,06268	0,43635	0,137282	0,146898	0,13764	0,004577	0,001044		0,067237	0,391464	0,297559	0,124806	0,206647	0,00129	0,001119		0,015514	0,039721	0,311284	0,129843	0,009388	0,007073	0,000684
T6	0,246972	0,42084	0,200788	0,325242	0,266948	0,017351	0,00048		0,492382	0,735779	0,028155	0,172913	0,114799	0,024315	0,000873		0,22155	0,461387	0,314878	0,016845	0,205199	0,01128	0,001045
O1	0,016028	0,210646	0,150938	0,11839	0,152839	0,001157	0,000423		0,128847	0,062113	0,238268	0,048684	0,043989	0,005675	0,001408		0,359089	0,131415	0,172818	0,058592	0,049881	0,001477	0,000348
OZ	0,153039	0,496134	0,17728	0,198581	0,013782	0,00682	0,000473		0,366053	0,091636	0,220942	0,195902	0,004073	0,00274	0,002293		0,195477	0,006235	0,226539	0,125495	0,064529	0,002917	0,001528
O2	0,262531	0,340161	0,172344	0,097296	0,22763	0,001452	0,001544		0,470061	0,161232	0,298304	0,145724	0,098916	0,003169	0,002959		0,707588	0,177538	0,122828	0,153797	0,041546	0,010368	0,002679

	SILENCIO								MUSICA FAVORITA								MUSICA DESGOSTADA							
	DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO	
FP1	0,595768	0,87009	0,259956	0,316259	0	0,016973	0		0	0	0	0	0	0,027143	0		0	0	0	0,0845	0	0	0	
FP2	0	0,968848	0,118659	0,185927	0,247707	0	0,002762		0	0	0	0	0	0,019032	0		0	0	0	0,127447	0	0	0	
F7	0	0	0,111703	0,249798	0	0	0,003384		0	0	0	0	0	0,016715	0		0	0	0	0	0	0	0	
F3	0	0,593241	0,233814	0	0	0	0,001566		0	0	0	0	0	0	0,000884		0	0	0	0	0	0	0	
FZ	1,220249	1,103765	0,351018	0	0	0	0,003182		0	0	0	0	0	0	0,001528		0	0	0	0	0	0	0	
F4	1,417652	0,782454	0,161873	0	0	0,012444	0,00183		0	0	0	0	0	0,01787	0,000302		0	0	0	0,248263	0	0	0	
F8	0	0,827649	0,304923	0	0	0,025826	0,004453		1,054843	0,458895	0	0	0	0,030943	0,001809		0	0	0	0,159937	0	0	0	
T3	0	0	0,617214	0,571319	0,17662	0,035254	0,006291		0	0,78414	0,365087	0	0	0,049381	0		0	0,873576	0	0,529608	0,454545	0,058112	0,007222	
C3	0	0,742916	0,571433	0	0,069973	0	0,001677		0	0	0	0	0	0	0,001518		0	0	0	0	0,103764	0,02064	0,001428	
CZ	0	0,501053	0,353531	0	0	0	0,001519		0	0	0,418251	0	0	0	0		0	0	0	0	0	0,004543	0	
C4	0	0,926192	0,440222	0	0	0	0,002063		1,118511	0,442846	0	0	0	0,01859	0		0	0	0	0	0	0	0,001649	
T4	0	1,195034	0,579707	0,768204	0,450421	0,030686	0,007142		1,099557	0	0	0	0	0,024892	0,001509		0	0	0	0	0,191009	0	0,0044	
T5	0	1,336285	0,728461	0	0	0	0		0,742546	0	0	0,454682	0,314168	0	0		0	0	0	0	0	0	0,002192	
P3	0	0,896863	0,357998	0	0	0	0,000322		0	0	0	0,154402	0	0	0		0	0	0	0	0	0	0	
PZ	0	0	0,417561	0	0,173357	0	0,00152		1,519129	0	0	0	0	0,016068	0		0	0	0	0	0,254184	0	0,002268	
P4	0	0,624801	0,573596	0	0,213661	0	0,00274		0	0	0	0	0	0	0		0	0	0,354279	0	0	0	0	
T6	0	1,444386	0,774728	0	0,010429	0,020192	0,002907		1,219627	0	0,173884	0	0	0,02589	0,00079		0	0	0	0	0,335911	0	0,002607	
O1	0	1,284894	0,888519	0,07282	0	0	0,002317		0	0	0	0,208227	0	0	0		1,344151	1,313259	0,265216	0	0	0	0	
OZ	0	1,34282	0,896317	0	0	0,000982	0,002816		0	0	0,28609	0,118972	0	0	0		1,112802	0,715989	0	0	0	0	0,000682	
O2	0	0,903936	0,983046	0	0,276322	0	0,003779		0,919053	0	0	0,042094	0	0,019403	0,000658		0	1,285001	0,323655	0	0	0	0	
	DO CONTINUO								SOL BAIÃO								RUIDO BRANCO							

	DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO		DELTA	TETA	ALFA	BETA	GAMA	GAMA ALTA	RUIDO
FP1	0,447944	0,341924	0	0	0	0	0		0	0	0	0	0,183254	0	0,005041		0	0	0	0	0	0	0
FP2	0	0,532468	0	0	0	0	0		0	0	0	0	0	0,011509	0,001132		0	0	0	0	0	0	0
F7	0	0	0	0	0	0	0		1,000394	0	0	0,101051	0	0	0,0049		0,909085	0	0,225636	0,112774	0	0	0
F3	0	0	0	0	0	0	0,000928		0	0	0	0	0	0	0,001023		0	0	0	0	0	0	0
FZ	0	0	0	0	0	0	0		0	0	0	0	0	0	0,002313		0	0	0	0	0	0	0,000982
F4	0	0,369615	0	0	0	0	0,001003		0	0	0	0	0	0,009883	0,0014		0	0	0	0	0	0	0
F8	0	0,470208	0,254305	0	0	0,027662	0		0	0	0	0	0	0	0,002235		0	0,441858	0	0	0	0	0
T3	0	0	0	0	0	0	0,002558		0	0,625987	0	0,265963	0,236044	0	0,004924		0	0	0	0	0	0	0
C3	0	0	0,328723	0	0	0	0		0	0	0	0	0	0	0,002451		0	0	0	0	0	0	0
CZ	0	0	0	0	0	0	0		0	0	0	0	0	0	0,001532		0	0	0	0	0	0	0,001011
C4	0	0,623829	0	0	0	0,010019	0		0	0	0	0	0	0	0,000613		0,781091	0	0	0	0	0	0
T4	0	1,046021	0	0	0	0	0		0	0	0	0	0,15255	0	0,005157		0	0	0	0	0,241403	0	0,001544
T5	0	0	0	0	0	0	0		0	0	0	0	0	0	0,001854		0	0	0	0	0	0	0
P3	0	0	0	0	0	0	0		1,038688	0	0	0	0	0	0		0,72319	0	0	0	0	0	0
PZ	0	0	0	0,197411	0	0	0		0,714679	0	0	0	0	0,007435	0		1,097002	0	0	0	0	0	0
P4	0	0	0	0	0	0	0		0	0,391464	0	0,124806	0	0	0		0	0	0	0	0	0	0
T6	0	0,42084	0,200788	0,325242	0	0,017351	0		0	0	0	0	0	0,024315	0		0	0,461387	0,314878	0	0	0,01128	0
O1	0	0	0,150938	0	0	0	0		0	0	0	0	0	0	0,001408		0	0	0	0	0	0	0
OZ	0	0	0	0	0	0	0		0	0	0	0	0	0	0,002293		0	0	0	0	0	0	0
O2	0	0	0,172344	0	0,22763	0	0,001544		0	0	0	0	0	0	0,002959		0	0	0	0	0	0	0,002679

APÊNDICE I - Resultados do Treinamento Prognóstico Clínico

Os primeiros modelos que foram treinados basearam-se na arquitetura mencionada no item **5.2 Arquiteturas**.

Os resultados apresentados na Tabela 15 representam uma adaptação do processamento realizado por (BALDO JÚNIOR, 2023), incorporando reajustes na arquitetura original para permitir o treinamento com outros modelos, bem como a reamostragem do sinal de EEG.

Tabela 15 – Resultados do treinamento da base de dados Prognóstico Clínico para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MMLP SREA	0.78 ± 0.09	0.78 ± 0.09	0.84 ± 0.09	0.70 ± 0.13	0.78 ± 0.09	105
MMLP	0.70 ± 0.15	0.69 ± 0.15	0.81 ± 0.21	0.60 ± 0.08	0.70 ± 0.15	120
MMLP CP SREA	0.67 ± 0.09	0.66 ± 0.10	0.68 ± 0.09	0.63 ± 0.16	0.67 ± 0.09	72
MMLP CP	0.67 ± 0.09	0.66 ± 0.10	0.68 ± 0.09	0.63 ± 0.16	0.67 ± 0.09	76
MMLP CE SREA	0.65 ± 0.13	0.65 ± 0.14	0.65 ± 0.14	0.63 ± 0.19	0.65 ± 0.13	74
MMLP CE	0.63 ± 0.14	0.63 ± 0.14	0.64 ± 0.15	0.60 ± 0.17	0.63 ± 0.14	86
MMLP CPE SREA	0.52 ± 0.13	0.51 ± 0.14	0.49 ± 0.14	0.50 ± 0.24	0.52 ± 0.13	75
MMLP CPE	0.48 ± 0.19	0.48 ± 0.19	0.48 ± 0.15	0.53 ± 0.25	0.48 ± 0.19	82
MCL SREA	0.78 ± 0.11	0.78 ± 0.11	0.84 ± 0.16	0.73 ± 0.08	0.78 ± 0.11	497
MCL	0.77 ± 0.03	0.77 ± 0.03	0.79 ± 0.04	0.73 ± 0.08	0.77 ± 0.03	741
MCL CP SREA	0.87 ± 0.04	0.86 ± 0.04	0.92 ± 0.10	0.83 ± 0.15	0.87 ± 0.04	533
MCL CP	0.78 ± 0.07	0.78 ± 0.07	0.75 ± 0.08	0.87 ± 0.07	0.78 ± 0.07	683
MCL CE SREA	0.78 ± 0.16	0.78 ± 0.16	0.86 ± 0.20	0.73 ± 0.08	0.78 ± 0.16	548
MCL CE	0.73 ± 0.10	0.73 ± 0.10	0.76 ± 0.14	0.73 ± 0.17	0.73 ± 0.10	701
MCL CPE SREA	0.85 ± 0.06	0.85 ± 0.06	0.90 ± 0.09	0.80 ± 0.13	0.85 ± 0.06	543
MCL CPE	0.72 ± 0.13	0.71 ± 0.13	0.71 ± 0.12	0.77 ± 0.13	0.72 ± 0.13	706

Os resultados apresentados na Tabela 15 mostraram-se bastante próximos aos obtidos por (BALDO JÚNIOR, 2023), evidenciando que, apesar de algumas modificações no algoritmo base, os resultados permaneceram consistentes, mesmo com diferentes configurações de hardware nos experimentos. Destaca-se o desempenho superior do modelo MCL CP SREA (CNN-LSTM com características do paciente e sem reamostragem do sinal), assim como da base de dados sem

reamostragem, que apresentou resultados melhores em comparação com a versão reamostrada.

Em busca de melhorar os resultados utilizou-se no treinamento os atributos extraídos pelo *software* de processamento de EEG como: Participação de contribuição de Potência - PCP, Frequência Mediana – FM, e Coerência. Obtendo-se os resultados da Tabela 16:

Tabela 16 - Resultados do treinamento da base de dados Prognóstico Clínico para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPCP SREA	0.80 ± 0.09	0.80 ± 0.09	0.86 ± 0.13	0.73 ± 0.08	0.80 ± 0.09	649
MCL CPCP	0.75 ± 0.07	0.75 ± 0.08	0.78 ± 0.12	0.73 ± 0.17	0.75 ± 0.08	1048
MCL CPPCP SREA	0.80 ± 0.07	0.80 ± 0.07	0.83 ± 0.10	0.77 ± 0.13	0.80 ± 0.07	631
MCL CPPCP	0.82 ± 0.06	0.82 ± 0.06	0.84 ± 0.09	0.80 ± 0.13	0.82 ± 0.06	877
MCL CFM SREA	0.82 ± 0.10	0.82 ± 0.10	0.87 ± 0.13	0.77 ± 0.13	0.82 ± 0.10	701
MCL CFM	0.80 ± 0.04	0.80 ± 0.03	0.82 ± 0.11	0.80 ± 0.07	0.80 ± 0.04	1084
MCL CFM REA (REA exceto no FM)	0.77 ± 0.06	0.77 ± 0.06	0.79 ± 0.12	0.77 ± 0.08	0.77 ± 0.06	868
MCL CPM SREA	0.82 ± 0.06	0.81 ± 0.06	0.87 ± 0.11	0.77 ± 0.13	0.82 ± 0.06	728
MCL CPM	0.77 ± 0.03	0.77 ± 0.03	0.77 ± 0.05	0.77 ± 0.08	0.77 ± 0.03	906
MCL CC	0.88 ± 0.09	0.88 ± 0.09	0.97 ± 0.06	0.80 ± 0.19	0.88 ± 0.09	1055
MCL CPC	0.88 ± 0.04	0.88 ± 0.04	0.94 ± 0.07	0.83 ± 0.15	0.88 ± 0.04	3624
MCL CPC Aumento do Dropout para 0.5 nas camadas que usam 0.2 (kernel_regularize r=regularizers.l2(1e-4))	0.85 ± 0.06	0.85 ± 0.07	0.92 ± 0.10	0.80 ± 0.19	0.85 ± 0.06	1105

Na Tabela 16, o modelo com atributos de coerência não possui uma versão sem reamostragem, pois a coerência está diretamente relacionada ao espectro de frequência. Dados com frequências diferentes geram quantidades distintas de atributos, o que pode causar erros na arquitetura do modelo. Vale destacar que o modelo MCL com características de coerência apresentou o melhor desempenho entre as configurações avaliadas.

Posteriormente, foi realizado o treinamento do modelo utilizando sinais de EEG das regiões cerebrais frontal, central, occipital, parietal e temporal, conforme detalhado na Tabela 17.

Tabela 17 - Resultados do treinamento da base de dados Prognóstico Clínico com características do paciente e regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPEF SREA	0.80 ± 0.09	0.80 ± 0.09	0.78 ± 0.07	0.83 ± 0.15	0.80 ± 0.09	526
MCL CPEF	0.77 ± 0.06	0.77 ± 0.06	0.77 ± 0.06	0.77 ± 0.13	0.77 ± 0.06	696
MCL CPEC SREA	0.80 ± 0.14	0.80 ± 0.14	0.80 ± 0.13	0.80 ± 0.16	0.80 ± 0.14	489
MCL CPEC	0.87 ± 0.09	0.87 ± 0.09	0.88 ± 0.10	0.87 ± 0.13	0.87 ± 0.09	671
MCL CPEO SREA	0.82 ± 0.10	0.82 ± 0.10	0.84 ± 0.11	0.80 ± 0.16	0.82 ± 0.10	488
MCL CPEO	0.87 ± 0.09	0.86 ± 0.09	0.92 ± 0.11	0.83 ± 0.18	0.87 ± 0.09	673
MCL CPEP SREA	0.82 ± 0.08	0.82 ± 0.08	0.81 ± 0.05	0.83 ± 0.15	0.82 ± 0.08	517
MCL CPEP	0.83 ± 0.09	0.83 ± 0.10	0.87 ± 0.11	0.80 ± 0.16	0.83 ± 0.09	700
MCL CPET SREA	0.75 ± 0.05	0.75 ± 0.05	0.75 ± 0.06	0.77 ± 0.08	0.75 ± 0.05	482
MCL CPET	0.83 ± 0.05	0.83 ± 0.06	0.87 ± 0.13	0.83 ± 0.11	0.83 ± 0.05	688

Esse processo permitiu avaliar o impacto das diferentes áreas cerebrais na classificação dos sinais de EEG para o prognóstico de coma, destacando o desempenho superior das regiões central e occipital quando o sinal foi reamostrado, alcançando uma acurácia de **0,87**. Esses resultados evidenciam a relevância da reamostragem, contribuindo para a predição mais precisa do estado clínico dos pacientes nestas regiões em específico.

O próximo passo consistiu em testar o modelo utilizando atributos extraídos por meio do *Common Spatial Pattern* (CSP), também com os dados extraídos da decomposição *wavelet*, e realizando alterações na arquitetura como adição de um *layer* com *Transformer* ou alterações de hiperparâmetros, conforme apresentado na Tabela 18. Essa abordagem combinada permite capturar tanto padrões espaciais (via CSP), quanto características temporais e frequenciais (via decomposição *wavelet*) dos sinais de EEG.

Tabela 18 - Resultados do treinamento da base de dados Prognóstico Clínico para CSP, decomposição de Wavelet, e alterações na arquitetura do modelo, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CCSP4	0.60 ± 0.11	0.55 ± 0.18	0.58 ± 0.13	0.53 ± 0.22	0.60 ± 0.11	993
MCL CCSP10	0.47 ± 0.10	0.34 ± 0.22	0.37 ± 0.22	0.33 ± 0.24	0.47 ± 0.10	1012
MCL CCSP20	0.40 ± 0.14	0.32 ± 0.26	0.31 ± 0.26	0.33 ± 0.28	0.40 ± 0.14	908
MCL CDW4	0.75 ± 0.11	0.75 ± 0.11	0.75 ± 0.11	0.77 ± 0.08	0.75 ± 0.11	932
MCL CE Conv1D (64/128, kernel 5/3, para 128/256, kernel 3/7)	0.75 ± 0.11	0.75 ± 0.10	0.80 ± 0.18	0.73 ± 0.13	0.75 ± 0.11	859
MCLT CE	0.75 ± 0.05	0.75 ± 0.05	0.79 ± 0.12	0.73 ± 0.17	0.75 ± 0.05	1054

Conforme observado na Tabela 18, o CSP não apresentou resultados satisfatórios, enquanto a decomposição *wavelet* demonstrou um desempenho superior, alcançando um F1 score de **0,75**, e alterando o modelo base melhora-se o desempenho.

Ainda foi realizado testes utilizando outros modelos de redes neurais o qual o resultado pode ser visualizado na Tabela 19.

Tabela 19 - Resultados do treinamento da base de dados Prognóstico Clínico com outros modelos de rede neural, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
INCEPTION (ISMAIL FAWAZ <i>et al.</i> , 2019)	0.58 ± 0.09	0.55 ± 0.11	0.65 ± 0.19	0.60 ± 0.20	0.58 ± 0.09	1479
RESNET (ISMAIL FAWAZ <i>et al.</i> , 2019)	0.67 ± 0.12	0.64 ± 0.14	0.73 ± 0.17	0.67 ± 0.21	0.67 ± 0.12	1539
ResNet50	0.45 ± 0.10	0.32 ± 0.04	0.36 ± 0.20	0.67 ± 0.42	0.45 ± 0.10	6859
ResNet101	0.48 ± 0.03	0.33 ± 0.02	0.25 ± 0.01	0.48 ± 0.03	0.48 ± 0.03	14655
ERTNET (LIU <i>et al.</i> , 2024)	0.73 ± 0.18	0.73 ± 0.18	0.76 ± 0.22	0.77 ± 0.17	0.73 ± 0.18	284
EfficientNet	0.43 ± 0.24	0.38 ± 0.23	0.27 ± 0.24	0.40 ± 0.39	0.43 ± 0.24	884
EfficientNetB0	0.48 ± 0.12	0.41 ± 0.13	0.39 ± 0.21	0.63 ± 0.36	0.48 ± 0.12	1227
EfficientNetB1	0.50 ± 0.00	0.33 ± 0.00	0.30 ± 0.25	0.60 ± 0.49	0.50 ± 0.00	3669
EfficientNetB2	0.55 ± 0.10	0.45 ± 0.16	0.56 ± 0.12	0.80 ± 0.27	0.55 ± 0.10	4132
EfficientNetB3	0.37 ± 0.09	0.30 ± 0.03	0.35 ± 0.12	0.50 ± 0.35	0.37 ± 0.09	4517

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
EfficientNetB4	0.47 ± 0.09	0.39 ± 0.12	0.23 ± 0.29	0.17 ± 0.21	0.47 ± 0.09	5254
EfficientNetB5	0.32 ± 0.17	0.23 ± 0.10	0.34 ± 0.16	0.60 ± 0.37	0.32 ± 0.17	6861
EfficientNetB6	0.48 ± 0.03	0.43 ± 0.06	0.48 ± 0.04	0.50 ± 0.30	0.48 ± 0.03	8464
EfficientNetV2M	0.50 ± 0.11	0.41 ± 0.13	0.42 ± 0.21	0.73 ± 0.39	0.50 ± 0.11	4515
EfficientNetV2M (<i>preprocessing=true</i>)	0.50 ± 0.11	0.41 ± 0.13	0.42 ± 0.21	0.73 ± 0.39	0.50 ± 0.11	4116

APÊNDICE J - Resultados do Treinamento *Transformer* e Prognostico Clínico

1 Sinal Puro

A análise inicial considerou exclusivamente o sinal EEG bruto para a classificação, com os resultados apresentados nas Tabela 20 e Tabela 21, utilizando a legenda da Tabela 9 como referência. Essa abordagem permite avaliar a influência dos hiperparâmetros no desempenho dos modelos, destacando o impacto de configurações específicas na acurácia e no tempo de treinamento.

Na Tabela 20, observa-se o efeito da variação dos hiperparâmetros no modelo com camadas de *TransformerEncoder* (MT). O aumento do número de camadas (N_L , de 1 para 3) geralmente eleva a acurácia, mas implica maior tempo de treinamento. Por exemplo, o modelo MT com $N_H = 8$, $INT_D = 64$, $N_L = 1$, $DOUT = 0,1$ e $EPC = 30$ alcança acurácia de $0,78 \pm 0,16$, enquanto o modelo com $N_L = 3$ obtém $0,88 \pm 0,09$, um ganho de 10%, mas com tempo de treinamento mais que duplicado (de 228 para 503 segundos). Valores menores de dimensão interna (INT_D) reduzem a quantidade de atributos capturados, porém podem melhorar a acurácia, enquanto taxas de dropout ($DOUT$) mais elevadas tendem a diminuir o desempenho. Aumentar o número de épocas (EPC , de 30 para 60) não garante ganhos significativos, sugerindo convergência precoce dos modelos.

Adicionalmente, o processamento sem placa de vídeo (SPV) aumenta consideravelmente o tempo de treinamento, como no caso de MT SPV com $N_H = 8$, $INT_D = 64$, $N_L = 3$, $DOUT = 0,05$ e $EPC = 60$ (6037 segundos), com prejuízo ao desempenho (acurácia de $0,85 \pm 0,10$), reforçando a importância de recursos computacionais otimizados para aplicações clínicas.

Tabela 20 - Resultado Prognostico Clínico usando *Transformers* com Sinal Puro variando os hiperparâmetros do modelo MT, em negrito se destaca o melhor modelo

Mod.	N_H	INT_D	N_L	$DOUT$	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MT SPV	4	32	3	0.05	30	0.83±0.12	0.83±0.12	0.88±0.15	0.80±0.19	0.83±0.12	2628
MT	4	32	3	0.05	30	0.85±0.06	0.85±0.07	0.97±0.07	0.73±0.13	0.85±0.06	502
MT	4	64	1	0.1	30	0.78±0.07	0.73±0.10	0.81±0.17	0.63±0.07	0.73±0.10	190
MT	4	64	1	0.1	60	0.80±0.04	0.77±0.05	0.96±0.08	0.60±0.08	0.78±0.04	372

Mod.	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MT	4	64	1	0.2	30	0.78±0.07	0.78±0.07	0.90±0.13	0.67±0.11	0.78±0.07	193
MT	4	64	1	0.2	60	0.80±0.04	0.79±0.04	0.94±0.11	0.67±0.11	0.80±0.04	364
MT	4	64	3	0.1	30	0.83±0.05	0.83±0.06	0.93±0.08	0.73±0.13	0.83±0.05	425
MT	4	64	3	0.1	60	0.80±0.04	0.80±0.04	0.89±0.09	0.70±0.07	0.80±0.04	786
MT	4	64	3	0.2	30	0.80±0.11	0.80±0.11	0.84±0.15	0.77±0.17	0.80±0.11	420
MT	4	64	3	0.2	60	0.87±0.04	0.87±0.04	0.97±0.07	0.77±0.08	0.87±0.04	765
MT	4	128	1	0.1	30	0.80±0.09	0.80±0.09	0.89±0.13	0.70±0.13	0.80±0.09	202
MT	4	128	1	0.1	60	0.82±0.10	0.81±0.10	0.85±0.12	0.80±0.19	0.82±0.10	367
MT	4	128	1	0.2	30	0.83±0.09	0.83±0.10	0.92±0.10	0.73±0.17	0.83±0.09	206
MT	4	128	1	0.2	60	0.82±0.06	0.81±0.07	0.87±0.07	0.77±0.17	0.82±0.06	378
MT SPV	4	128	3	0.05	30	0.78±0.09	0.78±0.09	0.83±0.14	0.77±0.17	0.78±0.09	2779
MT	4	128	3	0.05	30	0.80±0.07	0.79±0.07	0.88±0.15	0.77±0.17	0.80±0.07	391
MT	4	128	3	0.1	30	0.78±0.11	0.78±0.11	0.81±0.16	0.77±0.17	0.78±0.11	390
MT	4	128	3	0.1	60	0.78±0.07	0.77±0.07	0.88±0.15	0.73±0.20	0.78±0.07	734
MT	4	128	3	0.2	30	0.87±0.11	0.86±0.12	0.94±0.11	0.80±0.19	0.87±0.11	415
MT	4	128	3	0.2	60	0.82±0.06	0.81±0.06	0.85±0.12	0.80±0.13	0.82±0.06	768
MT	4	128	5	0.05	30	0.80±0.13	0.80±0.13	0.88±0.16	0.70±0.13	0.80±0.13	602
MT	4	128	10	0.05	30	0.83±0.11	0.82±0.12	0.93±0.09	0.73±0.23	0.83±0.10	1142
MT	8	32	3	0.05	30	0.78±0.09	0.78±0.09	0.89±0.14	0.67±0.11	0.78±0.09	525
MT	8	64	1	0.1	30	0.78±0.16	0.77±0.18	0.86±0.20	0.63±0.25	0.78±0.16	228
MT	8	64	1	0.1	60	0.82±0.12	0.80±0.16	0.97±0.07	0.67±0.26	0.82±0.12	419
MT	8	64	1	0.2	30	0.77±0.14	0.75±0.17	0.86±0.20	0.60±0.23	0.77±0.14	242
MT	8	64	1	0.2	60	0.78±0.11	0.76±0.14	0.93±0.09	0.63±0.25	0.78±0.11	459
MT	8	64	3	0.05	30	0.85±0.10	0.85±0.10	0.93±0.09	0.77±0.17	0.85±0.10	499
MT	8	64	3	0.05	60	0.88±0.09	0.88±0.09	0.97±0.06	0.80±0.19	0.88±0.09	983
MT SPV	8	64	3	0.05	60	0.85±0.10	0.85±0.10	0.96±0.08	0.73±0.17	0.85±0.10	6037
MT	8	64	3	0.1	30	0.88±0.09	0.88±0.09	0.97±0.06	0.80±0.19	0.88±0.09	503
MT	8	64	3	0.1	60	0.88±0.09	0.88±0.09	0.97±0.06	0.80±0.19	0.88±0.09	939
MT	8	64	3	0.2	30	0.83±0.09	0.82±0.11	1.00±0.00	0.67±0.18	0.83±0.09	534
MT	8	64	3	0.2	60	0.80±0.10	0.79±0.11	0.94±0.11	0.67±0.21	0.80±0.10	987
MT	8	128	1	0.1	30	0.80±0.04	0.79±0.04	0.96±0.08	0.63±0.07	0.80±0.04	246
MT	8	128	1	0.1	60	0.82±0.03	0.81±0.04	0.97±0.07	0.67±0.11	0.82±0.03	451
MT	8	128	1	0.2	30	0.82±0.06	0.81±0.07	0.96±0.08	0.67±0.11	0.82±0.06	244
MT	8	128	1	0.2	60	0.82±0.06	0.81±0.07	0.96±0.08	0.67±0.11	0.82±0.06	447
MT	8	128	3	0.05	30	0.82±0.06	0.81±0.07	0.97±0.07	0.67±0.15	0.82±0.06	509
MT	8	128	3	0.1	30	0.80±0.04	0.79±0.05	0.97±0.07	0.63±0.13	0.80±0.04	508
MT	8	128	3	0.1	60	0.83±0.05	0.83±0.06	0.97±0.07	0.70±0.13	0.83±0.05	935
MT	8	128	3	0.2	30	0.80±0.09	0.79±0.10	1.00±0.00	0.60±0.17	0.80±0.09	531
MT	8	128	3	0.2	60	0.82±0.03	0.81±0.04	0.97±0.07	0.67±0.11	0.82±0.03	996

A Tabela 21 evidencia o impacto da variação dos hiperparâmetros no desempenho do modelo convolucional e transformer (MCT), que combina camadas convolucionais e *TransformerEncoder*. Configurações com número de cabeças de atenção (N_H) igual a 4 ou 8 apresentam desempenhos semelhantes, com variações mínimas na acurácia. O aumento da dimensão interna (INT_D) de 32 para 128 promove ligeira melhoria na acurácia e precisão, refletindo maior capacidade de captura de padrões complexos nos sinais EEG. Modelos com três camadas (N_L = 3) superam consistentemente aqueles com 5 ou 10 camadas, que exibem desempenho inferior e maior custo computacional. A elevação do número de épocas (EPC) de 30 para 60 não resulta em ganhos significativos, podendo, em alguns casos, reduzir a acurácia devido à convergência precoce ou ao sobreajuste. Esses resultados destacam a importância de configurações otimizadas, como N_H = 4, INT_D = 128, N_L = 3, DOUT = 0,05 e EPC = 30 ou N_H = 8, INT_D = 32, N_L = 3, DOUT = 0,05 e EPC = 30, para equilibrar precisão e eficiência em aplicações clínicas de prognóstico de morte.

Tabela 21 - Resultado Prognostico Clinico usando Transformers com Sinal Puro variando os hiperparâmetros do modelo MCT, em negrito se destaca o melhor modelo

Mod.	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT	4	32	3	0.05	30	0.73±0.06	0.73±0.06	0.73±0.07	0.77±0.13	0.73±0.06	1560
MCT	4	32	3	0.05	60	0.70±0.07	0.69±0.07	0.66±0.05	0.83±0.15	0.70±0.07	3121
MCT	4	32	3	0.2	30	0.73±0.06	0.73±0.06	0.73±0.07	0.77±0.13	0.73±0.06	1662
MCT	4	32	3	0.2	60	0.70±0.07	0.69±0.07	0.66±0.05	0.83±0.15	0.70±0.07	3052
MCT	4	64	3	0.05	30	0.75±0.05	0.75±0.05	0.80±0.11	0.70±0.07	0.75±0.05	1654
MCT	4	64	3	0.05	60	0.75±0.07	0.75±0.08	0.77±0.13	0.77±0.13	0.75±0.08	3034
MCT	4	64	3	0.1	30	0.73±0.06	0.73±0.06	0.73±0.07	0.77±0.13	0.73±0.06	1553
MCT	4	64	3	0.1	60	0.75±0.07	0.75±0.08	0.77±0.13	0.77±0.13	0.75±0.08	3217
MCT	4	64	3	0.2	30	0.73±0.06	0.73±0.06	0.73±0.07	0.77±0.13	0.73±0.06	1683
MCT	4	64	3	0.2	60	0.75±0.07	0.75±0.08	0.77±0.13	0.77±0.13	0.75±0.08	3262
MCT	4	128	3	0.05	30	0.78±0.09	0.78±0.08	0.81±0.12	0.77±0.13	0.78±0.09	1104
MCT	4	128	3	0.1	30	0.75±0.09	0.75±0.09	0.77±0.13	0.73±0.17	0.75±0.09	1095
MCT	4	128	5	0.05	30	0.70±0.14	0.70±0.13	0.73±0.17	0.67±0.18	0.70±0.14	1542
MCT	4	128	10	0.05	30	0.67±0.09	0.65±0.11	0.75±0.14	0.60±0.27	0.67±0.09	2706
MCT	8	32	3	0.05	30	0.78±0.07	0.78±0.07	0.83±0.14	0.77±0.13	0.78±0.07	1284
MCT	8	32	3	0.05	60	0.75±0.07	0.75±0.08	0.77±0.13	0.77±0.13	0.75±0.08	3064
MCT	8	32	3	0.2	30	0.73±0.06	0.73±0.06	0.73±0.07	0.77±0.13	0.73±0.06	1663
MCT	8	32	3	0.2	60	0.75±0.07	0.75±0.08	0.77±0.13	0.77±0.13	0.75±0.08	3105
MCT	8	64	3	0.05	30	0.73±0.06	0.73±0.06	0.73±0.07	0.77±0.13	0.73±0.06	1357

Mod.	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT	8	64	3	0.05	60	0.75±0.07	0.75±0.08	0.77±0.13	0.77±0.13	0.75±0.08	2572
MCT	8	64	3	0.2	30	0.73±0.06	0.73±0.06	0.73±0.07	0.77±0.13	0.73±0.06	1631
MCT	8	64	3	0.2	60	0.75±0.07	0.75±0.08	0.77±0.13	0.77±0.13	0.75±0.08	2862
MCT	8	128	3	0.05	30	0.77±0.11	0.76±0.11	0.83±0.16	0.70±0.19	0.77±0.11	1369
MCT	8	128	3	0.1	30	0.75±0.05	0.75±0.05	0.80±0.11	0.70±0.07	0.75±0.05	1618
MCT	8	128	3	0.2	30	0.75±0.05	0.75±0.05	0.80±0.11	0.70±0.07	0.75±0.05	1605
MCT	8	128	5	0.05	30	0.73±0.06	0.73±0.06	0.73±0.07	0.77±0.13	0.73±0.06	1633
MCT	8	128	10	0.05	30	0.75±0.05	0.75±0.05	0.80±0.11	0.70±0.07	0.75±0.05	1616

2 Sinal com características do paciente

Na base de dados utilizada, houve a catalogação das seguintes informações do paciente:

- Idade em anos;
- Gênero/sexo (Masculino ou Feminino);
- Etiologia do coma (acidente vascular cerebral – AVC (12), coma metabólico (18), Traumatismo cranioencefálico – TCE (20) e Outros (10)).

As informações acima foram colocadas como entrada da arquitetura da rede neural, no qual o gênero e etiologia passou por uma tradução de caracteres para número inteiro (*OneHotEncoder*), assim, foi adicionado três novos valores como entrada para cada paciente, os resultados desses treinamentos são apresentados na Tabela 22, Tabela 23, Tabela 24, Tabela 25, Tabela 26, Tabela 27 e Tabela 28.

Na Tabela 22 com $N_H = 4$ e $INT_D = 32$ os modelos MT CP superam consistentemente os MCT CP em acurácia, F1 score e precisão, além de apresentarem maior eficiência computacional, com tempo de treinamento aproximadamente 29% menor. O aumento do número de camadas ($N_L = 5$ ou 10) nos modelos MT CP não resulta em ganhos substanciais, e o incremento do número de épocas (de 30 para 60 ou 120) tende a reduzir a acurácia, indicando que configurações mais profundas e treinamentos prolongados podem levar a sobreajuste ou degradação do desempenho.

Tabela 22 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com $N_H = 4$ e $INT_D = 32$, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MCT CP	4	32	1	0.1	30	0.77±0.06	0.76±0.06	0.80±0.11	0.73±0.13	0.77±0.06	940
MT CP	4	32	1	0.1	30	0.85±0.03	0.85±0.03	0.87±0.07	0.83±0.00	0.85±0.03	304
MT CP	4	32	1	0.1	60	0.83±0.05	0.83±0.05	0.88±0.11	0.80±0.07	0.83±0.05	385
MT CP	4	32	1	0.1	120	0.78±0.04	0.78±0.04	0.81±0.02	0.73±0.08	0.78±0.04	795
MCT CP	4	32	3	0.05	30	0.78±0.11	0.78±0.11	0.78±0.13	0.80±0.13	0.78±0.11	1.244
MT CP	4	32	3	0.05	30	0.85±0.06	0.85±0.07	0.95±0.10	0.77±0.17	0.85±0.06	562
MT CP	4	32	3	0.05	60	0.85±0.10	0.85±0.10	0.92±0.10	0.77±0.17	0.85±0.10	1.055
MCT CP	4	32	3	0.1	30	0.75±0.09	0.75±0.09	0.77±0.10	0.73±0.08	0.75±0.09	1.263
MT CP	4	32	3	0.1	30	0.85±0.06	0.85±0.07	0.95±0.10	0.77±0.17	0.85±0.06	536
MT CP	4	32	3	0.1	60	0.82±0.10	0.81±0.10	0.89±0.13	0.73±0.13	0.82±0.10	1.033
MT CP	4	32	5	0.1	30	0.80±0.09	0.79±0.10	0.88±0.11	0.73±0.23	0.80±0.09	1048
MT CP	4	32	10	0.1	30	0.82±0.08	0.81±0.09	0.90±0.12	0.73±0.13	0.82±0.08	1590

Já na Tabela 23 com $N_H = 4$ e $INT_D = 64$ os modelos MCT CP mostram-se mais competitivos em termos de desempenho, porém, ao desabilitar a placa de vídeo para o modelo MT CP, este apresenta o melhor resultado geral, embora o tempo de processamento aumente significativamente.

Tabela 23 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com $N_H = 4$ e $INT_D = 64$, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MCT CP	4	64	1	0.1	30	0.80±0.09	0.80±0.09	0.80±0.12	0.83±0.11	0.80±0.09	754
MT CP	4	64	1	0.1	30	0.77±0.08	0.76±0.09	0.87±0.11	0.63±0.13	0.77±0.08	219
MCT CP	4	64	3	0.05	30	0.77±0.08	0.77±0.08	0.78±0.12	0.77±0.08	0.77±0.08	1059
MT CP	4	64	3	0.05	30	0.80±0.09	0.79±0.10	0.93±0.09	0.67±0.18	0.80±0.09	433
MT CP SPV	4	64	3	0.05	30	0.82±0.08	0.81±0.09	0.86±0.08	0.77±0.17	0.82±0.08	1806
MCT CP	4	64	3	0.1	30	0.77±0.03	0.76±0.03	0.79±0.11	0.77±0.08	0.77±0.03	991
MT CP	4	64	3	0.1	30	0.77±0.06	0.76±0.07	0.82±0.10	0.70±0.13	0.77±0.06	440

Avaliando a Tabela 24 com $N_H = 4$ e $INT_D = 128$ os modelos MT CP com 3 camadas ($N_L = 3$) e dropout moderado (0.05 ou 0.1) apresentam melhor desempenho (acurácia até 0.83), enquanto configurações mais simples ($N_L = 1$)

mantêm acurácia próxima de 0.80 com tempo de treino menor (ex: 210s). Aumentar épocas (EPC = 120) reduz ligeiramente a acurácia (ex: 0.78), indicando possível sobreajuste. Modelos MCT CP têm desempenho inferior (acurácia ≤ 0.73) e maior tempo de processamento.

Tabela 24 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com N_H = 4 e INT_D = 128, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MT CP	4	128	1	0.01	120	0.78±0.07	0.78±0.07	0.79±0.12	0.80±0.13	0.78±0.07	969
MT CP	4	128	1	0.05	30	0.80±0.10	0.80±0.10	0.87±0.11	0.70±0.13	0.80±0.10	210
MCT CP	4	128	1	0.1	30	0.70±0.15	0.69±0.16	0.67±0.18	0.70±0.29	0.70±0.15	895
MT CP	4	128	1	0.1	30	0.80±0.10	0.80±0.10	0.87±0.11	0.70±0.13	0.80±0.10	213
MT CP	4	128	1	0.1	60	0.83±0.08	0.83±0.08	0.90±0.09	0.77±0.17	0.83±0.08	401
MT CP	4	128	1	0.1	120	0.78±0.07	0.78±0.07	0.78±0.06	0.80±0.13	0.78±0.07	953
MCT CP	4	128	1	0.2	30	0.73±0.08	0.73±0.08	0.74±0.09	0.73±0.17	0.73±0.08	869
MT CP	4	128	1	0.2	30	0.80±0.07	0.80±0.07	0.89±0.09	0.70±0.13	0.80±0.07	214
MT CP	4	128	3	0.05	30	0.82±0.06	0.81±0.07	0.91±0.12	0.73±0.13	0.82±0.06	440
MT CP	4	128	3	0.05	60	0.82±0.06	0.81±0.07	0.91±0.12	0.73±0.13	0.82±0.06	1074
MT CP	4	128	3	0.1	30	0.83±0.09	0.83±0.10	0.92±0.11	0.73±0.13	0.83±0.09	736

Com N_H = 4 e INT_D = 256 conforme apresentado na Tabela 25, os modelos MT CP destacam-se pelo desempenho superior, especialmente para a configuração com 3 camadas (N_L = 3) e DOUT = 0.05 no qual ambos modelos MT e MCT alcança o melhor desempenho nessa configuração.

Tabela 25 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com N_H = 4 e INT_D = 256, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MCT CP	4	256	1	0.1	30	0.75±0.09	0.75±0.09	0.79±0.12	0.70±0.13	0.75±0.09	752
MT CP	4	256	1	0.1	30	0.80±0.07	0.80±0.07	0.89±0.09	0.70±0.13	0.80±0.07	314
MCT CP	4	256	3	0.05	30	0.78±0.09	0.78±0.09	0.78±0.08	0.80±0.13	0.78±0.09	1170
MT CP	4	256	3	0.05	30	0.87±0.07	0.87±0.07	0.96±0.08	0.77±0.08	0.87±0.07	426
MCT CP	4	256	3	0.1	30	0.73±0.06	0.72±0.07	0.77±0.15	0.77±0.17	0.73±0.06	1231
MT CP	4	256	3	0.1	30	0.83±0.09	0.83±0.10	0.95±0.10	0.70±0.13	0.83±0.09	439

Analisando a Tabela 26 com $N_H = 8$ e $INT_D = 32$, os modelos MT CP, especialmente com 3 camadas, apresentam melhor desempenho, alcançando acurácia e F1 score de até 0,83, além de maior precisão (até 1,00) com tempos de treinamento significativamente menores (entre 283 e 782 segundos) em comparação aos modelos MCT CP. Embora os MCT CP apresentem desempenho competitivo, eles demandam tempos de processamento mais longos (acima de 1000 segundos), indicando que MT CP oferece melhor equilíbrio entre eficiência e precisão para as configurações avaliadas.

Tabela 26 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com $N_H = 8$ e $INT_D = 32$, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CP	8	32	1	0.1	30	0.80±0.09	0.80±0.09	0.81±0.12	0.80±0.07	0.80±0.09	1070
MT CP	8	32	1	0.1	30	0.77±0.06	0.76±0.07	0.82±0.10	0.70±0.13	0.77±0.06	283
MCT CP	8	32	1	0.1	60	0.78±0.09	0.78±0.09	0.77±0.09	0.83±0.11	0.78±0.09	1419
MT CP	8	32	1	0.1	60	0.82±0.06	0.82±0.06	0.85±0.08	0.77±0.08	0.82±0.06	483
MCT CP	8	32	3	0.05	30	0.78±0.07	0.78±0.07	0.78±0.12	0.83±0.11	0.78±0.07	1310
MT CP	8	32	3	0.05	30	0.83±0.05	0.83±0.05	0.93±0.09	0.73±0.08	0.83±0.05	551
MCT CP	8	32	3	0.1	30	0.80±0.10	0.80±0.10	0.82±0.10	0.77±0.17	0.80±0.10	1349
MT CP	8	32	3	0.1	30	0.83±0.05	0.83±0.06	1.00±0.00	0.67±0.11	0.83±0.05	782

Observando a Tabela 27 com $N_H = 8$ e $INT_D = 64$, os modelos MT CP com 3 camadas novamente apresentam os melhores resultados. O processamento sem placa de vídeo (MT CP SPV) eleva a acurácia para 0,85, porém aumenta significativamente o tempo de treinamento (3202 segundos). Modelos com menos camadas ou MCT CP têm desempenho inferior e maior tempo de processamento. Configurações com 5 camadas mantêm desempenho similar, enquanto 10 camadas aumentam o tempo sem ganhos expressivos.

Tabela 27 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com $N_H = 8$ e $INT_D = 64$, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MCT CP	8	64	1	0.1	30	0.73±0.11	0.72±0.12	0.78±0.13	0.67±0.24	0.73±0.11	1059
MT CP	8	64	1	0.1	30	0.78±0.09	0.78±0.09	0.88±0.10	0.67±0.15	0.78±0.09	282
MT CP	8	64	3	0.05	30	0.80±0.09	0.80±0.09	0.87±0.13	0.73±0.13	0.80±0.09	543
MT CP SPV	8	64	3	0.05	30	0.85±0.06	0.85±0.07	0.95±0.10	0.77±0.17	0.85±0.06	3202
MCT CP	8	64	3	0.1	30	0.78±0.07	0.78±0.07	0.80±0.12	0.80±0.13	0.78±0.07	1356
MT CP	8	64	3	0.1	30	0.85±0.06	0.85±0.07	0.97±0.07	0.73±0.13	0.85±0.06	911
MT CP	8	64	3	0.1	60	0.78±0.09	0.78±0.09	0.85±0.14	0.73±0.13	0.78±0.09	1055
MT CP	8	64	5	0.05	30	0.85±0.06	0.85±0.07	0.97±0.07	0.73±0.13	0.85±0.06	1308
MT CP	8	64	10	0.05	30	0.83±0.08	0.83±0.08	0.94±0.11	0.73±0.13	0.83±0.08	2213

Visualizando a Tabela 28 com $N_H = 8$ e $INT_D = 128$, os modelos MT CP superam os MCT CP em acurácia e precisão, com destaque para 3 camadas ($N_L=3$).

Tabela 28 - Resultado Prognostico Clinico usando Transformers com características do paciente variando os hiperparâmetros com $N_H = 8$ e $INT_D = 128$, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MCT CP	8	128	1	0.1	30	0.77±0.08	0.76±0.08	0.78±0.05	0.73±0.17	0.77±0.08	866
MT CP	8	128	1	0.1	30	0.78±0.09	0.78±0.09	0.88±0.10	0.67±0.15	0.78±0.09	340
MCT CP	8	128	3	0.05	30	0.77±0.12	0.77±0.12	0.79±0.13	0.73±0.17	0.77±0.12	1371
MT CP	8	128	3	0.05	30	0.83±0.05	0.83±0.05	0.93±0.09	0.73±0.08	0.83±0.05	573
MCT CP	8	128	3	0.1	30	0.73±0.10	0.73±0.10	0.71±0.09	0.80±0.13	0.73±0.10	1375
MT CP	8	128	3	0.1	30	0.83±0.05	0.83±0.06	0.97±0.07	0.70±0.13	0.83±0.05	903

A melhor configuração geral observada foi o modelo MT CP com 4 cabeças de atenção ($N_H = 4$), dimensão intermediária ($INT_D = 256$), 3 camadas ($N_L = 3$), *dropout* de 0,05 ($DOUT = 0.05$) e 30 épocas ($EPC = 30$), que alcançou F1 score (macro) de $0,87 \pm 0,07$ e precisão de $0,96 \pm 0,08$, com tempo de treinamento de 426 segundos. Em comparação, o modelo MCT CP com $N_H = 8$, $INT_D = 32$, $N_L = 3$, $DOUT = 0,1$ e $EPC = 30$ com F1 score de $0,80 \pm 0,10$ e tempo de processamento significativamente maior (1349 segundos). Esses resultados ressaltam que configurações com 3 camadas proporcionam o melhor desempenho, enquanto o

modelo MT CP oferece vantagens claras em termos de eficiência computacional, apresentando tempos de treinamento mais baixos sem comprometer a precisão.

3 Sinal com características estatísticas

Nesta seção, o processamento do sinal EEG foi realizado por meio da extração de características estatísticas, incluindo média, desvio padrão, valores máximo e mínimo, e variância. Para cada um dos 20 canais utilizados, foram extraídos cinco atributos, totalizando 100 atributos por segmento. Essa abordagem permite capturar informações temporais e variacionais do sinal, possibilitando a avaliação do impacto da variação dos hiperparâmetros nas métricas de desempenho dos modelos durante o treinamento.

Na Tabela 29 podemos notar que os modelos MT CE apresentam desempenho consistentemente superior aos MCT CE em termos de acurácia, F1 score e precisão, especialmente em configurações com 3 camadas ($N_L = 3$), e dimensões intermediárias maiores ($INT_D = 128$ ou 256). Destaca-se o modelo MT $N_H = 8, INT_D = 256, N_L = 3, DOUT = 0,05, EPC = 30$, que alcança acurácia de 0,85 e precisão de 0,93, com tempos de treinamento relativamente baixos (em torno de 685 segundos). Já os modelos MCT CE, embora apresentem desempenho razoável, geralmente exibem acurácia inferior (em torno de 0,70 a 0,77) e tempos de processamento mais elevados. Além disso, observa-se que o aumento do número de cabeças de atenção não garante melhoria significativa no desempenho, enquanto a escolha adequada da dimensão intermediária e do número de camadas é crucial para otimizar os resultados.

Tabela 29 - Resultado Prognóstico Clínico usando Transformers com características estatísticas variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CE	4	32	3	0.1	30	0.77±0.06	0.77±0.06	0.75±0.06	0.80±0.13	0.77±0.06	1114
MT CE	4	32	3	0.1	30	0.83±0.08	0.83±0.08	0.94±0.11	0.73±0.13	0.83±0.08	614
MCT CE	4	64	1	0.1	30	0.77±0.12	0.76±0.12	0.77±0.15	0.80±0.19	0.77±0.12	631
MT CE	4	64	1	0.1	30	0.75±0.05	0.75±0.05	0.80±0.11	0.70±0.13	0.75±0.05	205
MCT CE	4	128	3	0.05	30	0.75±0.09	0.75±0.09	0.79±0.13	0.70±0.16	0.75±0.09	1372

Modelo	N _H	INT_D	N _L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MT CE	4	128	3	0.05	30	0.83±0.08	0.83±0.08	0.89±0.11	0.80±0.19	0.83±0.08	422
MCT CE	4	256	3	0.05	30	0.75±0.12	0.74±0.13	0.75±0.07	0.73±0.25	0.75±0.12	1170
MT CE	4	256	3	0.05	30	0.83±0.08	0.83±0.08	0.91±0.11	0.77±0.17	0.83±0.08	547
MCT CE	8	32	3	0.05	30	0.73±0.12	0.73±0.12	0.73±0.15	0.77±0.17	0.73±0.12	1680
MT CE	8	32	3	0.05	30	0.77±0.06	0.75±0.08	0.94±0.11	0.60±0.17	0.77±0.06	500
MCT CE	8	32	3	0.1	30	0.72±0.11	0.71±0.11	0.71±0.11	0.73±0.17	0.72±0.11	1649
MT CE	8	32	3	0.1	30	0.77±0.10	0.75±0.11	0.93±0.13	0.60±0.17	0.77±0.10	831
MCT CE	8	64	1	0.1	30	0.77±0.14	0.77±0.14	0.76±0.14	0.80±0.16	0.77±0.14	863
MT CE	8	64	1	0.1	30	0.73±0.21	0.72±0.23	0.78±0.28	0.63±0.29	0.73±0.21	218
MCT CE	8	64	3	0.05	30	0.70±0.10	0.70±0.10	0.70±0.10	0.70±0.16	0.70±0.10	1686
MCT CE	8	64	3	0.05	60	0.75±0.09	0.75±0.09	0.74±0.13	0.80±0.13	0.75±0.09	2501
MCT CE	8	64	3	0.1	30	0.75±0.12	0.75±0.12	0.76±0.14	0.77±0.13	0.75±0.12	1384
MT CE	8	64	3	0.1	30	0.80±0.09	0.79±0.10	0.96±0.08	0.63±0.16	0.80±0.09	682
MCT CE	8	128	3	0.1	30	0.72±0.07	0.71±0.07	0.77±0.14	0.67±0.18	0.72±0.07	1695
MT CE	8	128	3	0.1	30	0.82±0.06	0.81±0.07	0.94±0.11	0.70±0.13	0.82±0.06	540
MCT CE	8	256	3	0.05	30	0.73±0.13	0.73±0.14	0.76±0.14	0.70±0.22	0.73±0.13	1523
MT CE	8	256	3	0.05	30	0.85±0.10	0.84±0.10	0.93±0.13	0.80±0.19	0.85±0.10	685

4 Sinal com características de PCP

Nesta seção, o processamento do sinal EEG foi realizado por meio da extração dos valores de PCP nas bandas de frequência delta, teta, alfa e beta. Para cada um dos 20 canais, foram obtidos quatro atributos (um por banda), resultando em uma matriz de 20×4 elementos, totalizando 80 características adicionais por paciente como entrada para o treinamento dos modelos. Os resultados dessa abordagem são apresentados na Tabela 30, evidenciando o impacto dessas características e das alterações dos hiperparâmetros nas métricas de desempenho.

Conforme observado na Tabela 30 os modelos MT CPCP superam os MCT CPCP em acurácia e precisão, com destaque para MT CPCP ($N_H = 8, INT_D = 256, N_L = 3, DOUT = 0,05, EPC = 30$), que atinge acurácia de 0,87 e precisão de 0,95 em 1000 segundos. Configurações MCT CPCP apresentam desempenho inferior (em torno de 0,70 a 0,78) e tempos maiores (chegando a 2225 segundos). Modelos com $N_L = 3$ e $INT_D \geq 64$ oferecem melhor desempenho, enquanto $N_H = 8$ maximiza a precisão em MT CPCP.

Tabela 30 - Resultado Prognostico Clinico usando Transformers com características de PCP variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CPCP	4	32	3	0.1	30	0.70±0.09	0.70±0.09	0.70±0.10	0.73±0.08	0.70±0.09	1606
MT CPCP	4	32	3	0.1	30	0.83±0.09	0.83±0.10	0.91±0.11	0.77±0.20	0.83±0.09	824
MCT CPCP	4	64	1	0.1	30	0.72±0.09	0.71±0.09	0.73±0.15	0.77±0.13	0.72±0.09	1127
MT CPCP	4	64	1	0.1	30	0.80±0.07	0.80±0.07	0.83±0.10	0.77±0.13	0.80±0.07	896
MCT CPCP	4	64	3	0.1	30	0.78±0.11	0.78±0.11	0.80±0.13	0.77±0.13	0.78±0.11	1976
MT CPCP	4	64	3	0.1	30	0.85±0.06	0.85±0.07	0.97±0.07	0.73±0.13	0.85±0.06	779
MCT CPCP	4	128	3	0.05	30	0.70±0.13	0.69±0.13	0.76±0.21	0.70±0.07	0.70±0.13	1897
MT CPCP	4	128	3	0.05	30	0.85±0.11	0.85±0.11	0.90±0.12	0.80±0.19	0.85±0.11	713
MCT CPCP	4	128	3	0.1	30	0.75±0.07	0.75±0.08	0.78±0.06	0.70±0.13	0.75±0.08	1400
MT CPCP	4	128	3	0.1	30	0.85±0.10	0.85±0.10	0.94±0.11	0.77±0.17	0.85±0.10	769
MCT CPCP	4	256	3	0.05	30	0.70±0.11	0.70±0.11	0.71±0.16	0.73±0.17	0.70±0.11	1842
MT CPCP	4	256	3	0.05	30	0.85±0.10	0.84±0.10	0.93±0.13	0.80±0.19	0.85±0.10	1038
MCT CPCP	8	32	3	0.05	30	0.75±0.05	0.75±0.05	0.76±0.03	0.73±0.17	0.75±0.05	1968
MT CPCP	8	32	3	0.05	30	0.78±0.13	0.78±0.13	0.81±0.11	0.73±0.17	0.78±0.13	1124
MCT CPCP	8	32	3	0.1	30	0.78±0.09	0.78±0.09	0.76±0.12	0.87±0.13	0.78±0.09	1876
MT CPCP	8	32	3	0.1	30	0.80±0.11	0.80±0.12	0.88±0.15	0.70±0.13	0.80±0.11	1125
MT CPCP	8	64	1	0.1	30	0.82±0.10	0.81±0.10	0.83±0.10	0.80±0.16	0.82±0.10	589
MCT CPCP	8	64	3	0.1	30	0.75±0.14	0.75±0.14	0.75±0.16	0.77±0.17	0.75±0.14	1913
MT CPCP	8	64	3	0.1	30	0.83±0.05	0.83±0.06	0.97±0.07	0.70±0.13	0.83±0.05	765
MCT CPCP	8	128	3	0.05	30	0.70±0.07	0.70±0.07	0.69±0.07	0.73±0.17	0.70±0.07	2035
MT CPCP	8	128	3	0.05	30	0.82±0.06	0.81±0.07	0.94±0.11	0.70±0.13	0.82±0.06	1009
MCT CPCP	8	256	3	0.05	30	0.72±0.07	0.71±0.07	0.68±0.05	0.83±0.15	0.72±0.07	2225
MT CPCP	8	256	3	0.05	30	0.87±0.04	0.86±0.04	0.95±0.10	0.80±0.13	0.87±0.04	1000

5 Sinal com características de FM

De forma análoga ao processamento com PCP, o sinal EEG foi processado por meio da extração da frequência mediana (FM) nas bandas delta, teta, alfa e beta. Para cada um dos 20 canais, obtiveram-se quatro atributos (um por banda), formando uma matriz de 20×4 elementos, totalizando 80 características adicionais por paciente como entrada para o treinamento dos modelos. Os resultados dessa abordagem, apresentados na Tabela 31, evidenciam o impacto dessas características e da variação dos hiperparâmetros nas métricas de desempenho dos modelos.

Avaliando a Tabela 31, os modelos MT CFM superam os MCT CFM em acurácia e precisão, com destaque para MT CFM ($N_H = 8, INT_D = 256, N_L =$

3, DOUT = 0,05, EPC = 30), que alcança acurácia de 0,83 e precisão de 0,96 em 950 segundos. Configurações MCT CFM apresentam desempenho inferior (em torno de 0,77) e tempos maiores (chegando a 2241 segundos). Modelos com $N_L = 3$ e $INT_D \geq 128$ oferecem melhor desempenho, enquanto $N_H = 8$ não melhora consistentemente os resultados.

Tabela 31 - Resultado Prognostico Clinico usando Transformers com características de FM variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CFM	4	32	3	0.1	30	0.75±0.09	0.75±0.09	0.77±0.14	0.77±0.13	0.75±0.09	1665
MT CFM	4	32	3	0.1	30	0.80±0.09	0.80±0.08	0.88±0.15	0.73±0.08	0.80±0.09	698
MCT CFM	4	64	1	0.1	30	0.75±0.15	0.75±0.15	0.78±0.20	0.77±0.17	0.75±0.15	1109
MT CFM	4	64	1	0.1	30	0.75±0.07	0.75±0.08	0.75±0.08	0.77±0.13	0.75±0.08	674
MCT CFM	4	64	3	0.1	30	0.73±0.12	0.73±0.12	0.75±0.16	0.73±0.17	0.73±0.12	1908
MT CFM	4	64	3	0.1	30	0.75±0.07	0.75±0.08	0.75±0.08	0.77±0.13	0.75±0.08	827
MCT CFM	4	128	3	0.05	30	0.77±0.08	0.76±0.08	0.81±0.16	0.77±0.13	0.77±0.08	1909
MT CFM	4	128	3	0.05	30	0.82±0.10	0.81±0.10	0.89±0.14	0.77±0.17	0.82±0.10	711
MCT CFM	4	256	3	0.05	30	0.75±0.09	0.74±0.09	0.81±0.17	0.73±0.17	0.75±0.09	1774
MT CFM	4	256	3	0.05	30	0.83±0.08	0.83±0.08	0.91±0.13	0.80±0.19	0.83±0.08	995
MCT CFM	8	32	3	0.05	30	0.72±0.07	0.71±0.07	0.76±0.12	0.70±0.22	0.72±0.07	1847
MT CFM	8	32	3	0.05	30	0.75±0.05	0.75±0.05	0.85±0.13	0.63±0.07	0.75±0.05	1149
MCT CFM	8	32	3	0.1	30	0.72±0.07	0.71±0.07	0.76±0.12	0.70±0.22	0.72±0.07	1900
MT CFM	8	32	3	0.1	30	0.73±0.10	0.72±0.10	0.88±0.16	0.57±0.13	0.73±0.10	1151
MT CFM	8	64	1	0.1	30	0.75±0.05	0.75±0.05	0.80±0.12	0.70±0.13	0.75±0.05	612
MCT CFM	8	64	3	0.1	30	0.78±0.11	0.78±0.12	0.83±0.16	0.77±0.17	0.78±0.11	1796
MT CFM	8	64	3	0.1	30	0.82±0.06	0.81±0.07	0.96±0.08	0.67±0.11	0.82±0.06	937
MCT CFM	8	128	3	0.05	30	0.80±0.07	0.80±0.07	0.83±0.09	0.77±0.08	0.80±0.07	2014
MT CFM	8	128	3	0.05	30	0.78±0.10	0.78±0.10	0.88±0.15	0.67±0.11	0.78±0.10	936
MCT CFM	8	256	3	0.05	30	0.75±0.14	0.73±0.16	0.86±0.15	0.63±0.29	0.75±0.14	2241
MT CFM	8	256	3	0.05	30	0.83±0.05	0.83±0.05	0.96±0.08	0.70±0.07	0.83±0.05	950

6 Sinal com características de Coerência

A seguir, a análise concentra-se nas características de coerência extraídas dos sinais, avaliando seu impacto no desempenho dos modelos. Essas características são fundamentais para capturar a sincronização e a conectividade funcional entre diferentes regiões do cérebro.

Ao observar a Tabela 32, os dados mostram que os modelos MCT CC geralmente apresentam desempenho ligeiramente superior ao MT CC, especialmente em configurações com menor número de cabeças de atenção (4) e dimensões intermediárias médias (64 a 256). Com destaque para MCT CC ($N_H = 4$, $INT_D = 64$, $N_L = 1$, $DOUT = 0,1$, $EPC = 30$), que alcança acurácia de 0,87 e precisão de 0,95 em 1281 segundos. No entanto, os modelos MT CC tendem a apresentar tempos de treinamento menores, oferecendo maior eficiência computacional. Além disso, modelos com $N_L = 3$ não melhoram consistentemente o desempenho, enquanto $N_H = 4$ oferece melhores resultados que $N_H = 8$.

Tabela 32 - Resultado Prognostico Clinico usando Transformers com características de Coerência variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CC	4	32	3	0.1	30	0.85±0.11	0.84±0.13	0.95±0.10	0.77±0.25	0.85±0.11	1646
MT CC	4	32	3	0.1	30	0.83±0.09	0.83±0.10	0.86±0.08	0.80±0.19	0.83±0.09	980
MCT CC	4	64	1	0.1	30	0.87±0.09	0.86±0.09	0.95±0.10	0.80±0.19	0.87±0.09	1281
MT CC	4	64	1	0.1	30	0.83±0.09	0.83±0.10	0.86±0.08	0.80±0.19	0.83±0.09	648
MCT CC	4	64	3	0.1	30	0.85±0.06	0.85±0.07	0.92±0.10	0.80±0.19	0.85±0.06	1611
MT CC	4	64	3	0.1	30	0.80±0.13	0.79±0.13	0.82±0.12	0.77±0.25	0.80±0.13	1085
MCT CC	4	128	3	0.05	30	0.85±0.06	0.85±0.07	0.92±0.10	0.80±0.19	0.85±0.06	2156
MT CC	4	128	3	0.05	30	0.83±0.14	0.83±0.15	0.87±0.12	0.77±0.25	0.83±0.14	725
MCT CC	4	256	1	0.1	30	0.85±0.06	0.85±0.07	0.92±0.10	0.80±0.19	0.85±0.06	1083
MT CC	4	256	1	0.1	30	0.87±0.11	0.86±0.12	0.92±0.10	0.80±0.19	0.87±0.11	632
MCT CC	4	256	3	0.05	30	0.83±0.05	0.83±0.06	0.90±0.12	0.80±0.19	0.83±0.05	1744
MT CC	4	256	3	0.05	30	0.80±0.09	0.80±0.09	0.81±0.11	0.80±0.19	0.80±0.09	902
MCT CC	8	32	3	0.05	30	0.87±0.09	0.86±0.09	0.95±0.10	0.80±0.19	0.87±0.09	1884
MT CC	8	32	3	0.05	30	0.83±0.14	0.83±0.15	0.86±0.13	0.80±0.27	0.83±0.14	1138
MCT CC	8	32	3	0.1	30	0.85±0.06	0.85±0.07	0.92±0.10	0.80±0.19	0.85±0.06	1890
MT CC	8	32	3	0.1	30	0.83±0.12	0.83±0.12	0.86±0.12	0.80±0.19	0.83±0.12	1135
MT CC	8	64	1	0.1	30	0.82±0.08	0.81±0.09	0.84±0.09	0.80±0.19	0.82±0.08	718
MCT CC	8	64	3	0.1	30	0.85±0.11	0.84±0.13	0.95±0.10	0.77±0.25	0.85±0.11	1903
MT CC	8	64	3	0.1	30	0.83±0.09	0.83±0.10	0.86±0.08	0.80±0.19	0.83±0.09	1188
MCT CC	8	128	3	0.05	30	0.85±0.06	0.85±0.07	0.92±0.10	0.80±0.19	0.85±0.06	2020
MT CC	8	128	3	0.05	30	0.80±0.10	0.79±0.10	0.84±0.10	0.77±0.23	0.80±0.10	1028
MCT CC	8	256	3	0.05	30	0.85±0.06	0.85±0.07	0.92±0.10	0.80±0.19	0.85±0.06	2078
MT CC	8	256	3	0.05	30	0.78±0.10	0.78±0.11	0.80±0.11	0.77±0.25	0.78±0.10	1189

7 Sinal com características do paciente e estatísticas

Nesta configuração, foram adicionadas 103 características ao conjunto de entrada para cada paciente, sendo 3 referentes às informações clínicas e 100 derivadas dos dados estatísticos previamente mencionados. Os resultados do treinamento com essa configuração estão apresentados na Tabela 33.

Os resultados exibidos na Tabela 33, evidenciam que os modelos MT CPE superam os MCT CPE em termos de acurácia, F1 score e precisão, com destaque para MT CPE ($N_H = 4, INT_D = 128, N_L = 3, DOUT = 0,05, EPC = 30$), que alcança acurácia de 0,85 e precisão de 0,97 em 413 segundos, enquanto os modelos MCT CPE apresentam acurácia máxima próximo a 0,78 e tempos mais longos, acima de 900 segundos. Modelos com $N_L = 3$ e $INT_D \geq 128$ oferecem melhor desempenho, enquanto $N_H = 8$ mantém resultados similares a $N_H = 4$, mas com maior custo computacional.

Tabela 33 - Resultado Prognostico Clinico usando Transformers com características do paciente e estatísticas variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CPE	4	32	3	0.1	30	0.77±0.03	0.77±0.03	0.76±0.05	0.80±0.07	0.77±0.03	1163
MT CPE	4	32	3	0.1	30	0.83±0.11	0.83±0.11	0.88±0.10	0.77±0.17	0.83±0.11	385
MCT CPE	4	64	1	0.1	30	0.75±0.05	0.74±0.06	0.80±0.10	0.70±0.19	0.75±0.05	941
MT CPE	4	64	1	0.1	30	0.78±0.09	0.78±0.09	0.82±0.11	0.73±0.08	0.78±0.09	209
MCT CPE	4	64	3	0.1	30	0.75±0.05	0.75±0.06	0.74±0.07	0.80±0.07	0.75±0.05	1130
MT CPE	4	64	3	0.1	30	0.80±0.07	0.80±0.07	0.89±0.09	0.70±0.13	0.80±0.07	413
MCT CPE	4	128	3	0.05	30	0.75±0.07	0.74±0.09	0.72±0.09	0.87±0.13	0.75±0.08	1408
MT CPE	4	128	3	0.05	30	0.85±0.06	0.85±0.07	0.97±0.07	0.73±0.13	0.85±0.06	413
MCT CPE	4	128	3	0.1	30	0.73±0.10	0.73±0.10	0.75±0.10	0.70±0.13	0.73±0.10	1265
MT CPE	4	128	3	0.1	30	0.85±0.06	0.85±0.07	0.97±0.07	0.73±0.13	0.85±0.06	420
MCT CPE	4	256	3	0.05	30	0.78±0.09	0.78±0.09	0.76±0.07	0.83±0.11	0.78±0.09	1217
MT CPE	4	256	3	0.05	30	0.83±0.05	0.83±0.06	0.93±0.08	0.73±0.13	0.83±0.05	418
MCT CPE	8	32	3	0.05	30	0.73±0.10	0.73±0.10	0.74±0.15	0.80±0.07	0.73±0.10	1267
MT CPE	8	32	3	0.05	30	0.85±0.06	0.85±0.07	0.97±0.07	0.73±0.13	0.85±0.06	824
MCT CPE	8	32	3	0.1	30	0.73±0.10	0.73±0.10	0.71±0.08	0.77±0.17	0.73±0.10	1564
MT CPE	8	32	3	0.1	30	0.85±0.06	0.85±0.07	0.97±0.07	0.73±0.13	0.85±0.06	824
MT CPE	8	64	1	0.1	30	0.72±0.09	0.71±0.09	0.76±0.08	0.63±0.13	0.72±0.09	347
MCT CPE	8	64	3	0.1	30	0.73±0.06	0.73±0.06	0.73±0.07	0.77±0.13	0.73±0.06	1649

Modelo	N _H	INT_D	N _L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MT CPE	8	64	3	0.1	30	0.83±0.08	0.83±0.08	0.96±0.08	0.70±0.13	0.83±0.08	582
MT CPE	8	128	3	0.05	30	0.82±0.08	0.81±0.09	0.89±0.14	0.77±0.17	0.82±0.08	578
MCT CPE	8	128	3	0.1	30	0.75±0.09	0.75±0.09	0.76±0.15	0.80±0.13	0.75±0.09	1404
MT CPE	8	128	3	0.1	30	0.82±0.06	0.81±0.07	0.94±0.11	0.70±0.13	0.82±0.06	688
MCT CPE	8	256	3	0.05	30	0.77±0.06	0.76±0.07	0.75±0.09	0.83±0.11	0.77±0.06	1532
MT CPE	8	256	3	0.05	30	0.83±0.08	0.83±0.08	0.93±0.09	0.73±0.17	0.83±0.08	711

8 Sinal com características do paciente e PCP

Para esta configuração, 83 características são adicionadas ao treinamento para cada paciente, no qual 3 são características de paciente e as 80 demais são as características de PCP mencionadas anteriormente. Os resultados do treinamento com essa configuração estão apresentados na Tabela 34.

Os resultados da Tabela 34 indicam que, em geral, os modelos MT CPPCP apresentam desempenho superior aos MCT CPPCP em acurácia e precisão, com destaque para MT CPPCP ($N_H = 8$, $INT_D = 64$, $N_L = 3$, $DOUT = 0,1$, $EPC = 30$), que alcança acurácia de 0,83 e precisão de 0,93 em 1046 segundos. Em contraste, os modelos MCT CPPCP apresentam acurácia máxima em torno de 0,83, mas com tempos de processamento consideravelmente maiores, chegando a 2090 segundos. Modelos com $N_L = 3$ e $INT_D \geq 64$ oferecem melhor desempenho, enquanto $N_H = 8$ não melhora significativamente os resultados.

Tabela 34 - Resultado Prognóstico Clínico usando Transformers com características do paciente e PCP variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N _H	INT_D	N _L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CPPCP	4	32	3	0.1	30	0.80±0.09	0.80±0.08	0.84±0.14	0.77±0.13	0.80±0.09	1600
MT CPPCP	4	32	3	0.1	30	0.83±0.08	0.83±0.08	0.90±0.09	0.77±0.17	0.83±0.08	778
MCT CPPCP	4	64	1	0.05	30	0.78±0.09	0.78±0.09	0.79±0.13	0.83±0.11	0.78±0.09	1169
MT CPPCP	4	64	1	0.05	30	0.82±0.06	0.82±0.06	0.84±0.09	0.80±0.13	0.82±0.06	779
MCT CPPCP	4	64	1	0.1	30	0.80±0.07	0.80±0.07	0.82±0.02	0.77±0.13	0.80±0.07	917
MT CPPCP	4	64	1	0.1	30	0.80±0.07	0.80±0.07	0.81±0.10	0.80±0.13	0.80±0.07	964
MCT CPPCP	4	128	3	0.05	30	0.78±0.04	0.78±0.04	0.78±0.04	0.80±0.13	0.78±0.04	1554

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MT CPPCP	4	128	3	0.05	30	0.78±0.09	0.78±0.09	0.82±0.10	0.73±0.13	0.78±0.09	709
MCT CPPCP	4	128	3	0.1	30	0.77±0.03	0.76±0.03	0.81±0.11	0.73±0.08	0.77±0.03	1362
MT CPPCP	4	128	3	0.1	30	0.82±0.06	0.81±0.07	0.93±0.09	0.70±0.13	0.82±0.06	795
MCT CPPCP	4	256	3	0.05	30	0.80±0.07	0.80±0.07	0.80±0.11	0.83±0.11	0.80±0.07	1690
MT CPPCP	4	256	3	0.05	30	0.83±0.05	0.83±0.06	0.92±0.11	0.77±0.17	0.83±0.05	1125
MCT CPPCP	8	32	3	0.05	30	0.77±0.11	0.76±0.11	0.77±0.13	0.77±0.17	0.77±0.11	2064
MT CPPCP	8	32	3	0.05	30	0.80±0.07	0.80±0.07	0.90±0.13	0.70±0.07	0.80±0.07	1151
MT CPPCP	8	32	3	0.1	30	0.80±0.09	0.80±0.09	0.86±0.13	0.73±0.08	0.80±0.09	1143
MCT CPPCP	8	32	3	0.1	30	0.70±0.07	0.69±0.07	0.68±0.08	0.80±0.13	0.70±0.07	1735
MT CPPCP	8	64	1	0.1	30	0.82±0.03	0.82±0.03	0.86±0.07	0.77±0.08	0.82±0.03	670
MCT CPPCP	8	64	3	0.1	30	0.78±0.04	0.78±0.04	0.78±0.05	0.80±0.07	0.78±0.04	2090
MT CPPCP	8	64	3	0.1	30	0.83±0.08	0.83±0.08	0.93±0.13	0.77±0.17	0.83±0.08	1046
MCT CPPCP	8	128	3	0.05	30	0.73±0.06	0.73±0.06	0.73±0.08	0.77±0.08	0.73±0.06	1863
MT CPPCP	8	128	3	0.05	30	0.80±0.07	0.80±0.07	0.89±0.09	0.70±0.13	0.80±0.07	931
MCT CPPCP	8	256	3	0.05	30	0.83±0.05	0.83±0.05	0.83±0.02	0.83±0.11	0.83±0.05	1878
MT CPPCP	8	256	3	0.05	30	0.83±0.05	0.83±0.06	0.92±0.11	0.77±0.17	0.83±0.05	945

9 Sinal com características do paciente e FM

Nesta configuração, utiliza-se 80 valores referente as características de FM mencionados anteriormente, combinado com 3 características clínicas do paciente, totalizando 83 valores adicionais para cada paciente que compõem o treinamento. Os resultados do treinamento com essa combinação são apresentados na Tabela 35.

Analisando a Tabela 35, os modelos MT CPM apresentam desempenho superior aos MCT CPM, com destaque para MT CPM SPV ($N_H = 4, INT_D = 64, N_L = 3, DOUT = 0,1, EPC = 30$), que alcança acurácia de 0,83 e precisão de 0,89 em 2626 segundos. A variante MCT CPM SREA ($N_H = 4, INT_D = 128, N_L = 3, DOUT = 0,05$) atinge a maior acurácia (0,87), com tempo menor (736 segundos). Ressalva-se também que o processamento sem placa de vídeo (MT CPM SPV) não garantiu melhoria significativa no desempenho, mas aumentou o tempo de treinamento. Além disso, percebe-se que não reamostrar o sinal para MCT melhora a performance das métricas.

Tabela 35 - Resultado Prognostico Clinico usando Transformers com características do paciente e FM variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N _H	INT_D	N _L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CPMF	4	32	1	0.05	30	0.70±0.09	0.69±0.09	0.71±0.08	0.70±0.19	0.70±0.09	1571
MT CPMF	4	32	1	0.05	30	0.82±0.14	0.82±0.15	0.85±0.15	0.77±0.17	0.82±0.14	571
MCT CPMF	4	32	1	0.1	30	0.75±0.12	0.75±0.12	0.78±0.15	0.73±0.17	0.75±0.12	1060
MT CPMF	4	32	1	0.1	30	0.83±0.12	0.83±0.12	0.86±0.13	0.80±0.13	0.83±0.12	568
MCT CPMF	4	32	3	0.1	30	0.75±0.05	0.74±0.06	0.75±0.06	0.77±0.17	0.75±0.05	1756
MT CPMF	4	32	3	0.1	30	0.80±0.11	0.80±0.12	0.88±0.15	0.70±0.13	0.80±0.11	936
MCT CPMF	4	64	1	0.1	30	0.82±0.06	0.82±0.06	0.82±0.10	0.83±0.11	0.82±0.06	966
MT CPMF SPV	4	64	1	0.1	30	0.75±0.05	0.75±0.05	0.75±0.06	0.77±0.08	0.75±0.05	1673
MT CPMF	4	64	1	0.1	30	0.75±0.05	0.75±0.05	0.80±0.11	0.70±0.07	0.75±0.05	549
MCT CPMF SREA	4	64	3	0.1	30	0.85±0.03	0.85±0.03	0.93±0.08	0.77±0.08	0.85±0.03	815
MCT CPMF	4	64	3	0.1	30	0.77±0.10	0.76±0.10	0.76±0.09	0.80±0.13	0.77±0.10	1568
MT CPMF SPV	4	64	3	0.1	30	0.83±0.09	0.83±0.10	0.89±0.10	0.77±0.17	0.83±0.09	2626
MT CPMF	4	64	3	0.1	30	0.80±0.09	0.80±0.09	0.88±0.10	0.70±0.13	0.80±0.09	728
MCT CPMF SREA	4	128	3	0.05	30	0.87±0.04	0.87±0.04	0.94±0.08	0.80±0.13	0.87±0.04	736
MCT CPMF	4	128	3	0.05	30	0.73±0.06	0.73±0.06	0.76±0.13	0.73±0.08	0.73±0.06	1468
MT CPMF	4	128	3	0.05	30	0.82±0.08	0.81±0.09	0.87±0.11	0.77±0.17	0.82±0.08	701
MCT CPMF	4	256	3	0.05	30	0.77±0.06	0.76±0.07	0.76±0.07	0.80±0.13	0.77±0.06	1860
MT CPMF	4	256	3	0.05	30	0.77±0.12	0.77±0.12	0.79±0.14	0.73±0.13	0.77±0.12	888
MCT CPMF	8	32	3	0.05	30	0.77±0.06	0.76±0.07	0.79±0.13	0.77±0.08	0.77±0.06	1925
MT CPMF	8	32	3	0.05	30	0.77±0.08	0.77±0.08	0.81±0.11	0.70±0.07	0.77±0.08	1166
MCT CPMF	8	32	3	0.1	30	0.75±0.07	0.75±0.08	0.79±0.13	0.73±0.08	0.75±0.08	1978
MT CPMF	8	32	3	0.1	30	0.78±0.07	0.78±0.07	0.84±0.08	0.70±0.07	0.78±0.07	1169
MT CPMF	8	64	1	0.1	30	0.78±0.09	0.78±0.09	0.85±0.14	0.73±0.13	0.78±0.09	592
MCT CPMF	8	64	3	0.1	30	0.75±0.07	0.74±0.08	0.79±0.12	0.73±0.17	0.75±0.08	1937
MT CPMF	8	64	3	0.1	30	0.82±0.10	0.81±0.10	0.91±0.11	0.70±0.13	0.82±0.10	894
MCT CPMF	8	128	3	0.05	30	0.78±0.04	0.78±0.04	0.81±0.11	0.77±0.08	0.78±0.04	1936
MT CPMF	8	128	3	0.05	30	0.80±0.11	0.80±0.12	0.88±0.15	0.70±0.13	0.80±0.11	848
MCT CPMF	8	256	3	0.05	30	0.77±0.08	0.76±0.09	0.85±0.14	0.70±0.13	0.77±0.08	1984
MT CPMF	8	256	3	0.05	30	0.82±0.06	0.82±0.06	0.87±0.11	0.77±0.08	0.82±0.06	1001

10 Sinal com características do paciente e Coerência

Para esta configuração, além das características de coerência extraídas dos sinais EEG, são incorporadas as características clínicas do paciente. Os resultados

do treinamento com essa combinação são apresentados na Tabela 36, destacando o impacto dessas características nas métricas de desempenho dos modelos.

Observando a Tabela 36, percebe-se que os modelos MCT CPC superam ligeiramente os MT CPC em acurácia e precisão, com destaque para MCT CPC ($N_H = 4$, $INT_D = 32$, $N_L = 3$, $DOUT = 0,1$, $EPC = 30$), que alcança acurácia de 0,90 e precisão de 0,97 em 1526 segundos. Configurações MT CPC apresentam desempenho competitivo, mas com tempos menores. Modelos com $N_L = 3$ e $INT_D \leq 64$ oferecem os melhores resultados, enquanto $N_H = 8$ não melhora significativamente a acurácia. O processamento sem placa de vídeo (MT CPC SPV) não mostrou ganhos expressivos em desempenho, mas aumentou o tempo de processamento.

Tabela 36 - Resultado Prognostico Clinico usando Transformers com características do paciente e Coerência variando os hiperparâmetros, em negrito se destaca o melhor resultado para MT e MCT

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CPC	4	32	1	0.1	30	0.87±0.04	0.86±0.04	0.92±0.10	0.83±0.15	0.87±0.04	1070
MT CPC	4	32	1	0.1	30	0.87±0.07	0.87±0.07	0.90±0.08	0.83±0.15	0.87±0.07	658
MT CPC SPV	4	32	1	0.1	30	0.87±0.07	0.87±0.07	0.90±0.08	0.83±0.15	0.87±0.07	1257
MCT CPC	4	32	3	0.1	30	0.90±0.06	0.90±0.06	0.97±0.06	0.83±0.15	0.90±0.06	1526
MT CPC	4	32	3	0.1	30	0.85±0.06	0.85±0.06	0.87±0.07	0.83±0.15	0.85±0.06	917
MCT CPC	4	64	1	0.1	30	0.88±0.04	0.88±0.04	0.94±0.07	0.83±0.15	0.88±0.04	922
MT CPC	4	64	1	0.1	30	0.85±0.06	0.85±0.06	0.87±0.07	0.83±0.15	0.85±0.06	587
MCT CPC	4	128	3	0.05	30	0.88±0.04	0.88±0.04	0.94±0.07	0.83±0.15	0.88±0.04	1505
MT CPC	4	128	3	0.05	30	0.80±0.07	0.80±0.07	0.81±0.12	0.83±0.15	0.80±0.07	738
MCT CPC	8	32	3	0.05	30	0.88±0.04	0.88±0.04	0.94±0.07	0.83±0.15	0.88±0.04	1917
MT CPC	8	32	3	0.05	30	0.87±0.04	0.87±0.04	0.91±0.07	0.83±0.15	0.87±0.04	1161
MCT CPC	8	32	3	0.1	30	0.85±0.06	0.85±0.07	0.92±0.10	0.80±0.19	0.85±0.06	1981
MT CPC	8	32	3	0.1	30	0.85±0.06	0.85±0.06	0.87±0.07	0.83±0.15	0.85±0.06	1165
MT CPC	8	64	1	0.1	30	0.85±0.06	0.85±0.06	0.87±0.07	0.83±0.15	0.85±0.06	693
MCT CPC	8	64	3	0.1	30	0.88±0.04	0.88±0.04	0.94±0.07	0.83±0.15	0.88±0.04	1974
MT CPC	8	64	3	0.1	30	0.85±0.06	0.85±0.06	0.87±0.07	0.83±0.15	0.85±0.06	927
MCT CPC	8	128	3	0.05	30	0.88±0.04	0.88±0.04	0.94±0.07	0.83±0.15	0.88±0.04	1943
MT CPC	8	128	3	0.05	30	0.85±0.06	0.85±0.06	0.87±0.07	0.83±0.15	0.85±0.06	980
MCT CPC	8	256	3	0.05	30	0.88±0.04	0.88±0.04	0.94±0.07	0.83±0.15	0.88±0.04	1867
MT CPC	8	256	3	0.05	30	0.85±0.06	0.85±0.06	0.87±0.07	0.83±0.15	0.85±0.06	920

APÊNDICE K - Resultados do Treinamento Etiologia do Coma

Conforme detalhado na Tabela 37, os modelos, fundamentados nas arquiteturas descritas no item **5.2 Arquiteturas**, foram treinados utilizando sinais puros de EEG, complementados por características clínicas dos pacientes e estatísticas descritivas. O processamento dos dados seguiu uma adaptação da metodologia proposta por (BALDO JÚNIOR, 2023), incorporando ajustes na arquitetura original para otimizar a integração de diferentes modelos de aprendizado de máquina, bem como a reamostragem do sinal de EEG.

Tabela 37 – Resultados do treinamento da base de dados Etiologia do Coma para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MMLP	0.32±0.08	0.21±0.07	0.21±0.10	0.26±0.06	0.75±0.03	93
MMLP SREA	0.40±0.13	0.25±0.08	0.23±0.09	0.31±0.09	0.78±0.04	98
MCL	0.40±0.11	0.30±0.10	0.28±0.12	0.35±0.11	0.79±0.04	670
MCL SREA	0.40±0.13	0.31±0.14	0.32±0.16	0.35±0.12	0.80±0.05	476
MMLP CP	0.42±0.14	0.30±0.16	0.28±0.17	0.36±0.15	0.79±0.05	92
MMLP CP SREA	0.42±0.14	0.30±0.16	0.28±0.17	0.36±0.15	0.79±0.05	91
MCL CP	0.60±0.11	0.53±0.13	0.58±0.17	0.56±0.10	0.86±0.03	787
MCL CP SREA	0.60±0.12	0.51±0.11	0.48±0.11	0.54±0.11	0.86±0.04	594
MMLP CE	0.45±0.13	0.34±0.10	0.32±0.10	0.38±0.09	0.81±0.04	98
MMLP CE SREA	0.42±0.12	0.31±0.09	0.29±0.09	0.34±0.09	0.80±0.04	99
MCL CE	0.35±0.10	0.25±0.07	0.24±0.09	0.29±0.08	0.77±0.03	702
MCL CE SREA	0.40±0.11	0.27±0.08	0.25±0.09	0.32±0.08	0.79±0.03	527
MMLP CPE	0.33±0.09	0.27±0.08	0.35±0.14	0.29±0.09	0.76±0.03	100
MMLP CPE SREA	0.27±0.06	0.15±0.04	0.13±0.06	0.20±0.05	0.74±0.02	97
MCL CPE	0.52±0.13	0.44±0.10	0.48±0.09	0.48±0.11	0.83±0.04	787
MCL CPE SREA	0.47±0.16	0.40±0.17	0.41±0.22	0.42±0.17	0.82±0.05	524

Analisando a Tabela 37, observa-se que os modelos baseados em *Multi Layer Perceptron* (MMLP) apresentaram os menores índices de acurácia e F1 score, evidenciando limitações na capacidade de capturar a complexidade dos dados. Em contrapartida, os modelos que combinam camadas convolucionais seguidas de camadas recorrentes (MCL) demonstraram desempenho superior, com destaque para

aqueles que incorporaram características clínicas dos pacientes (CP), alcançando acurácia média de 60% e especificidade de 86%.

Esses resultados ressaltam a importância da inclusão de atributos clínicos para aprimorar a classificação. Ademais, os desempenhos obtidos são bastante próximos aos reportados por (BALDO JÚNIOR, 2023), o que reforça a consistência dos resultados mesmo diante de modificações na arquitetura base e variações nas configurações de hardware utilizadas nos experimentos. A reamostragem do sinal para 400 Hz (ausente nos modelos SREA) apresentou impacto variável, promovendo ligeiras melhorias em alguns modelos. Por fim, os tempos de processamento indicam que os modelos MCL demandam maior custo computacional em comparação aos MMLP, refletindo a maior complexidade dessas arquiteturas.

Para aprimorar o desempenho dos modelos na classificação da etiologia do coma, foram incorporados atributos extraídos por meio de *software* de processamento de EEG, incluindo o quantificador de Porcentagem de Contribuição de Potência (PCP), Frequência Mediana (FM) e Coerência. Esses atributos, que capturam características específicas das bandas de frequência e da conectividade cerebral, com os resultados apresentados na Tabela 38.

Tabela 38 – Resultados do treinamento da base de dados Etiologia do Coma para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPCP	0.43±0.10	0.36±0.09	0.36±0.10	0.39±0.10	0.81±0.03	1053
MCL CPCP SREA	0.45±0.16	0.32±0.11	0.31±0.11	0.38±0.14	0.81±0.05	610
MCL CPPCP	0.48±0.19	0.39±0.13	0.41±0.08	0.41±0.15	0.82±0.06	1046
MCL CPPCP SREA	0.50±0.11	0.35±0.05	0.32±0.05	0.40±0.07	0.83±0.03	661
MCL CFM	0.32±0.13	0.22±0.08	0.21±0.09	0.28±0.11	0.76±0.04	959
MCL CFM SREA	0.45±0.11	0.33±0.07	0.37±0.08	0.38±0.10	0.81±0.04	662
MCL CPFM	0.53±0.13	0.46±0.10	0.47±0.11	0.49±0.12	0.84±0.04	968
MCL CPFM SREA	0.53±0.15	0.41±0.11	0.42±0.10	0.45±0.13	0.84±0.05	588
MCL CC	0.48±0.10	0.41±0.09	0.41±0.10	0.44±0.11	0.82±0.03	1115
MCL CPC	0.45±0.16	0.38±0.15	0.43±0.21	0.42±0.17	0.81±0.05	1124
MCL CPC SPV	0.47±0.17	0.40±0.19	0.42±0.23	0.43±0.19	0.82±0.06	2772

Os resultados da Tabela 38 mostram que o modelo MCL CPEFM obteve o melhor desempenho, com F1 score (macro) de 0,46 e especificidade de 0,84, destacando-se pela integração de características do paciente e frequência mediana. A não utilização de placa de vídeo (SPV) quase triplica tempo de processamento, sem ganhos expressivos nas métricas.

Em seguida, realizou-se o treinamento dos modelos utilizando sinais de EEG provenientes das regiões cerebrais frontal, central, occipital, parietal e temporal, conforme detalhado na Tabela 39. Essa abordagem buscou avaliar o impacto da análise regionalizada do sinal EEG na classificação das etiologias do coma.

Tabela 39 – Resultados do treinamento da base de dados Etiologia do Coma com características do paciente e regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPEF	0.63 ± 0.14	0.59 ± 0.16	0.65 ± 0.21	0.62 ± 0.14	0.87 ± 0.04	813
MCL CPEF SREA	0.60 ± 0.11	0.53 ± 0.07	0.56 ± 0.07	0.55 ± 0.08	0.86 ± 0.04	579
MCL CPEC	0.58 ± 0.14	0.54 ± 0.17	0.60 ± 0.24	0.54 ± 0.14	0.86 ± 0.04	912
MCL CPEC SREA	0.55 ± 0.11	0.49 ± 0.12	0.52 ± 0.16	0.50 ± 0.10	0.85 ± 0.04	569
MCL CPEO	0.57 ± 0.19	0.48 ± 0.20	0.51 ± 0.22	0.51 ± 0.19	0.85 ± 0.06	909
MCL CPEO SREA	0.47 ± 0.17	0.43 ± 0.17	0.47 ± 0.18	0.44 ± 0.17	0.82 ± 0.05	506
MCL CPEP	0.57 ± 0.13	0.52 ± 0.18	0.60 ± 0.23	0.52 ± 0.14	0.85 ± 0.04	771
MCL CPEP SREA	0.50 ± 0.17	0.43 ± 0.18	0.48 ± 0.22	0.45 ± 0.16	0.83 ± 0.06	579
MCL CPET	0.63 ± 0.15	0.61 ± 0.13	0.69 ± 0.15	0.61 ± 0.12	0.87 ± 0.04	922
MCL CPET SREA	0.58 ± 0.13	0.48 ± 0.17	0.51 ± 0.23	0.53 ± 0.13	0.85 ± 0.05	588

Ao analisar a Tabela 39, observa-se que o modelo MCL CPEF apresentou o melhor desempenho, alcançando acurácia de 0,63 e especificidade de 87%, evidenciando a importância da região frontal na identificação das etiologias do coma. A ausência de reamostragem do sinal (SREA) comprometeu a acurácia em todas as regiões avaliadas, indicando que a reamostragem contribui para a melhoria da qualidade dos dados e, consequentemente, do desempenho dos modelos.

Para ampliar a análise, foram testadas outras abordagens no treinamento da base de dados voltada para a etiologia do coma, buscando aprimorar a classificação das diferentes causas do coma. Os resultados obtidos com essas metodologias estão apresentados na Tabela 40.

Tabela 40 – Resultados do treinamento da base de dados Etiologia do Coma testando outras abordagens, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCLT CE	0.47±0.14	0.36±0.11	0.35±0.11	0.39±0.13	0.82±0.05	1412
MCLT CPEF	0.58±0.15	0.56±0.17	0.62±0.20	0.57±0.17	0.86±0.05	871
MCL CDW4	0.43±0.10	0.35±0.09	0.34±0.11	0.39±0.10	0.80±0.03	948

APÊNDICE L - Resultados do Treinamento Etiologia do Coma usando Transformer

Nesta seção, são apresentados os resultados do treinamento da base de dados do Coma para a classificação da etiologia do mesmo, utilizando modelos baseados em arquiteturas *TransformerEncoder*, especificamente as variações dos modelos MT e MCT.

A primeira análise que é apresentada na Tabela 41, considerou sinais puros de EEG, complementados por características clínicas dos pacientes e estatísticas descritivas, com o objetivo de avaliar o impacto dos diferentes hiperparâmetros na performance dos modelos.

Tabela 41 - Resultados do treinamento da base de dados Etiologia do Coma usando Transformers variando os hiperparâmetros do modelo MT e MCT para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo

Modelo	N _H	INT_D	N _L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MT	8	128	3	0.2	60	0.38±0.15	0.32±0.14	0.30±0.13	0.36±0.16	0.79±0.05	852
MCT	8	256	3	0.05	30	0.32±0.16	0.26±0.14	0.28±0.18	0.28±0.14	0.76±0.05	1628
MT CP	4	64	3	0.1	30	0.50±0.14	0.37±0.10	0.38±0.13	0.45±0.13	0.83±0.05	501
MT CP	8	128	3	0.2	60	0.53±0.18	0.44±0.19	0.47±0.24	0.49±0.19	0.84±0.06	1250
MCT CP	8	256	3	0.05	30	0.47±0.11	0.38±0.09	0.38±0.12	0.42±0.11	0.81±0.04	1707
MT CE	4	64	3	0.1	30	0.42±0.15	0.33±0.14	0.35±0.18	0.37±0.15	0.80±0.05	517
MT CE	8	128	3	0.2	60	0.37±0.16	0.27±0.14	0.24±0.13	0.33±0.16	0.78±0.06	1539
MCT CE	8	256	3	0.05	30	0.32±0.10	0.23±0.08	0.24±0.10	0.28±0.08	0.76±0.03	1788
MT CPE	4	64	3	0.1	30	0.52±0.14	0.43±0.16	0.47±0.20	0.47±0.17	0.83±0.05	365
MT CPE	8	128	3	0.2	60	0.50±0.14	0.42±0.14	0.45±0.17	0.47±0.16	0.83±0.05	1534
MT CPE	8	256	3	0.05	30	0.47±0.16	0.40±0.15	0.41±0.17	0.42±0.16	0.81±0.05	548
MCT CPE	8	256	3	0.05	30	0.57±0.12	0.49±0.14	0.49±0.17	0.53±0.13	0.85±0.04	1758

Os resultados da Tabela 41 indicam que os modelos que incorporaram características do paciente (CP) apresentaram desempenho superior em comparação aos demais, ressaltando a importância da inclusão de atributos clínicos na classificação da etiologia do coma. Destaca-se o modelo MCT CPE ($N_H = 8$, $INT_D = 256$, $N_L = 3$, $DOUT = 0,05$, $EPC = 30$), que obteve o melhor desempenho, com acurácia de 0,57 e especificidade de 0,85. Ressalta-se ainda que os modelos baseados na arquitetura MCT demandaram maior tempo computacional, em parte

devido à execução sem o uso de placa de vídeo, conforme limitação previamente mencionada.

Para ampliar a avaliação dos modelos baseados em arquiteturas *Transformer*, foram testadas variações dos hiperparâmetros, aplicados aos atributos extraídos do EEG referentes à Participação de Contribuição de Potência (PCP), Frequência Mediana (FM) e Coerência. Os resultados obtidos com essas configurações estão apresentados na Tabela 42.

Tabela 42 - Resultados do treinamento da base de dados Etiologia do Coma usando Transformers variando os hiperparâmetros do modelo MT e MCT, para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo

Modelo	N _H	INT_D	N _L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MT CPCP	4	64	3	0.1	30	0.35±0.06	0.30±0.07	0.29±0.07	0.31±0.07	0.78±0.02	744
MT CPCP	8	128	3	0.2	60	0.37±0.20	0.32±0.19	0.33±0.21	0.35±0.20	0.78±0.07	1876
MCT CPCP	8	256	3	0.05	30	0.43±0.13	0.33±0.09	0.36±0.12	0.36±0.10	0.80±0.04	2046
MT CPPCP	4	64	3	0.1	30	0.43±0.16	0.39±0.16	0.42±0.23	0.40±0.17	0.81±0.05	804
MT CPPCP	8	128	3	0.2	60	0.45±0.23	0.39±0.22	0.41±0.23	0.41±0.23	0.81±0.07	1873
MCT CPPCP	8	256	3	0.05	30	0.48±0.03	0.41±0.06	0.44±0.08	0.45±0.06	0.82±0.01	2023
MT CFM	4	64	3	0.1	30	0.40±0.08	0.32±0.07	0.33±0.11	0.37±0.09	0.79±0.03	783
MT CFM	8	128	3	0.2	60	0.47±0.13	0.38±0.12	0.40±0.10	0.42±0.13	0.81±0.04	1855
MCT CFM	8	256	3	0.05	30	0.28±0.11	0.19±0.07	0.24±0.11	0.23±0.08	0.75±0.04	1926
MT CPFM	4	64	3	0.1	30	0.45±0.07	0.38±0.05	0.43±0.07	0.41±0.06	0.82±0.02	791
MT CPFM	8	128	3	0.2	60	0.45±0.14	0.35±0.12	0.36±0.12	0.40±0.14	0.81±0.05	1847
MT CPFM	8	256	3	0.05	30	0.50±0.14	0.41±0.14	0.42±0.11	0.43±0.15	0.82±0.05	957
MCT CPFM	8	256	3	0.05	30	0.52±0.14	0.44±0.07	0.45±0.06	0.47±0.12	0.83±0.05	1933
MT CC	4	64	3	0.1	30	0.37±0.09	0.31±0.09	0.30±0.07	0.33±0.12	0.78±0.03	686
MT CC	8	128	3	0.2	60	0.32±0.13	0.26±0.12	0.28±0.10	0.30±0.16	0.77±0.04	1746
MCT CC	8	256	3	0.05	30	0.45±0.16	0.36±0.15	0.38±0.21	0.39±0.17	0.81±0.05	1997
MT CPC	4	64	3	0.1	30	0.42±0.12	0.34±0.14	0.34±0.17	0.37±0.14	0.80±0.04	753
MT CPC	8	128	3	0.2	60	0.43±0.14	0.36±0.15	0.35±0.15	0.40±0.15	0.81±0.05	1673
MCT CPC	8	256	3	0.05	30	0.37±0.07	0.31±0.06	0.32±0.11	0.33±0.07	0.79±0.03	1963

Os resultados apresentados na Tabela 42 indicam que o modelo MCT CPFM (N_H = 8, INT_D = 256, N_L = 3, DOUT = 0,05, EPC = 30) obteve o melhor desempenho, alcançando um F1 score macro de 0,44 e especificidade de 0,83, evidenciando a eficácia da integração entre características clínicas dos pacientes e a frequência mediana do EEG. Observa-se que o aumento do número de cabeças de

atenção (N_H) e da dimensão intermediária (INT_D) contribui, em geral, para a melhoria dos resultados, embora implique em maior tempo de processamento. Diante do exposto, percebe-se que os modelos que incorporaram características do paciente combinadas com os quantificadores apresentaram desempenho superior em relação às demais configurações.

Na etapa seguinte, foram avaliados os resultados do treinamento dos modelos baseados em arquitetura *Transformer* utilizando sinais puros de EEG provenientes das regiões cerebrais frontal, central, occipital, parietal e temporal. Os resultados, apresentados na Tabela 43, analisam o desempenho dessas configurações na identificação de etiologias.

Tabela 43 - Resultados do treinamento da base de dados Etiologia do Coma usando Transformers com Sinal Puro variando os hiperparâmetros do modelo MT para as regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CEF	3	128	3	0.2	60	0.40±0.16	0.34±0.18	0.36±0.21	0.38±0.18	0.79±0.06	2374
MT CEF	7	128	3	0.2	60	0.47±0.13	0.38±0.11	0.42±0.10	0.44±0.14	0.82±0.04	681
MT CEF	3	128	3	0.2	60	0.45±0.07	0.37±0.08	0.35±0.09	0.43±0.08	0.81±0.02	687
MCT CEC	3	128	3	0.2	60	0.47±0.10	0.39±0.08	0.39±0.11	0.43±0.11	0.82±0.04	2344
MT CEC	3	128	3	0.2	60	0.38±0.10	0.24±0.11	0.24±0.14	0.33±0.10	0.78±0.04	632
MCT CEP	3	128	3	0.2	60	0.40±0.21	0.35±0.21	0.36±0.21	0.37±0.22	0.80±0.06	2345
MT CEP	3	128	3	0.2	60	0.38±0.10	0.22±0.08	0.20±0.09	0.30±0.09	0.77±0.04	538
MCT CEO	3	128	3	0.2	60	0.33±0.14	0.27±0.12	0.27±0.13	0.30±0.12	0.78±0.05	2315
MT CEO	3	128	3	0.2	60	0.28±0.13	0.17±0.08	0.17±0.10	0.23±0.08	0.74±0.04	544
MCT CET	3	128	3	0.2	60	0.47±0.04	0.39±0.09	0.46±0.11	0.41±0.06	0.82±0.02	2333
MT CET	3	128	3	0.2	60	0.30±0.10	0.20±0.09	0.21±0.12	0.25±0.09	0.75±0.03	586

Os resultados da Tabela 43 indicam que o modelo MCT CET (N_H = 3, INT_D = 128, N_L = 3, DOUT = 0,2, EPC = 60) apresentou o melhor desempenho, alcançando acurácia de 0,47 e precisão de 0,46, ressaltando a importância da região temporal na identificação das etiologias do coma. Os modelos MT CEF e MCT CEC também obtiveram resultados expressivos, com acurácia próxima a 0,47, enquanto as configurações aplicadas à região occipital (CEO) apresentaram desempenho inferior, com acurácia inferior a 0,33.

APÊNDICE M - Resultados do Treinamento Etiologia do Coma removendo os exames pertencentes ao rótulo OUTROS

Com o objetivo de aprimorar a acurácia na classificação da etiologia do coma, foi implementada a sugestão do coorientador Murillo de remover da base de dados os exames de eletroencefalograma (EEG) pertencentes ao rótulo OUTROS, conforme apresentado a seguir. Essa decisão fundamenta-se na heterogeneidade do grupo OUTROS, que engloba diversas etiologias do coma, o que pode dificultar a capacidade dos modelos de aprendizado de máquina em classificá-los com precisão devido à grande variabilidade de padrões cerebrais. Ao excluir esses exames, espera-se aumentar a assertividade dos modelos, uma vez que a gama de etiologias a serem classificadas torna-se mais específica, permitindo uma análise mais focada em condições como traumatismo cranioencefálico, coma metabólico e acidente vascular cerebral, conforme descrito no item **5.10.2 Base de dados**.

Conforme a metodologia apresentada anteriormente, a primeira análise baseou-se nos modelos fundamentados nas arquiteturas descritas no item **5.2 Arquiteturas**, que foram treinados utilizando sinais puros de EEG, complementados por características clínicas dos pacientes e estatísticas descritivas. Os resultados desse treinamento, apresentados na Tabela 44.

Tabela 44 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rótulo outros, para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MMLP	0.44±0.15	0.36±0.12	0.35±0.12	0.38±0.12	0.71±0.08	147
MCL	0.54±0.16	0.49±0.18	0.51±0.20	0.52±0.17	0.76±0.09	664
MMLP CP	0.38±0.19	0.33±0.20	0.31±0.21	0.37±0.20	0.67±0.10	78
MCL CP	0.58±0.12	0.51±0.08	0.54±0.07	0.54±0.08	0.78±0.05	546
MMLP CE	0.50±0.14	0.44±0.14	0.47±0.18	0.48±0.15	0.75±0.07	84
MCL CE	0.56±0.10	0.50±0.10	0.50±0.13	0.54±0.12	0.78±0.06	643
MMLP CPE	0.34±0.08	0.24±0.09	0.21±0.11	0.31±0.08	0.65±0.04	78
MCL CPE	0.60±0.14	0.56±0.16	0.61±0.18	0.59±0.15	0.80±0.06	625

Os resultados da Tabela 44, indicam que os modelos baseados em *Multi Layer Perceptron* (MMLP) apresentaram desempenho inferior em relação aos

modelos com camadas convolucionais recorrentes (MCL). O modelo MCL CPE, que combina sinais puros de EEG com características do paciente e estatísticos, destacou-se com a maior acurácia média de 60% e especificidade elevada de 80%. Os tempos de processamento dos modelos MCL foram consideravelmente maiores, refletindo a maior complexidade computacional dessas arquiteturas.

A seguir, na Tabela 45, são apresentados os resultados do treinamento utilizando os atributos extraídos do EEG, especificamente PCP, FM e Coerência.

Tabela 45 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rótulo outros, para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPCP	0.54±0.14	0.47±0.12	0.48±0.13	0.49±0.11	0.76±0.08	936
MCL CPPCP	0.58±0.13	0.50±0.13	0.53±0.13	0.55±0.11	0.79±0.06	847
MCL CFM	0.52±0.17	0.49±0.18	0.55±0.24	0.49±0.17	0.75±0.09	949
MCL CPFM	0.64±0.17	0.60±0.20	0.66±0.23	0.62±0.18	0.81±0.09	942
MCL CC	0.54±0.17	0.48±0.17	0.50±0.19	0.51±0.18	0.77±0.09	942
MCL CPC	0.62±0.16	0.58±0.18	0.64±0.20	0.61±0.17	0.81±0.08	871

Os resultados da Tabela 45 mostram que o modelo MCL CPFM obteve o melhor desempenho, com acurácia de 0,64 e especificidade de 0,81, destacando a eficácia da integração de características do paciente e frequência mediana para identificar etiologias. Os tempos de processamento foram relativamente semelhantes entre os modelos, variando entre 847 e 949 segundos.

A Tabela 46 apresenta os resultados do treinamento considerando as regiões cerebrais frontal, central, occipital, parietal e temporal, permitindo avaliar o desempenho dos modelos em diferentes áreas do cérebro. Essa análise visa compreender a contribuição específica de cada região na classificação da etiologia do coma, considerando a complexidade e a diversidade funcional das áreas cerebrais envolvidas.

Tabela 46 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, com regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CEF	0.68±0.16	0.64±0.18	0.69±0.21	0.67±0.18	0.84±0.08	1483
MCL CEC	0.60±0.16	0.56±0.16	0.61±0.18	0.58±0.16	0.80±0.08	1484
MCL CEO	0.46±0.16	0.42±0.17	0.45±0.23	0.47±0.20	0.72±0.09	1095
MCL CEP	0.50±0.13	0.46±0.10	0.48±0.12	0.47±0.11	0.75±0.06	1414
MCL CET	0.54±0.17	0.48±0.17	0.51±0.19	0.50±0.16	0.77±0.09	1418
MCL CPEF	0.70±0.14	0.68±0.18	0.72±0.18	0.70±0.16	0.85±0.07	733
MCL CPEF FA=200 400 pontos	0.62±0.12	0.60±0.16	0.65±0.17	0.62±0.15	0.81±0.06	462
MCL CPEC	0.64±0.19	0.60±0.21	0.64±0.19	0.62±0.18	0.81±0.08	734
MCL CPEO	0.62±0.19	0.59±0.22	0.64±0.23	0.60±0.20	0.80±0.10	753
MCL CPEO FA=200 400 pontos	0.62±0.20	0.58±0.23	0.60±0.26	0.60±0.21	0.80±0.10	467
MCL CPEP	0.64±0.16	0.60±0.18	0.64±0.19	0.61±0.16	0.82±0.07	763
MCL CPET	0.70±0.14	0.67±0.16	0.71±0.18	0.67±0.15	0.84±0.07	715
MCL CEEF	0.58±0.16	0.55±0.13	0.64±0.12	0.56±0.15	0.79±0.08	747
MCL CEEC	0.58±0.12	0.55±0.10	0.62±0.11	0.55±0.10	0.79±0.05	745
MCL CEEO	0.58±0.12	0.51±0.09	0.54±0.12	0.53±0.09	0.79±0.06	741
MCL CEEP	0.54±0.05	0.49±0.07	0.54±0.12	0.50±0.05	0.77±0.04	751
MCL CEET	0.58±0.17	0.51±0.17	0.54±0.18	0.54±0.18	0.79±0.08	736

Os resultados apresentados na Tabela 46 destacam que as regiões frontal e temporal, quando combinadas com características do paciente, alcançaram uma acurácia de 70%, com o modelo MCL CPEF apresentando a melhor performance geral. A reamostragem dos dados (FA=200, 400 pontos) contribuiu para a redução do tempo computacional, como observado no modelo MCL CPEF, cujo tempo diminuiu de 733 para 462 segundos. Contudo, essa redução no tempo foi acompanhada por uma queda na acurácia, evidenciando um trade-off entre eficiência computacional e desempenho do modelo.

APÊNDICE N - Resultados do Treinamento Etiologia do Coma usando Transformer removendo os exames pertencentes ao rótulo OUTROS

De forma análoga ao descrito no **APÊNDICE L - Resultados do Treinamento Etiologia do Coma usando Transformer**, foram realizados experimentos com arquiteturas *Transformer* (MT e MCT), utilizando a base de dados sem os exames do rótulo OUTROS. Os resultados, apresentados nas tabelas subsequentes, avaliam o desempenho dessas configurações na classificação de etiologias.

Os resultados apresentados na Tabela 47 avaliam o desempenho do modelo *Transformer* (MT), com variação de hiperparâmetros, utilizando sinais puros de EEG.

Tabela 47 - Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rótulo outros, usando Transformers com Sinal Puro variando os hiperparâmetros do modelo MT, em negrito se destaca o melhor modelo

Mod.	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MT	4	64	1	0.1	30	0.42±0.10	0.35±0.11	0.33±0.11	0.40±0.11	0.69±0.05	164
MT	4	64	1	0.1	60	0.46±0.15	0.41±0.14	0.41±0.14	0.43±0.15	0.72±0.07	298
MT	4	64	1	0.2	30	0.42±0.10	0.38±0.14	0.39±0.16	0.40±0.14	0.70±0.05	167
MT	4	64	1	0.2	60	0.42±0.12	0.38±0.14	0.38±0.15	0.41±0.14	0.70±0.06	294
MT	4	64	3	0.1	30	0.56±0.05	0.49±0.09	0.48±0.13	0.55±0.11	0.77±0.03	360
MT	4	64	3	0.1	60	0.62±0.08	0.53±0.09	0.51±0.12	0.60±0.07	0.81±0.04	642
MT	4	64	3	0.1	120	0.54±0.05	0.45±0.07	0.46±0.13	0.52±0.11	0.76±0.04	1255
MT	4	64	3	0.2	30	0.48±0.13	0.45±0.12	0.51±0.16	0.48±0.15	0.73±0.06	366
MT	4	64	3	0.2	60	0.52±0.12	0.48±0.13	0.52±0.14	0.53±0.15	0.76±0.06	649
MT	4	128	1	0.1	30	0.48±0.12	0.37±0.11	0.41±0.18	0.43±0.10	0.73±0.06	150
MT	4	128	1	0.1	60	0.50±0.09	0.44±0.08	0.52±0.10	0.47±0.09	0.74±0.05	315
MT	4	128	1	0.2	30	0.44±0.14	0.34±0.13	0.34±0.19	0.40±0.12	0.71±0.07	162
MT	4	128	1	0.2	60	0.52±0.10	0.46±0.10	0.53±0.14	0.50±0.13	0.76±0.06	308
MT	4	128	1	0.2	120	0.56±0.14	0.52±0.16	0.54±0.18	0.54±0.17	0.78±0.08	647
MT	4	128	3	0.1	30	0.48±0.12	0.45±0.12	0.53±0.13	0.48±0.13	0.73±0.06	360
MT	4	128	3	0.1	60	0.56±0.20	0.52±0.21	0.55±0.19	0.55±0.21	0.78±0.10	655
MT	4	128	3	0.2	30	0.48±0.16	0.45±0.17	0.50±0.19	0.50±0.18	0.74±0.08	357
MT	4	128	3	0.2	60	0.54±0.14	0.47±0.13	0.53±0.16	0.52±0.16	0.77±0.07	651
MT	4	128	3	0.2	120	0.58±0.10	0.55±0.10	0.64±0.15	0.58±0.12	0.79±0.06	1286
MT	4	128	3	0.2	160	0.60±0.18	0.56±0.19	0.65±0.20	0.60±0.20	0.80±0.09	1668
MT	8	64	1	0.1	30	0.46±0.14	0.37±0.10	0.35±0.11	0.41±0.10	0.71±0.07	213
MT	8	64	1	0.1	60	0.48±0.10	0.45±0.12	0.47±0.15	0.48±0.12	0.73±0.04	399

Mod.	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MT	8	64	1	0.2	30	0.48±0.13	0.39±0.09	0.37±0.10	0.43±0.10	0.72±0.07	209
MT	8	64	1	0.2	60	0.48±0.08	0.43±0.04	0.44±0.05	0.45±0.05	0.73±0.03	399
MT	8	64	3	0.1	30	0.60±0.14	0.56±0.17	0.58±0.17	0.58±0.17	0.80±0.08	441
MT	8	64	3	0.1	60	0.60±0.17	0.56±0.20	0.62±0.25	0.59±0.18	0.80±0.08	878
MT	8	64	3	0.2	30	0.52±0.20	0.50±0.21	0.54±0.20	0.54±0.23	0.77±0.10	451
MT	8	64	3	0.2	60	0.48±0.15	0.45±0.17	0.49±0.21	0.50±0.18	0.75±0.07	851
MT	8	128	1	0.1	30	0.50±0.06	0.40±0.06	0.36±0.08	0.46±0.06	0.74±0.03	206
MT	8	128	1	0.1	60	0.58±0.10	0.50±0.14	0.52±0.19	0.55±0.13	0.78±0.05	383
MT	8	128	1	0.2	30	0.50±0.06	0.40±0.07	0.38±0.10	0.46±0.06	0.74±0.03	218
MT	8	128	1	0.2	60	0.48±0.17	0.45±0.17	0.49±0.23	0.48±0.18	0.74±0.08	386
MT	8	128	3	0.05	60	0.56±0.08	0.51±0.10	0.53±0.16	0.55±0.11	0.78±0.05	1070
MT	8	128	3	0.1	30	0.54±0.14	0.50±0.12	0.61±0.14	0.55±0.15	0.77±0.07	469
MT	8	128	3	0.1	60	0.60±0.21	0.57±0.22	0.62±0.27	0.61±0.21	0.81±0.10	850
MT	8	128	3	0.2	30	0.54±0.14	0.52±0.12	0.63±0.15	0.57±0.16	0.78±0.07	428
MT	8	128	3	0.2	60	0.62±0.19	0.62±0.19	0.68±0.17	0.64±0.20	0.81±0.10	832
MT	8	128	3	0.2	120	0.64±0.16	0.60±0.22	0.62±0.24	0.64±0.20	0.82±0.09	1622
MT	8	128	3	0.2	160	0.62±0.18	0.60±0.21	0.62±0.21	0.62±0.22	0.81±0.10	2162
MT	8	256	3	0.05	30	0.66±0.15	0.61±0.13	0.64±0.14	0.63±0.14	0.83±0.07	682

Os dados apresentados na Tabela 47 demonstram que o desempenho dos modelos *Transformer* (MT) varia significativamente conforme a configuração dos hiperparâmetros, especialmente o número de camadas (N_L), a taxa de dropout (DOUT) e o número de épocas (EPC). Modelos com três camadas (N_L=3) e maior número de épocas tendem a alcançar melhores resultados, com F1 score (macro) chegando a 62%, precisão de 0,68 e especificidade de 0,81, como observado na configuração MT com N_H = 8, INT_D = 128, N_L = 3, DOUT = 0,20, EPC = 60. Além disso, o aumento do número de cabeças de atenção (N_H) e da dimensão intermediária (INT_D) também contribui para a melhora do desempenho, embora impacte diretamente no tempo de processamento, que pode variar de 164 a 2162 segundos.

Configurações com N_L = 3 e EPC ≥ 60 apresentaram melhores resultados (acurácia de 0,54–0,64) em comparação com N_L = 1 (acurácia ≤ 0,58). O tempo computacional aumentou com EPC mais alto, como em MT (EPC = 120, 1622 segundos) e MT (EPC = 160, 2162 segundos), indicando um trade-off entre precisão e custo computacional. Configurações com menor *dropout* (0,1) e maior número de

épocas tendem a promover maior estabilidade e precisão nos resultados. Esses achados indicam que a otimização dos hiperparâmetros é fundamental para maximizar a eficácia dos modelos *Transformer* na classificação da etiologia, equilibrando desempenho e custo computacional.

Os resultados apresentados na Tabela 48 avaliam o desempenho dos modelos *Transformer* (MT e MCT) na base de dados, utilizando sinais puros de EEG, complementados por características do paciente e estatísticas descritivas.

Tabela 48 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, usando Transformers, com o sinal puro, características do paciente e estatísticas, em negrito se destaca o melhor modelo

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT	8	256	3	0.05	30	0.42±0.12	0.34±0.09	0.39±0.13	0.38±0.10	0.70±0.05	1208
MT CP	8	128	3	0.2	60	0.60±0.21	0.59±0.22	0.65±0.23	0.61±0.24	0.81±0.11	928
MT CP	8	256	3	0.05	30	0.62±0.18	0.59±0.19	0.63±0.22	0.60±0.19	0.81±0.09	691
MCT CP	8	256	3	0.05	30	0.50±0.11	0.47±0.12	0.62±0.13	0.48±0.10	0.74±0.05	1426
MT CE	8	128	3	0.2	60	0.54±0.08	0.51±0.11	0.53±0.18	0.57±0.10	0.77±0.04	1321
MCT CE	8	256	3	0.05	30	0.60±0.13	0.54±0.15	0.55±0.15	0.56±0.13	0.79±0.06	1453
MT CPE	8	128	3	0.2	60	0.50±0.17	0.47±0.18	0.49±0.18	0.51±0.20	0.75±0.08	1323
MCT CPE	8	256	3	0.05	30	0.60±0.17	0.59±0.19	0.64±0.19	0.60±0.19	0.80±0.08	1257

Ao analisar a Tabela 48, observa-se que o modelo MT CP ($N_H = 8$, $INT_D = 256$, $N_L = 3$, $DOUT = 0.05$, $EPC = 30$) apresentou o melhor desempenho, alcançando acurácia de 62% e um F1 score macro de 0,59, evidenciando a eficácia da incorporação das características do paciente na identificação das etiologias. Os modelos MCT CPE e MCT CE também obtiveram resultados expressivos, com acurácia próxima a 0,60, enquanto o modelo MCT isolado apresentou desempenho inferior, com acurácia de 42%. Esses resultados ressaltam a importância da integração de informações clínicas para aprimorar a assertividade dos modelos na classificação da etiologia do coma.

Na Tabela 49, são apresentados os resultados do treinamento da base de dados utilizando os atributos extraídos do EEG: PCP, FM e Coerência. Esses quantificadores avaliam diferentes características do sinal no domínio da frequência,

forneendo informações complementares sobre a atividade cerebral para a classificação da etiologia do coma.

Tabela 49 – Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, usando Transformers, para os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo

Modelo	N _H	INT_D	N _L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MT CPCP	8	128	3	0.2	60	0.60±0.17	0.59±0.16	0.69±0.18	0.63±0.19	0.81±0.08	1503
MCT CPCP	8	256	3	0.05	30	0.42±0.16	0.34±0.12	0.33±0.13	0.37±0.13	0.70±0.08	1708
MCT CPPCP	8	64	3	0.05	30	0.52±0.19	0.43±0.20	0.47±0.25	0.47±0.18	0.75±0.09	1590
MCT CPPCP	8	64	3	0.05	60	0.54±0.17	0.46±0.17	0.49±0.21	0.49±0.15	0.76±0.08	2600
MCT CPPCP	8	128	3	0.05	30	0.52±0.17	0.45±0.16	0.47±0.17	0.47±0.15	0.76±0.08	1556
MT CPPCP	8	128	3	0.2	60	0.56±0.16	0.54±0.16	0.55±0.15	0.58±0.18	0.79±0.08	1523
MCT CPPCP	8	256	3	0.05	30	0.56±0.27	0.51±0.27	0.52±0.26	0.52±0.27	0.78±0.13	1800
MCT CFM	8	64	3	0.05	30	0.38±0.16	0.30±0.13	0.31±0.17	0.35±0.13	0.68±0.08	1557
MT CFM	8	128	3	0.2	60	0.54±0.14	0.51±0.14	0.56±0.22	0.56±0.15	0.77±0.07	1307
MCT CFM	8	256	3	0.05	30	0.42±0.19	0.32±0.16	0.30±0.16	0.37±0.17	0.70±0.10	1711
MT CPFM	8	128	3	0.2	60	0.54±0.17	0.51±0.19	0.53±0.21	0.55±0.20	0.77±0.08	1314
MT CPFM	8	256	3	0.05	30	0.56±0.14	0.51±0.16	0.52±0.21	0.53±0.13	0.77±0.07	938
MCT CPFM	8	256	3	0.05	30	0.50±0.18	0.40±0.14	0.45±0.17	0.44±0.12	0.74±0.08	1668
MT CC	8	128	3	0.2	60	0.48±0.12	0.44±0.11	0.44±0.14	0.49±0.13	0.74±0.06	1152
MCT CC	8	256	3	0.05	30	0.50±0.09	0.45±0.10	0.46±0.13	0.48±0.12	0.75±0.05	1694
MT CPC	8	128	3	0.2	60	0.58±0.12	0.58±0.12	0.65±0.13	0.59±0.11	0.80±0.05	1149
MT CPCP	8	256	3	0.05	30	0.56±0.10	0.50±0.12	0.53±0.17	0.54±0.14	0.78±0.05	947
MCT CPC	8	256	3	0.05	30	0.54±0.10	0.48±0.10	0.51±0.16	0.52±0.13	0.77±0.06	1692

Os resultados da Tabela 49 indicam que os modelos baseados na arquitetura *Transformer* (MT) geralmente superam os modelos híbridos (MCT) quando treinados com os atributos PCP e FM isoladamente ou em combinação, com exceção da Coerência. O modelo MT CPCP ($N_H = 8$, $INT_D = 128$, $N_L = 3$, $DOUT = 0,2$, $EPC = 60$) obteve o melhor desempenho, alcançando uma acurácia média de 60% e especificidade de 0,81. Modelos treinados apenas com o atributo FM exibiram os menores índices de acurácia e F1 score, evidenciando que essa característica isolada pode ser menos discriminativa para a tarefa.

Os resultados apresentados na Tabela 50 avaliam o desempenho utilizando sinais puros de EEG das regiões frontal, central, occipital, parietal e temporal.

Tabela 50 - Resultados do treinamento da base de dados Etiologia do Coma SEM exames pertencentes ao rotulo outros, usando Transformers com Sinal Puro, variando os hiperparâmetros do modelo MT para as regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo

Modelo	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MT CEF	4	64	3	0.1	60	0.52±0.13	0.50±0.14	0.53±0.17	0.55±0.15	0.78±0.08	584
MT CEC	3	64	3	0.1	60	0.36±0.14	0.23±0.10	0.24±0.15	0.31±0.12	0.66±0.07	516
MT CEP	3	64	3	0.1	60	0.44±0.08	0.29±0.09	0.29±0.14	0.37±0.07	0.69±0.04	526
MT CEO	3	64	3	0.1	60	0.36±0.10	0.21±0.09	0.17±0.10	0.30±0.09	0.65±0.05	451
MT CET	4	64	3	0.1	60	0.58±0.08	0.47±0.07	0.50±0.08	0.53±0.04	0.79±0.03	596
MCT CEF	3	128	3	0.2	60	0.56±0.17	0.53±0.15	0.57±0.17	0.55±0.16	0.79±0.09	1991
MT CEF	4	128	3	0.2	60	0.58±0.10	0.57±0.10	0.61±0.12	0.61±0.11	0.80±0.05	474
MT CEF	7	128	3	0.2	60	0.54±0.14	0.51±0.15	0.65±0.21	0.58±0.14	0.79±0.07	510
MCT CEC	3	128	3	0.2	60	0.64±0.16	0.60±0.16	0.67±0.20	0.63±0.16	0.82±0.08	1961
MT CEC	3	128	3	0.2	60	0.40±0.06	0.22±0.08	0.17±0.08	0.33±0.05	0.67±0.03	526
MCT CEP	3	128	3	0.2	60	0.50±0.14	0.48±0.15	0.52±0.19	0.50±0.16	0.75±0.07	1936
MT CEP	3	128	3	0.2	60	0.40±0.06	0.21±0.06	0.20±0.14	0.33±0.05	0.67±0.03	555
MCT CEO	3	128	3	0.2	60	0.48±0.10	0.44±0.08	0.47±0.08	0.44±0.09	0.74±0.05	1932
MT CEO	3	128	3	0.2	60	0.36±0.10	0.20±0.08	0.19±0.15	0.30±0.09	0.65±0.05	571
MCT CET	3	128	3	0.2	60	0.48±0.13	0.43±0.12	0.45±0.14	0.44±0.13	0.74±0.07	1946
MT CET	4	128	3	0.2	60	0.48±0.08	0.42±0.07	0.43±0.09	0.48±0.04	0.74±0.03	568

A análise dos dados da Tabela 50 revela uma variação significativa no desempenho dos modelos *Transformer* (MT) e híbridos (MCT) aplicados às diferentes regiões cerebrais. O modelo MCT CEC ($N_H = 3$, $INT_D = 128$, $N_L = 3$, $DOUT = 0.2$, $EPC = 60$) obteve o melhor desempenho, com acurácia de 0,64 e especificidade de 0,82, indicando melhor capacidade discriminativa nessa região. Modelos aplicados a região frontal (CEF) também mostraram desempenho relativamente elevado, com acurácia entre 52% e 58%, especialmente quando a dimensão intermediária foi aumentada para 128.

APÊNDICE O - Resultados do Treinamento Gosto Musical

Os resultados apresentados a seguir referem-se ao treinamento dos modelos de inteligência artificial voltados para a classificação do gosto musical.

Para o estudo do gosto musical, o procedimento adotado foi análogo ao utilizado para o prognóstico clínico e a etiologia do coma, empregando as mesmas arquiteturas. Conforme detalhado na Tabela 51, os modelos, fundamentados nas arquiteturas descritas no item **5.2 Arquiteturas**, foram treinados utilizando sinais puros de EEG, complementados por características clínicas dos voluntários e estatísticas descritivas.

Tabela 51 - Resultados do treinamento da base de dados Estimulação musical (Favorita e Desgostada) para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MMLP A//	0.53±0.09	0.52±0.09	0.53±0.07	0.67±0.14	0.53±0.09	223
MCL A//	0.43±0.08	0.35±0.07	0.24±0.20	0.23±0.22	0.43±0.08	1413
MMLP CP A//	0.29±0.08	0.28±0.09	0.25±0.13	0.23±0.12	0.29±0.08	143
MCL CP A//	0.35±0.06	0.35±0.06	0.34±0.06	0.33±0.09	0.35±0.06	1565
MMLP CE A//	0.48±0.07	0.46±0.06	0.50±0.12	0.30±0.07	0.48±0.07	136
MCL CE A//	0.41±0.09	0.38±0.07	0.40±0.15	0.23±0.06	0.41±0.09	1589
MMLP CPE A//	0.30±0.03	0.30±0.03	0.28±0.03	0.27±0.06	0.30±0.03	149
MCL CPE A//	0.36±0.06	0.35±0.06	0.34±0.07	0.32±0.12	0.36±0.05	1550

Os resultados da Tabela 51 mostram que o modelo MMLP ALL obteve o melhor desempenho, com F1 score (macro) de 0,52 e especificidade de 53%, indicando maior capacidade de identificar padrões neurais sem características adicionais, esse modelo também se destacou pelo elevado valor de recall (0,67), indicando uma maior sensibilidade na identificação correta das classes. Em comparação, os modelos baseados em MCL apresentaram desempenho inferior, com acurácia variando entre 35% e 43%, sugerindo menor capacidade discriminativa, especialmente quando utilizados em conjunto com atributos específicos (como CP ou CE). O tempo computacional foi significativamente menor para modelos MMLP (média de 163 segundos) em comparação com MCL (média de 1530 segundos), sugerindo maior eficiência do MMLP na classificação.

O treinamento subsequente foi realizado utilizando atributos extraídos do sinal eletroencefalográfico (EEG) por meio do *software* de processamento, especificamente a PCP, FM e Coerência, que caracterizam diferentes aspectos do sinal no domínio da frequência, na qual a Tabela 52 apresenta os resultados obtidos com essa configuração.

Tabela 52 - Resultados do treinamento da base de dados Estimulação musical (Favorita e Desgostada) para o sinal puro, com os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPCP A//	0.32±0.04	0.31±0.04	0.33±0.04	0.37±0.09	0.32±0.04	1529
MCL CPPCP A//	0.24±0.08	0.23±0.08	0.25±0.06	0.27±0.10	0.24±0.08	1497
MCL CFM A//	0.43±0.11	0.43±0.11	0.44±0.10	0.43±0.12	0.43±0.11	1540
MCL CPFM A//	0.30±0.06	0.30±0.06	0.30±0.06	0.30±0.06	0.30±0.06	1772
MCL CC A//	0.41±0.09	0.39±0.10	0.39±0.10	0.41±0.09	0.41±0.09	1754
MCL CPC A//	0.38±0.11	0.37±0.11	0.37±0.11	0.38±0.11	0.38±0.11	1834

Avaliando a Tabela 52 percebe-se que o modelo MCL CFM A// obteve o melhor desempenho, com F1 score (macro) e especificidade de 43%, evidenciando a relevância da frequência mediana para identificar padrões neurais associados a preferências musicais. Enquanto MCL CPPCP A// obteve o menor desempenho (acurácia de 0,24).

Em seguida, realizou-se o treinamento dos modelos utilizando sinais de EEG provenientes das regiões cerebrais frontal, central, occipital, parietal e temporal, conforme detalhado na Tabela 53. Essa abordagem buscou avaliar o impacto da análise regionalizada do sinal EEG na classificação de respostas emocionais a estímulos musicais (favorita vs. desgostada).

Tabela 53 - Resultados do treinamento da base de dados Estimulação musical (Favorita e Desgostada) com características do voluntário e as regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPEF A//	0.37±0.02	0.35±0.03	0.31±0.08	0.28±0.16	0.37±0.02	1478
MCL CPEC A//	0.44±0.03	0.44±0.04	0.44±0.04	0.42±0.08	0.44±0.03	1484
MCL CPEO A//	0.26±0.03	0.25±0.04	0.24±0.06	0.23±0.08	0.26±0.03	1676
MCL CPEP A//	0.30±0.05	0.29±0.05	0.30±0.06	0.32±0.11	0.30±0.05	1919
MCL CPET A//	0.43±0.04	0.42±0.05	0.41±0.08	0.35±0.13	0.43±0.04	1920

Os resultados apresentados na Tabela 53 indicam que o modelo MCL CPEC *All* obteve o melhor desempenho, com F1 score (macro) e especificidade de 44%, o que evidencia a importância da região central na identificação de padrões neurais associados às preferências musicais. O modelo baseado nos eletrodos da região temporal (CPET) apresentou resultados próximos, demonstrando também relevância dessa área para a tarefa. Em contrapartida, o modelo que utilizou sinais da região occipital (CPEO) obteve o menor desempenho, sugerindo menor contribuição dessa região para a discriminação das respostas neurais a estímulos musicais.

APÊNDICE P - Resultados do Treinamento Gosto Musical segregando a base de dados

Nesta etapa, foi realizado o treinamento dos modelos com a base de dados segregada de diferentes formas, com o objetivo de investigar o impacto da divisão dos exames de música gostada e desgostada na performance da classificação. Foram conduzidas quatro segregações:

- **First Half:** utilizando metade dos exames de música favorita e a outra metade de música desgostada de pacientes distintos;
- **Other Half:** utilizando o conjunto complementar não selecionado em *First Half*;
- **Same Half:** empregando apenas metade da base de dados, no qual, os mesmos exames de música favorita e desgostada foram utilizados;
- **All Group:** agrupando exames de música favorita e desgostada do mesmo paciente no mesmo conjunto de treino ou validação.

Essa abordagem foi motivada pela observação do **APÊNDICE O - Resultados do Treinamento Gosto Musical** de que a classificação binária entre gostada e desgostada apresentou desempenho inferior à estratégia mais simples, que consiste na escolha constante de um único resultado, sugerindo limitações na generalização dos modelos. Os resultados detalhados desses experimentos estão apresentados na Tabela 54, Tabela 55 e Tabela 56.

Tabela 54 - Resultados do treinamento segregando a base de dados Estimulação musical (Favorita e Desgostada) para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo com *All Group*

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MMLP <i>All Group</i>	0.63±0.07	0.62±0.08	0.62±0.08	0.65±0.14	0.63±0.08	232
MMLP <i>Same Half</i>	0.67±0.15	0.66±0.15	0.68±0.18	0.63±0.19	0.67±0.15	120
MMLP <i>Other Half</i>	0.77±0.11	0.76±0.11	0.82±0.17	0.73±0.20	0.77±0.11	111
MMLP <i>First Half</i>	0.84±0.11	0.84±0.11	0.83±0.13	0.85±0.15	0.84±0.11	117
MCL <i>All Group</i>	0.58±0.09	0.49±0.14	0.58±0.35	0.52±0.38	0.58±0.09	1829
MCL <i>Same Half</i>	0.47±0.04	0.37±0.04	0.23±0.20	0.10±0.08	0.47±0.04	697

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL <i>Other Half</i>	0.55±0.04	0.43±0.08	0.60±0.49	0.10±0.08	0.55±0.04	882
MCL <i>First Half</i>	0.58±0.15	0.49±0.21	0.37±0.33	0.53±0.44	0.60±0.13	845
MCL CP <i>All Group</i>	0.47±0.03	0.45±0.04	0.47±0.03	0.55±0.15	0.47±0.03	1745
MCL CP <i>Same Half</i>	0.22±0.16	0.19±0.15	0.14±0.20	0.20±0.32	0.22±0.16	959
MCL CP <i>Other Half</i>	0.72±0.09	0.71±0.08	0.75±0.14	0.70±0.19	0.72±0.09	0
MCL CP <i>First Half</i>	0.86±0.16	0.86±0.16	0.84±0.18	0.89±0.16	0.86±0.16	719
MCL CE <i>All Group</i>	0.58±0.05	0.54±0.07	0.65±0.11	0.35±0.19	0.58±0.05	1723
MCL CE <i>Same Half</i>	0.42±0.11	0.41±0.11	0.41±0.12	0.43±0.17	0.42±0.11	985
MCL CE <i>Other Half</i>	0.73±0.19	0.73±0.20	0.74±0.17	0.73±0.25	0.73±0.19	984
MCL CE <i>First Half</i>	0.73±0.20	0.73±0.21	0.72±0.26	0.70±0.27	0.73±0.20	745
MCL CPE <i>All Group</i>	0.52±0.06	0.49±0.05	0.60±0.20	0.53±0.22	0.52±0.06	1746
MCL CPE <i>Same Half</i>	0.30±0.09	0.28±0.07	0.22±0.13	0.20±0.13	0.30±0.09	978
MCL CPE <i>Other Half</i>	0.87±0.09	0.86±0.09	0.94±0.08	0.80±0.19	0.87±0.09	985
MCL CPE <i>First Half</i>	0.84±0.17	0.84±0.17	0.84±0.17	0.85±0.15	0.84±0.17	757

Observando os resultados da Tabela 54 percebe-se variações significativas no desempenho dos modelos em função da estratégia de segregação da base de dados. Fica evidente uma discrepância marcante entre os grupos *Same Half* e *All Group*, em comparação com as versões *Other Half* e *First Half*. Por exemplo, enquanto o modelo MCL CPE *Same Half* apresentou precisão de apenas 22%, a versão *Other Half* alcançou uma precisão de 94%. Esse contraste sugere que a distribuição assimétrica dos dados entre as partições pode introduzir viés de seleção, impactando diretamente a capacidade de generalização dos modelos.

Os resultados apresentados na Tabela 55 evidenciam, mais uma vez, uma divergência significativa entre as estratégias de segregação: as configurações *Same Half* e *All Group* apresentaram métricas inferiores em comparação com *First Half* e

Other Half. Isso sugere que a inclusão de estímulos musicais provenientes do mesmo voluntário no mesmo conjunto de dados compromete a capacidade de generalização do modelo, possivelmente devido a vieses intraindividuais presentes nos padrões neurais. Vale destacar que, ao utilizar características de Coerência, o modelo apresentou um desempenho superior.

Tabela 55 - Resultados do treinamento segregando a base de dados Estimulação musical (Favorita e Desgostada) para o sinal puro, com os atributos PCP, FM e Coerência, em negrito se destaca o melhor modelo *All Group*

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPCP <i>All Group</i>	0.52±0.03	0.51±0.03	0.52±0.03	0.53±0.11	0.52±0.03	1699
MCL CPCP <i>Same Half</i>	0.48±0.08	0.47±0.07	0.48±0.08	0.53±0.19	0.48±0.08	976
MCL CPCP <i>Other Half</i>	0.67±0.20	0.66±0.21	0.71±0.25	0.60±0.27	0.67±0.20	965
MCL CPCP <i>First Half</i>	0.84±0.14	0.84±0.14	0.84±0.16	0.85±0.15	0.84±0.13	708
MCL CPPCP <i>All Group</i>	0.59±0.05	0.59±0.05	0.60±0.06	0.57±0.14	0.59±0.05	1725
MCL CPPCP <i>Same Half</i>	0.37±0.13	0.34±0.12	0.29±0.19	0.33±0.30	0.37±0.13	971
MCL CPPCP <i>Other Half</i>	0.70±0.07	0.70±0.07	0.69±0.07	0.73±0.08	0.70±0.07	963
MCL CPPCP <i>First Half</i>	0.89±0.18	0.89±0.18	0.87±0.19	0.88±0.24	0.89±0.18	728
MCL CFM <i>All Group</i>	0.56±0.09	0.56±0.09	0.56±0.10	0.52±0.10	0.56±0.09	1717
MCL CFM <i>Same Half</i>	0.43±0.08	0.42±0.08	0.43±0.09	0.43±0.08	0.43±0.08	905
MCL CFM <i>Other Half</i>	0.72±0.17	0.70±0.18	0.74±0.17	0.72±0.17	0.72±0.17	911
MCL CFM <i>First Half</i>	0.82±0.13	0.82±0.13	0.84±0.12	0.82±0.12	0.82±0.12	871
MCL CPFM <i>All Group</i>	0.56±0.09	0.56±0.09	0.56±0.09	0.56±0.09	0.56±0.09	1660
MCL CPFM <i>Same Half</i>	0.23±0.12	0.23±0.12	0.23±0.13	0.23±0.12	0.23±0.12	896
MCL CPFM <i>Other Half</i>	0.62±0.13	0.61±0.13	0.62±0.13	0.62±0.13	0.62±0.13	901

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPFM <i>First Half</i>	0.84±0.16	0.84±0.16	0.86±0.16	0.84±0.16	0.84±0.16	838
MCL CC <i>All Group</i>	0.60±0.08	0.60±0.08	0.60±0.08	0.60±0.08	0.60±0.08	1760
MCL CC <i>Same Half</i>	0.42±0.11	0.41±0.11	0.42±0.11	0.42±0.11	0.42±0.11	887
MCL CC <i>Other Half</i>	0.87±0.11	0.86±0.13	0.91±0.07	0.87±0.11	0.87±0.11	908
MCL CC <i>First Half</i>	0.84±0.13	0.84±0.13	0.87±0.11	0.85±0.12	0.85±0.12	887
MCL CPC <i>All Group</i>	0.65±0.11	0.64±0.11	0.66±0.10	0.62±0.19	0.65±0.11	1616
MCL CPC <i>Same Half</i>	0.35±0.11	0.35±0.11	0.35±0.11	0.35±0.11	0.35±0.11	910
MCL CPC <i>Other Half</i>	0.87±0.11	0.86±0.13	0.91±0.07	0.87±0.11	0.87±0.11	906
MCL CPC <i>First Half</i>	0.82±0.19	0.82±0.19	0.84±0.17	0.83±0.18	0.83±0.18	845

A partir dos resultados da Tabela 56, fica ainda mais evidente que as estratégias de segregação *Same Half* e *All Group* apresentam desempenho inferior em comparação com as segregações *First Half* e *Other Half*. Contudo, vale ressaltar que as regiões centrais (CPEC) e temporais (CPET), na configuração *All Group*, se destacaram ao apresentar desempenho superior em relação às demais regiões analisadas.

Tabela 56 - Resultados do treinamento segregando a base de dados Estimulação musical (Favorita e Desgostada) com características do voluntário e as regiões cerebrais: frontal, central, occipital, parietal e temporal, em negrito se destaca o melhor modelo para *All Group*

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPEF <i>All Group</i>	0.50±0.00	0.49±0.01	0.50±0.00	0.43±0.14	0.50±0.00	1714
MCL CPEF <i>Same Half</i>	0.30±0.16	0.28±0.15	0.28±0.19	0.30±0.22	0.30±0.16	957
MCL CPEF <i>Other Half</i>	0.82±0.12	0.82±0.12	0.82±0.14	0.83±0.15	0.82±0.12	906
MCL CPEF <i>First Half</i>	0.89±0.13	0.89±0.14	0.86±0.16	0.96±0.08	0.89±0.13	693
MCL CPEC <i>All Group</i>	0.62±0.03	0.61±0.03	0.62±0.04	0.60±0.10	0.62±0.03	1560

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCL CPEC <i>Same Half</i>	0.40±0.06	0.38±0.05	0.39±0.08	0.33±0.15	0.40±0.06	954
MCL CPEC <i>Other Half</i>	0.75±0.09	0.74±0.10	0.75±0.06	0.73±0.23	0.75±0.09	907
MCL CPEC <i>First Half</i>	0.84±0.20	0.84±0.21	0.85±0.22	0.85±0.15	0.84±0.20	690
MCL CPEO <i>All Group</i>	0.53±0.11	0.52±0.12	0.57±0.11	0.52±0.11	0.53±0.11	1674
MCL CPEO <i>Same Half</i>	0.27±0.10	0.25±0.10	0.16±0.15	0.13±0.13	0.27±0.10	926
MCL CPEO <i>Other Half</i>	0.78±0.09	0.77±0.10	0.93±0.09	0.63±0.19	0.78±0.09	921
MCL CPEO <i>First Half</i>	0.79±0.17	0.79±0.17	0.77±0.20	0.81±0.24	0.79±0.17	885
MCL CPET <i>All Group</i>	0.62±0.06	0.60±0.06	0.68±0.09	0.48±0.13	0.62±0.06	1732
MCL CPET <i>Same Half</i>	0.45±0.13	0.44±0.13	0.45±0.17	0.40±0.13	0.45±0.13	933
MCL CPET <i>Other Half</i>	0.67±0.05	0.66±0.06	0.67±0.03	0.67±0.18	0.67±0.05	927
MCL CPET <i>First Half</i>	0.79±0.17	0.78±0.17	0.76±0.20	0.81±0.22	0.79±0.17	862
MCL CPEP <i>All Group</i>	0.57±0.06	0.56±0.05	0.58±0.08	0.58±0.12	0.57±0.06	1750
MCL CPEP <i>Same Half</i>	0.33±0.08	0.33±0.08	0.30±0.10	0.27±0.13	0.33±0.08	923
MCL CPEP <i>Other Half</i>	0.75±0.12	0.74±0.12	0.77±0.15	0.77±0.23	0.75±0.12	922
MCL CPEP <i>First Half</i>	0.82±0.11	0.82±0.12	0.83±0.11	0.78±0.23	0.82±0.12	858

Buscando aprimorar os resultados da classificação de respostas emocionais a estímulos musicais (favorita vs. desgostada), realizou-se alterações nas arquiteturas de inteligência artificial, incluindo o uso de *TransformerEncoder*, *Common Spatial Patterns* (CSP) e a aplicação do *Multi-Layer Perceptron* (MLP) restrito a bandas de frequência específicas do sinal EEG. Essas modificações visam explorar diferentes aspectos do sinal de EEG para melhorar a capacidade discriminativa dos modelos na classificação das respostas a estímulos musicais. Os resultados obtidos com essas novas arquiteturas são apresentados na Tabela 57.

Tabela 57 - Resultados do treinamento segregando a base de dados Estimulação musical (Favorita e Desgostada) com outras arquiteturas, em negrito se destaca o melhor modelo para *All Group*

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCLT CE <i>All Group</i>	0.55±0.10	0.50±0.14	0.50±0.18	0.55±0.10	0.55±0.10	533
MCL CCSP4 <i>All Group</i>	0.49±0.02	0.36±0.05	0.29±0.08	0.49±0.02	0.49±0.02	1465
MCL CCSP4 <i>Same Half</i>	0.38±0.13	0.31±0.10	0.33±0.22	0.38±0.13	0.38±0.13	989
MCL CCSP4 <i>Other Half</i>	0.85±0.11	0.84±0.13	0.89±0.07	0.85±0.11	0.85±0.11	891
MCL CCSP4 <i>First Half</i>	0.81±0.20	0.81±0.20	0.82±0.20	0.81±0.20	0.81±0.20	849
MCL CCSP10 <i>All Group</i>	0.52±0.07	0.47±0.10	0.46±0.13	0.52±0.07	0.52±0.07	1704
MCL CCSP10 <i>Same Half</i>	0.43±0.23	0.37±0.23	0.35±0.26	0.43±0.23	0.43±0.23	809
MCL CCSP10 <i>Other Half</i>	0.87±0.14	0.86±0.14	0.89±0.13	0.87±0.14	0.87±0.14	904
MCL CCSP10 <i>First Half</i>	0.84±0.13	0.84±0.13	0.85±0.13	0.84±0.13	0.84±0.13	850
MCL CCSP20 <i>All Group</i>	0.55±0.07	0.47±0.13	0.50±0.14	0.55±0.07	0.55±0.07	1851
MCL CCSP20 <i>Same Half</i>	0.37±0.20	0.35±0.20	0.35±0.22	0.37±0.20	0.37±0.20	747
MCL CCSP20 <i>Other Half</i>	0.85±0.10	0.85±0.10	0.86±0.10	0.85±0.10	0.85±0.10	896
MCL CCSP20 <i>First Half</i>	0.88±0.14	0.87±0.14	0.89±0.13	0.88±0.13	0.88±0.13	861
MMLP CPCP <i>All Group</i>	0.49±0.08	0.49±0.08	0.49±0.08	0.52±0.10	0.49±0.08	808
MMLP CPCP Alfa <i>All Group</i>	0.50±0.05	0.50±0.05	0.50±0.06	0.47±0.09	0.50±0.05	380
MMLP CPCP Beta <i>All Group</i>	0.50±0.10	0.48±0.09	0.47±0.10	0.53±0.30	0.50±0.10	148
MMLP CPCP Gama <i>All Group</i>	0.53±0.06	0.52±0.05	0.52±0.04	0.63±0.15	0.53±0.06	138
MMLP CPCP Super Gama <i>All Group</i>	0.55±0.07	0.54±0.07	0.54±0.05	0.67±0.14	0.55±0.07	148
MMLP CPCP Teta <i>All Group</i>	0.54±0.03	0.54±0.03	0.54±0.02	0.60±0.06	0.54±0.03	135
MMLP CPCP Delta <i>All Group</i>	0.52±0.08	0.52±0.08	0.51±0.07	0.55±0.11	0.52±0.08	134
MMLP CPCP Delta Teta Super Gama <i>All Group</i>	0.55±0.07	0.54±0.07	0.55±0.06	0.65±0.12	0.55±0.07	136
MCL CPC <i>All Group</i> Aumento do Dropout para 0.5 nas camadas que usam 0.2 (kernel_regularizer=regularizers.l2(1e-4))	0.68±0.09	0.67±0.09	0.67±0.08	0.70±0.16	0.68±0.09	1577
MCT CPC <i>All Group</i> usando 30 segmentos ao invés de 10	0.60±0.03	0.59±0.04	0.61±0.03	0.60±0.03	0.60±0.03	4914

Modelo	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Tempo (seg.)
MCT CPC <i>All Group</i> usando 30 segmentos ao invés de 10	0.58±0.05	0.57±0.05	0.59±0.04	0.58±0.05	0.58±0.05	7348
MCL CPC <i>All Group</i> usando 30 segmentos ao invés de 10	0.63±0.04	0.63±0.04	0.64±0.04	0.63±0.04	0.63±0.04	6236
MCL CE T3 T4 Pz O2 Oz <i>All Group</i>	0.64±0.11	0.63±0.12	0.67±0.11	0.57±0.19	0.64±0.11	1663
MCL CP T3 T4 Pz O2 Oz <i>All Group</i>	0.60±0.07	0.60±0.07	0.60±0.09	0.62±0.13	0.60±0.07	1502
MCL CPE T3 T4 Pz O2 Oz <i>All Group</i>	0.63±0.074	0.62±0.04	0.65±0.06	0.57±0.14	0.63±0.04	1632

Os resultados apresentados na Tabela 57 evidenciam que as versões dos modelos com maior número de filtros CSP tendem a apresentar métricas superiores, refletindo uma melhor extração das características espaciais relevantes do sinal EEG. Embora os modelos baseados em MMLP tenham exibido desempenho mais modesto, eles mostraram resultados consistentes ao longo de diferentes bandas de frequência, com acurácias na faixa de 50% a 55%, sugerindo que a segmentação espectral oferece informações complementares, porém insuficientes quando utilizadas isoladamente para a tarefa.

Além disso, observou-se que o ajuste de hiperparâmetros, como o aumento do *dropout* e alteração do *kernel_regularizer* no modelo MCL CPC *All Group*, promoveu uma melhora significativa no desempenho, alcançando acurácia de 68%, o que indica que estratégias de regularização são interessantes para evitar *overfitting* e aprimorar a capacidade de generalização dos modelos. Vale destacar ainda que a utilização exclusiva dos eletrodos com maior relevância para a distinção entre música favorita e desgostada, conforme identificado na seção **4.6.2.3 Análise detalhada quando diferentes estímulos musicais são comparados**, resultou em uma melhora significativa na performance do modelo, reforçando a importância da seleção criteriosa dos eletrodos para otimizar a classificação.

APÊNDICE Q - Resultados do Treinamento Gosto Musical usando *Tranformer*

Com o objetivo de aprimorar o desempenho dos modelos, foram realizados experimentos ajustando os hiperparâmetros das arquiteturas baseadas em *transformers*. Essa etapa buscou identificar configurações que potencializassem a capacidade de discriminação dos modelos na classificação das respostas neurais a estímulos musicais. Os resultados obtidos a partir dessas variações encontram-se detalhados na Tabela 58. Esta análise foi realizada apenas com a segregação *Same Half*, pois é a configuração com menor desempenho.

Tabela 58 - Resultados do treinamento da base de dados Estimulação musical (Favorita e Desgostada) usando arquitetura com *transformer*, para o sinal puro, com características do paciente e estatísticas, em negrito se destaca o melhor modelo

Mod.	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
MCT CP <i>Same Half</i>	4	256	1	0.1	30	0.38±0.15	0.35±0.14	0.38±0.15	0.40±0.29	0.38±0.15	730
idem	4	128	1	0.1	30	0.30±0.14	0.29±0.13	0.30±0.12	0.27±0.08	0.30±0.14	727
idem	4	64	1	0.1	30	0.32±0.13	0.27±0.10	0.22±0.13	0.20±0.13	0.32±0.13	735
idem	4	32	1	0.1	30	0.40±0.16	0.37±0.16	0.34±0.25	0.30±0.19	0.40±0.16	707
idem	4	32	1	0.2	30	0.35±0.13	0.32±0.13	0.25±0.22	0.13±0.13	0.35±0.13	682
idem	4	32	1	0.3	30	0.32±0.10	0.29±0.09	0.23±0.13	0.17±0.11	0.32±0.10	718
idem	6	256	1	0.1	30	0.33±0.11	0.30±0.09	0.25±0.17	0.17±0.11	0.33±0.11	807
idem	6	128	1	0.1	30	0.33±0.05	0.31±0.07	0.26±0.14	0.23±0.17	0.33±0.05	798
idem	6	128	1	0.2	30	0.27±0.12	0.24±0.11	0.16±0.15	0.13±0.13	0.27±0.12	762
idem	6	128	1	0.3	30	0.37±0.10	0.34±0.11	0.29±0.18	0.23±0.17	0.37±0.10	777
idem	6	64	1	0.1	30	0.27±0.11	0.24±0.11	0.15±0.15	0.13±0.13	0.27±0.11	791
idem	6	32	1	0.1	30	0.32±0.14	0.29±0.13	0.27±0.17	0.17±0.11	0.32±0.14	792
idem	8	256	1	0.1	30	0.33±0.14	0.31±0.15	0.28±0.19	0.27±0.17	0.33±0.14	879
idem	8	128	1	0.1	30	0.28±0.04	0.27±0.05	0.26±0.13	0.30±0.16	0.28±0.04	868
idem	8	64	1	0.1	30	0.32±0.10	0.27±0.09	0.14±0.18	0.13±0.19	0.32±0.10	843
idem	8	64	1	0.2	30	0.35±0.19	0.33±0.20	0.26±0.24	0.27±0.31	0.35±0.19	860
idem	8	64	1	0.3	30	0.42±0.14	0.41±0.14	0.43±0.16	0.37±0.07	0.42±0.14	846
idem	8	32	1	0.1	30	0.35±0.11	0.33±0.12	0.30±0.17	0.33±0.21	0.35±0.11	847
idem	4	256	1	0.1	30	0.38±0.15	0.35±0.14	0.38±0.15	0.40±0.29	0.38±0.15	730
idem	4	128	1	0.1	30	0.30±0.14	0.29±0.13	0.30±0.12	0.27±0.08	0.30±0.14	727
idem	4	64	1	0.1	30	0.32±0.13	0.27±0.10	0.22±0.13	0.20±0.13	0.32±0.13	735
idem	4	32	1	0.1	30	0.40±0.16	0.37±0.16	0.34±0.25	0.30±0.19	0.40±0.16	707

Mod.	N_H	INT_D	N_L	DOUT	EPC	Acurácia	F1 score (macro)	Precisão	Recall	Espec.	Temp o (seg.)
idem	4	32	1	0.2	30	0.35±0.13	0.32±0.13	0.25±0.22	0.13±0.13	0.35±0.13	682

A análise dos resultados apresentados na Tabela 58 destaca um desempenho relativamente modesto dos modelos avaliados, com acurácia e F1 score (macro) variando na faixa de aproximadamente 24% a 42%, refletindo o desafio inerente da tarefa. Observa-se que o modelo com a melhor performance, identificado como MCT CP *Same Half* com $N_H = 8$, $INT_D = 64$, $N_L = 1$ e $DOUT = 0.3$ atingiu um F1 score de 41% e acurácia de 42%. Note-se que a variação nos hiperparâmetros, como o número de cabeças de atenção (N_H) e dimensão da camada intermediária do *TransformerEncoder* (INT_D) e taxa de *dropout* ($DOUT$), apresenta impacto claro nos resultados, indicando a sensibilidade desse modelo a tais ajustes. Além disso, o tempo de treinamento, apesar de relativamente estável na faixa de 682 a 879 segundos, não parece correlacionar diretamente com a melhora do desempenho, sugerindo que otimizações no ajuste dos hiperparâmetros podem ser mais efetivas para ganhos preditivos do que o simples aumento do tempo computacional. Estes resultados apontam para a necessidade de abordagens mais robustas e potencialmente novas arquiteturas para melhorar a classificação nesta base de dados complexa.

ANEXO A - Parecer Comitê de Ética 369/11 base de dados pacientes em coma



Universidade Federal de Uberlândia
Pró-Reitoria de Pesquisa e Pós-Graduação
COMITÊ DE ÉTICA EM PESQUISA - CEP
Av. João Naves de Ávila, nº 2121 - Bloco A - sala 224 - Campus Santa Mônica - Uberlândia-MG -
CEP 38408-144 - FONE/FAX (34) 3239-4131

ANÁLISE FINAL Nº. 014/12 DO COMITÊ DE ÉTICA EM PESQUISA PARA O PROTOCOLO REGISTRO CEP/UFU
369/11

Projeto Pesquisa: "Aplicações clínicas do EEG quantitativo para o estudo de indivíduos normais, pacientes com déficit de aprendizagem e pacientes em estado de coma".

Pesquisador Responsável: João Batista Destro Filho

De acordo com as atribuições definidas na Resolução CNS 196/96, o CEP manifesta-se pela aprovação do protocolo de pesquisa proposto.
O protocolo não apresenta problemas de ética nas condutas de pesquisa com seres humanos, nos limites da redação e da metodologia apresentadas.

O CEP/UFU lembra que:

- a- segundo a Resolução 196/96, o pesquisador deverá arquivar por 5 anos o relatório da pesquisa e os Termos de Consentimento Livre e Esclarecido, assinados pelo sujeito de pesquisa.
- b- poderá, por escolha aleatória, visitar o pesquisador para conferência do relatório e documentação pertinente ao projeto.
- c- a aprovação do protocolo de pesquisa pelo CEP/UFU dá-se em decorrência do atendimento a Resolução 196/96/CNS, não implicando na qualidade científica do mesmo.

Data de entrega do 1º Relatório Parcial: **fevereiro de 2013**

Data de entrega do 2º Relatório Parcial: **fevereiro de 2014**

Data de entrega do Relatório Final: **fevereiro de 2015**

SITUAÇÃO: PROTOCOLO APROVADO


OBS.: O CEP/UFU LEMBRA QUE QUALQUER MUDANÇA NO PROTOCOLO DEVE SER INFORMADA IMEDIATAMENTE AO CEP PARA FINS DE ANÁLISE E APROVAÇÃO DA MESMA.

Uberlândia, 02 de fevereiro de 2012.

Profa. Dra. Sandra Terezinha de Farias Furtado
Coordenadora do CEP/UFU

ANEXO B - Parecer Comitê de Ética 2.570.022 base de dados pacientes em coma

Abaixo é mostrado a primeira e a última página do parecer consubstanciado.



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Estudo do efeito da estimulação musical baseada em eletroencefalografia (EEG)

Pesquisador: João Batista Destro Filho

Área Temática:

Versão: 1

CAAE: 82824017.5.0000.5152

Instituição Proponente: Faculdade de Engenharia Elétrica

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER


Número do Parecer: 2.570.022

Apresentação do Projeto:

O protocolo de pesquisa intitulado "Estudo do efeito da estimulação musical baseada em eletroencefalografia (EEG)" pretende estudar prospectivamente os efeitos de estimulação musical em pacientes da Unidade de Terapia Intensiva Adulta (UTIA) do Hospital de Clínicas de Uberlândia, sem perturbar a rotina de tratamento dos mesmos, investigando a influência de tais estimulações através do EEG previsto no protocolo de tratamento, e através dos parâmetros de monitoramento contínuo (em termos de pressões arteriais e frequências cardíacas). O grupo de estudo receberá estimulação musical prolongada, ou seja, durante três dias consecutivos logo após a realização do EEG de rotina. Já o grupo controle não receberá estas estimulações. O Eletroencefalograma (EEG) mede a atividade elétrica do cérebro em diferentes locais do córtex cerebral, geralmente usando eletrodos colocados no couro cabeludo. Suas principais vantagens sobre as outras técnicas de gravação são a alta resolução temporal e o fato de que pode ser gravado de forma não-invasiva. Devido ao baixo custo, as gravações de EEG são amplamente utilizados tanto em ambientes clínicos quanto em pesquisas. Isso faz com que esse exame seja uma ferramenta muito acessível e útil, que é particularmente interessante para a análise dos processos cerebrais de alto nível. No contexto das Unidades de Terapia Intensiva (UTI), observa-se que existe uma tendência internacional em utilizar registros de EEG para monitorização contínua de pacientes neurologicamente críticos. Particularmente, no contexto de pacientes em coma, o EEG revelou recentemente resultados significativos, com impacto clínico

Endereço: Av. João Naves de Ávila 2121- Bloco "1A", sala 224 - Campus Sta. Mônica
Bairro: Santa Mônica **CEP:** 38.408-144
UF: MG **Município:** UBERLÂNDIA
Telefone: (34)3239-4131 **Fax:** (34)3239-4335 **E-mail:** cep@propp.ufu.br

Página 01 de 07



Continuação do Parecer: 2.570.022

Outros	RAMETROS.pdf	16:27:08	Camila Davi Ramos	Aceito
Outros	ANEXO2_DADOS_MUSICOTERAPICO S.pdf	03/02/2018 16:26:31	Camila Davi Ramos	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_CORRIGIDO.pdf	03/02/2018 16:23:40	Camila Davi Ramos	Aceito
Projeto Detalhado / Brochura	PROJETO_V_SUBMISSAO_CORRIGIDO.pdf	03/02/2018 16:22:47	Camila Davi Ramos	Aceito
Investigador	termo_compromisso_fev_2018.pdf	03/02/2018 16:21:45	Camila Davi Ramos	Aceito
Declaração de Pesquisadores	link_jattes.docx	29/01/2018 13:33:03	Camila Davi Ramos	Aceito
Outros	Ints_COPARTICIPANTE_2.jpeg	10/10/2017 08:46:45	Camila Davi Ramos	Aceito
Declaração de Instituição e Infraestrutura	Inst_COPARTICIPANTE.jpeg	10/10/2017 08:45:35	Camila Davi Ramos	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

UBERLÂNDIA, 28 de Março de 2018

Assinado por:







Sandra Terezinha de Farias Furtado
 (Coordenador)

Endereço: Av. João Naves de Ávila 2121- Bloco "1A", sala 224 - Campus Sta. Mônica
Bairro: Santa Mônica **CEP:** 38.408-144
UF: MG **Município:** UBERLÂNDIA
Telefone: (34)3239-4131 **Fax:** (34)3239-4335 **E-mail:** cep@propp.ufu.br

Página 07 de 07

ANEXO C - Parecer Comitê de Ética 1.715.960 base de dados estimulação musical

Abaixo é mostrado a primeira e a última página do parecer consubstanciado.

<div data-bbox="268 593 774 660">  <div> UNIVERSIDADE FEDERAL DE UBERLÂNDIA/MG <small>Comitê de Ética em Pesquisa</small> </div>  </div> <div data-bbox="395 669 647 687" style="background-color: #cccccc; text-align: center;"> PARER CONSUBSTANCIADO DO CEP </div> <div data-bbox="263 698 453 714"> DADOS DO PROJETO DE PESQUISA </div> <div data-bbox="263 723 777 752"> Título da Pesquisa: Caracterização do ruído associado à eletroencefalografia (EEG) realizado em Unidade de Terapia Intensiva (UTI) </div> <div data-bbox="263 752 458 768"> Pesquisador: João Batista Destro Filho </div> <div data-bbox="263 768 343 784"> Área Temática: </div> <div data-bbox="263 784 322 799"> Versão: 2 </div> <div data-bbox="263 799 413 815"> CAAE: 54781615.6.0000.5152 </div> <div data-bbox="263 815 545 833"> Instituição Proponente: Faculdade de Engenharia Elétrica </div> <div data-bbox="263 833 496 851"> Patrocinador Principal: Financiamento Próprio </div> <div data-bbox="263 864 378 880"> DADOS DO PARECER </div> <div data-bbox="263 891 419 909"> Número do Parecer: 1.715.960 </div> <div data-bbox="263 940 395 956"> Apresentação do Projeto: </div> <div data-bbox="260 956 778 1216"> <p>Conforme apresenta o protocolo: Este projeto visa investigar as características estatísticas do ruído artificial que perturba o exame em eletroencefalografia (EEG) no intuito de definir um padrão de ruído no ambiente de UTI Adulto do Hospital de Clínicas da Universidade Federal de Uberlândia (HCU-UFU) e elaborar um banco de dados EEG normal, considerando explicitamente a técnica de Oscilações de Alta Frequência (OAF) na faixa 0 – 120 Hz. A eletroencefalografia (EEG) consiste num exame bastante coerente com a realidade SUS, devido ao fato de ser não-invasivo, barato, simples e sem contra-indicações para qualquer tipo de paciente. Embora este exame permite o monitoramento em tempo real do estado neurológico do paciente, todavia não consegue apresentar uma boa resolução espacial e também é fortemente perturbado por ruído. Os pesquisadores justificam a proposta argumentando que a falta de estudos orientados a utilização de EEG em alta frequência e, a escassez de monitorização contínua em ambientes da UTI no Brasil. A realização deste projeto deve melhorar a qualidade dos diagnósticos de morte encefálica e fundamentar o alicerce para o desenvolvimento de um sistema de monitoramento EEG contínuo, assim como, evitar o deslocamento arriscado de um paciente neurologicamente crítico da UTI/HCU para o ambiente sem ruído SEM/HCU. Para realizar a pesquisa, os próprios membros da equipe executora, assim como, como 100 indivíduos voluntários, saudáveis entre 18 – 60 anos,</p> </div> <div data-bbox="263 1276 774 1386"> <div> Endereço: Av. João Naves de Ávila 2121-Bloco "1A", sala 224 - Campus Sta. Mônica Bairro: Santa Mônica UF, MG: Município: UBERLÂNDIA Telefone: (34)3239-4131 Fax: (34)3239-4535 E-mail: cep@ufu.br </div> <div>  UNIVERSIDADE FEDERAL DE UBERLÂNDIA Comitê de Ética em Pesquisa Prof.ª Dr.ª Sandra Ferreira de Fátima Furtado Coordenadora </div> <div>Página 01 de 06</div> </div>	<div data-bbox="880 593 1386 660">  <div> UNIVERSIDADE FEDERAL DE UBERLÂNDIA/MG <small>Comitê de Ética em Pesquisa</small> </div>  </div> <div data-bbox="871 658 1003 672"> <small>Continuação do Parecer: 1.715.960</small> </div> <div data-bbox="868 689 1385 725"> <p>por uma letra do alfabeto, seguida por um número de coleta. Apenas os alguns membros da equipe terão acesso à correspondência entre as siglas e identificação do indivíduo.</p> </div> <div data-bbox="868 723 1385 826"> <p>- Risco de Choque Elétrico: Para que esse incidente não aconteça será utilizado na pesquisa um equipamento de EEG registrado na ANVISA (cujo número de registro é 80694810001), que por ser aprovado nesse órgão, contém todas as proteções contra choques. - O gel condutor utilizado para coleta não causa danos à saúde. Porém, se o paciente apresentar alergia a alguma substância do composto, poderá ter leve irritação, que pode ser sanada limpando o couro cabeludo. Dependendo da possibilidade de irritação da epiderme, se necessário, o exame será cancelado.</p> </div> <div data-bbox="868 842 927 857"> Benefícios: </div> <div data-bbox="868 857 1385 947"> <p>Por se tratar de um projeto inovador tem como benefício primordial a criação de um banco de dados de EEG de alta frequência para que possa ser utilizado para pesquisas futuras relacionadas à EEG. Além disso é uma pesquisa que visa traçar um comportamento do ruído na UTIA do HCU-UFU e desse modo ser elemento para criação de filtros capazes de minimizar esses ruídos e dessa maneira permitir uma monitorização contínua em ambiente de UTI.</p> </div> <div data-bbox="868 967 1118 985"> Comentários e Considerações sobre a Pesquisa: </div> <div data-bbox="868 981 1383 1019"> <p>Pesquisa de relevância social: objetivos bem definidos; A metodologia parece suficiente para atingir os objetivos propostos.</p> </div> <div data-bbox="868 1021 1185 1039"> Considerações sobre os Termos de apresentação obrigatórios: </div> <div data-bbox="868 1037 1278 1057"> <p>Todos os termos de apresentação obrigatória foram encontrados na Plataforma Brasil.</p> </div> <div data-bbox="868 1059 962 1075"> Recomendações: </div> <div data-bbox="868 1072 911 1090"> <p>Não há.</p> </div> <div data-bbox="868 1095 1139 1113"> Conclusões ou Pendências e Lista de Inadequações: </div> <div data-bbox="868 1111 1383 1146"> <p>As pendências apontadas no parecer consubstanciado número 1.559.906, de 20 de Maio de 2016, foram atendidas.</p> </div> <div data-bbox="868 1180 1383 1216"> <p>De acordo com as atribuições definidas na Resolução CNS 466/12, o CEP manifesta-se pela aprovação do protocolo de pesquisa proposto.</p> </div> <div data-bbox="868 1214 1383 1249"> <p>O protocolo não apresenta problemas de ética nas condutas de pesquisa com seres humanos, nos limites da redação e da metodologia apresentadas.</p> </div> <div data-bbox="868 1272 1386 1386"> <div> Endereço: Av. João Naves de Ávila 2121-Bloco "1A", sala 224 - Campus Sta. Mônica Bairro: Santa Mônica UF, MG: Município: UBERLÂNDIA Telefone: (34)3239-4131 Fax: (34)3239-4535 E-mail: cep@ufu.br </div> <div>  UNIVERSIDADE FEDERAL DE UBERLÂNDIA Comitê de Ética em Pesquisa Prof.ª Dr.ª Sandra Ferreira de Fátima Furtado Coordenadora </div> <div>Página 02 de 06</div> </div>
--	--