

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA**  
**CURSO DE GRADUAÇÃO EM ENGENHARIA BIOMÉDICA**

**MARIA EDUARDA SERAFIM DE SOUZA**

**COMPARAÇÃO E VALIDAÇÃO DE  
PLATAFORMAS (MATLAB VS. PYTHON):  
ANÁLISE DE SINAIS EEG EM PACIENTES  
COMATOSOS SOB ESTIMULAÇÃO MUSICAL**

**UBERLÂNDIA – MG**  
**2025**

**MARIA EDUARDA SERAFIM DE SOUZA**

**COMPARAÇÃO E VALIDAÇÃO DE  
PLATAFORMAS (MATLAB VS. PYTHON):  
ANÁLISE DE SINAIS EEG EM PACIENTES  
COMATOSOS SOB ESTIMULAÇÃO MUSICAL**

**Trabalho de Conclusão de Curso**  
apresentado à Universidade Federal  
de Uberlândia como requisito parcial  
para obtenção do diploma de  
graduação do curso de Engenharia  
Biomédica.

Orientador: Prof. Dr. João Batista  
Destro Filho

**UBERLÂNDIA – MG**

**2025**

**MARIA EDUARDA SERAFIM DE SOUZA**

**COMPARAÇÃO E VALIDAÇÃO DE  
PLATAFORMAS (MATLAB VS. PYTHON):  
ANÁLISE DE SINAIS EEG EM PACIENTES  
COMATOSOS SOB ESTIMULAÇÃO MUSICAL**

**Trabalho de Conclusão de Curso**  
apresentado à Universidade Federal  
de Uberlândia como requisito parcial  
para obtenção do diploma de  
graduação do curso de Engenharia  
Biomédica.

Área de concentração:

Remoto, 20 de agosto de 2025

Banca Examinadora:

---

Dr. João Batista Destro Filho  
Universidade Federal de Uberlândia - UFU

---

Msc. João Ludovico Maximiano Barbosa  
Universidade Federal de Uberlândia – UFU

---

Dr. Murillo Guimarães Carneiro  
Universidade Federal de Uberlândia - UFU

Dedico este trabalho ao meu orientador, aos meus colegas do grupo de pesquisa, a Deus e à minha família, por todos os aprendizados, estímulo, carinho e compreensão durante essa trajetória.

"A música é o vínculo que une a  
vida do espírito à vida dos sentidos."

— *Ludwig van Beethoven*

## **AGRADECIMENTOS**

A realização deste Trabalho de Conclusão de Curso (TCC) é o ponto final de uma jornada repleta de desafios, aprendizados e crescimento. Gostaria de expressar minha profunda gratidão a todos que, de diferentes formas, contribuíram para que ele se tornasse realidade.

Primeiramente, meu mais sincero agradecimento ao meu orientador, João Batista Destro Filho, pela sua orientação precisa, paciência e incentivo constante. Sua dedicação a mim durante essa trajetória foi fundamental para o desenvolvimento deste trabalho e para meu crescimento acadêmico.

Estendo meus agradecimentos ao doutorando João Ludovico Maximiano Barbosa, cujo conhecimento e generosidade em compartilhar suas experiências foram essenciais para a concretização deste projeto. Suas contribuições enriqueceram cada etapa da minha pesquisa.

Aos colegas do grupo de pesquisa, meu muito obrigado por todo o apoio na coleta de dados, pelas discussões enriquecedoras e pela colaboração. Este trabalho foi, sem dúvida, um esforço conjunto.

Por fim, agradeço a Deus e à minha família por todo o carinho, compreensão e apoio incondicional. Sem o suporte de vocês, os desafios teriam sido muito maiores.

A todos, dedico este trabalho com imensa gratidão.

## RESUMO

Este trabalho investiga a eficácia e a confiabilidade do Python como ferramenta para o processamento de sinais de eletroencefalograma (EEG) em comparação com o MATLAB, que é tradicionalmente utilizado. O estudo focou na análise de EEG de pacientes em estado de coma submetidos à estimulação musical (Sonata K144 de Mozart) e períodos de silêncio, utilizando os quantificadores de Porcentagem de Contribuição de Potência (PCP), Frequência Mediana (FM) e Coerência. Os resultados demonstraram uma notável consistência entre as duas plataformas para os quantificadores FM e PCP, com erros relativos pequenos (na ordem de  $10^{-13}$  a  $10^{-15}$ ), validando o Python como uma ferramenta robusta e numericamente equivalente ao MATLAB para esses tipos de análise.

Além disso, o presente trabalho discute a predominância do maior erro relativo de cada exame analisado na banda de frequência "supergama" em ambos os momentos (silêncio e Mozart) tanto para FM quanto PCP e traz uma discussão sobre o quantificador 'Coerência'. O trabalho destaca a flexibilidade e o custo-benefício do Python como uma alternativa acessível, promovendo a transparência e reproduzibilidade na pesquisa em neurociência e neuroengenharia. Além disso, a pesquisa contribui para a compreensão da reatividade cerebral de pacientes comatosos à música, abrindo caminhos para futuras aplicações terapêuticas e diagnósticas.

**Palavras-chave:** EEG, Processamento de Sinais, Coma, Estimulação Musical, Python, MATLAB.

# ABSTRACT

This work investigates the effectiveness and reliability of Python as a tool for processing electroencephalogram (EEG) signals compared to MATLAB, which is traditionally used. The study focused on the analysis of EEG from comatose patients submitted to musical stimulation (Mozart's Sonata K144) and periods of silence, using the Percentage of Power Contribution (PCP), Median Frequency (FM), and Coherence quantifiers. The results demonstrated remarkable consistency between the two platforms for the FM and PCP quantifiers, with small relative errors (on the order of  $10^{-13}$  to  $10^{-15}$ ), validating Python as a robust and numerically equivalent tool to MATLAB for these types of analysis.

Furthermore, this paper discusses the predominance of the largest relative error of each exam analyzed in the "supergamma" frequency band at both time points (silence and Mozart) for both FM and PCP, and discusses the "Coherence" quantifier. The paper highlights the flexibility and cost-effectiveness of Python as an accessible alternative, promoting transparency and reproducibility in neuroscience and neuroengineering research. Furthermore, the research contributes to the understanding of the brain reactivity of comatose patients to music, paving the way for future therapeutic and diagnostic applications.

**Keywords:** EEG, Signal Processing, Coma, Musical Stimulation, Python, MATLAB

# **LISTA DE ILUSTRAÇÕES**

Figura 1 - Diagrama de sequência da coleta, processamento e análise estatística.....	35
Figura 2 - Gráficos com valores de Coerência de 0 a 129 Hz para as épocas de 1 a 4 no momento 'silêncio'.....	52
Figura 3 - Gráficos com valores de Coerência de 0 a 10 Hz para as épocas de 1 a 4 no momento 'silêncio'.....	53
Figura 4 - Épocas de 1 a 4 da Coerência de 0 a 4 Hz.....	54
Figura 5 - Épocas de 5 a 8 da Coerência de 0 a 4 Hz.....	55
Figura 6 - Épocas 9 e 10 da Coerência de 0 a 4 Hz.....	56
Figura 7 - Mapeamento topográfico da média de PCP para o momento 'silêncio'.....	58
Figura 8 - Mapeamento topográfico da média de FM para o momento 'silêncio' .....	59
Figura 9 - Mapeamento topográfico da média de PCP para o momento 'Mozart'.....	61
Figura 10 - Mapeamento topográfico da média de FM para o momento 'Mozart' .....	63
Figura 11 - Equivalência de precisão de MATLAB x Python .....	66

## **LISTA DE TABELAS**

Tabela 1 - Identificação e descrição das variáveis de entrada das funções desenvolvidas e seu respectivo ANEXO .....	42
Tabela 2 - Identificação e descrição das variáveis de saída das funções desenvolvidas e seu respectivo ANEXO .....	43
Tabela 3 - Resultados dos maiores erros relativos e suas respectivas posições para o quantificador PCP no momento 'silêncio' .....	46
Tabela 4 - Resultados dos maiores erros relativos e suas respectivas posições para o quantificador PCP no momento 'Mozart' .....	47
Tabela 5 - Resultados dos maiores erros relativos e suas respectivas posições para o quantificador FM no momento 'silêncio'.....	48
Tabela 6 - Resultados dos maiores erros relativos e suas respectivas posições para o quantificador FM no momento 'Mozart'.....	50
Tabela 7 - Média de PCP por época e eletrodo para o momento 'silêncio'.....	57
Tabela 8 - Média de FM por época e eletrodo para o momento 'silêncio'.....	58
Tabela 9 - Média de PCP por época e eletrodo para o momento 'Mozart'.....	60
Tabela 10 - Média de FM por época e eletrodo para o momento 'Mozart'.....	61

# LISTA DE SIGLAS E ABREVIATURAS

<b>BESA</b>	- <i>Brain Electrical Source Analysis</i>
<b>CRS-S</b>	- <i>Coma Recovery Scale-Revised</i>
<b>EEG</b>	- Eletroencefalograma
<b>EMC</b>	- Estado de Mínima Consciência
<b>EV</b>	- Estado Vegetativo
<b>FM</b>	- Frequência Mediana
<b>GCS</b>	- <i>Glasgow Coma Scale</i>
<b>HC-UFU</b>	- Hospital de Clínicas da Universidade Federal de Uberlândia
<b>ICA</b>	- <i>Independent Component Analysis</i>
<b>IDE</b>	- <i>Integrated Development Environment</i>
<b>Inf</b>	- Infinito
<b>MATLAB</b>	- <i>Matrix Laboratory</i>
<b>NaN</b>	- <i>Not a Number</i>
<b>PCP</b>	- Porcentagem de Contribuição de Potência
<b>PRE</b>	- Potenciais Relacionados a Eventos
<b>UFU</b>	- Universidade Federal de Uberlândia
<b>UTI</b>	- Unidade de Tratamento Intensivo

# SUMÁRIO

<b>CAPÍTULO 1 - INTRODUÇÃO .....</b>	<b>11</b>
<b>1.1 CONTEXTUALIZAÇÃO .....</b>	<b>11</b>
<b>1.2 JUSTIFICATIVA .....</b>	<b>14</b>
<b>1.3 OBJETIVOS .....</b>	<b>16</b>
1.3.1 Objetivo Geral .....	16
1.3.2 Objetivos Específicos .....	17
<b>1.4 ORGANIZAÇÃO DO DOCUMENTO.....</b>	<b>18</b>
<b>CAPÍTULO 2 - REVISÃO BIBLIOGRÁFICA .....</b>	<b>19</b>
<b>2.1 ESTIMULAÇÃO MUSICAL.....</b>	<b>19</b>
<b>2.2 ELETROENCEFALOGRAMA (EEG).....</b>	<b>20</b>
<b>2.3 EEG EM PACIENTES EM ESTADO DE COMA .....</b>	<b>22</b>
<b>2.4 ESTIMULAÇÃO MUSICAL EM PACIENTES EM ESTADO DE COMA.....</b>	<b>25</b>
<b>2.5 PYTHON E MATLAB PARA PROCESSAMENTO DE SINAIS EEG .....</b>	<b>26</b>
<b>2.6 QUANTIFICADORES DE ANÁLISE DE SINAIS EEG .....</b>	<b>28</b>
<b>2.7 REVISÃO DE ESTUDO DE CASOS.....</b>	<b>31</b>
<b>CAPÍTULO 3 - METODOLOGIA.....</b>	<b>33</b>
<b>3.1 BASE DE DADOS E AUTORIZAÇÃO ÉTICA PARA COLETA.....</b>	<b>33</b>
<b>3.2 QUANTIFICADORES UTILIZADOS .....</b>	<b>36</b>
<b>3.3 ANÁLISE ESTATÍSTICA.....</b>	<b>37</b>
3.3.1 Desenvolvimento e análise do erro relativo entre plataformas .....	37
3.3.2 Algoritmo para cálculo do erro relativo .....	38
3.3.3 Processamento e análise dos dados .....	40
<b>3.4 IDENTIFICAÇÃO E DESCRIÇÃO DAS VARIÁVEIS DE ENTRADA E SAÍDA DOS CÓDIGOS.....</b>	<b>42</b>
<b>3.5 QUANTIFICAÇÃO DA ATIVIDADE CEREBRAL (MOZART X SILÊNCIO) .....</b>	<b>44</b>
<b>CAPÍTULO 4 - RESULTADOS E DISCUSSÃO.....</b>	<b>45</b>
<b>4.1 RESULTADOS DA COMPARAÇÃO ENTRE PYTHON E MATLAB .....</b>	<b>45</b>

<b>4.2 RESULTADOS COMPARATIVOS DO QUANTIFICADOR DE COERÊNCIA.....</b>	<b>51</b>
<b>4.3 ANÁLISE SINAL ESTIMULAÇÃO MOZART X SILÊNCIO.....</b>	<b>56</b>
<b>4.4 DISCUSSÃO.....</b>	<b>64</b>
4.4.1 Consistência entre MATLAB e Python para Quantificadores FM e PCP.....	64
4.4.2 Implicações da Escolha da Plataforma (MATLAB vs. Python) .....	65
4.4.3 Variações da atividade cerebral (Mozart x Silêncio) .....	67
<b>CAPÍTULO 5 - CONCLUSÃO .....</b>	<b>68</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>71</b>
<b>ANEXO A - CÓDIGO RELATIVE_ERROR.....</b>	<b>75</b>
<b>ANEXO B - CÓDIGO MAX_RELATIVE_ERROR.....</b>	<b>77</b>
<b>ANEXO C – CÓDIGO RELATIVE_ERROR_QUANTIFIER .....</b>	<b>81</b>
<b>ANEXO D - EXEMPLO DO ARQUIVO CSV DE ENTRADA PARA O CÓDIGO DO ANEXO C.....</b>	<b>86</b>
<b>ANEXO E – EXEMPLO DO ARQUIVO CSV DE SAÍDA PARA O CÓDIGO DO ANEXO C</b>	<b>87</b>

# CAPÍTULO 1 - INTRODUÇÃO

Neste capítulo será apresentado uma iniciação ao tema, destacando a relevância de se comparar diferentes ferramentas para o processamento e análise de eletroencefalogramas (EEG) em pacientes comatosos que realizaram o exame sob estimulação musical, buscando assim, identificar uma relevância dessas análises para a ciência e para a sociedade.

## 1.1 CONTEXTUALIZAÇÃO

O coma é um estado de inconsciência profunda, onde a pessoa não responde a estímulos e não demonstra estar acordada, mantendo os olhos fechados. Diferente de desmaios ou concussões, que são passageiros, o coma se caracteriza por durar no mínimo uma hora (LAUREYS; OWEN; SCHIFF, 2004). Nesse estado, o paciente não apresenta os ciclos naturais de sono-vigília nem abertura espontânea dos olhos. A recuperação, caso ocorra, geralmente se inicia em duas a quatro semanas, podendo variar desde um retorno parcial da consciência até uma recuperação mais completa. Este estado é um grande desafio na medicina, pois é causado por lesões cerebrais graves, como traumas na cabeça, infecções ou intoxicações. A avaliação e o acompanhamento de pacientes em coma são complexos, exigindo ferramentas específicas para monitorar a atividade cerebral, já que não há respostas comportamentais óbvias (LAUREYS; OWEN; SCHIFF, 2004).

Nesse contexto, a estimulação musical emerge como uma intervenção terapêutica promissora, visando potencializar a recuperação neurológica em pacientes comatosos. A música, com sua estrutura rítmica e melódica, pode influenciar parâmetros fisiológicos e evocar respostas cerebrais, mesmo na ausência de consciência plena, ativando redes neurais associadas à percepção auditiva e emocional. Essa capacidade de modulação neural sugere o potencial da música em facilitar a reorganização cerebral e a recuperação funcional (LIMA et al., 2021).

O eletroencefalograma (EEG) é uma ferramenta fundamental na neurociência, permitindo o registro não invasivo da atividade elétrica cerebral. A análise precisa dos sinais de EEG é fundamental para compreender o estado neurológico do paciente e avaliar a eficácia de intervenções terapêuticas, como a estimulação musical. Diante disso, a análise de eletroencefalogramas (EEG's) em pacientes comatosos representa um desafio significativo, exigindo a extração de características fortes e relevantes para a avaliação do estado neurológico e prognóstico. A seleção cuidadosa de quantificadores do sinal é fundamental para garantir a precisão e confiabilidade dos resultados, notadamente em estudos comparativos entre diferentes plataformas de processamento, como MATLAB e Python que oferecem capacidades abrangentes que vão desde o pré-processamento de dados até a aplicação de algoritmos avançados de aprendizado de máquina que pode, por exemplo, auxiliar na classificação de estados cerebrais.

Vários softwares são empregados para o processamento de sinais de eletroencefalograma (EEG), cada um oferecendo um conjunto específico de ferramentas e funcionalidades para diferentes etapas da análise. Amplamente utilizados na pesquisa e na prática clínica, esses softwares permitem desde a visualização e pré-processamento dos dados brutos até análises mais avançadas, como a classificação de padrões cerebrais.

No contexto da pesquisa científica, muitas ferramentas digitais amplamente reconhecidos são úteis para o processamento de sinais de EEG, cada uma oferecendo funcionalidades e características distintivas. Entre as opções de código aberto mais populares destacam-se o EEGLAB, o FieldTrip, o Brainstorm e o MNE-Python. O EEGLAB é um toolbox interativo em MATLAB, amplamente utilizado, capaz de processar dados contínuos e eventos relacionados, e notabiliza-se pelo suporte a técnicas avançadas como a análise de componentes independentes (ICA) (DAS et al., 2023). O FieldTrip, também em MATLAB, provê um conjunto extenso de funções de alto nível para análises avançadas, incluindo decomposição tempo-frequência, reconstrução de fontes cerebrais e testes estatísticos não-paramétricos por permutação (OOSTENVELD et al., 2011). Já o Brainstorm oferece uma interface gráfica amigável para análise de EEG/MEG, com ferramentas integradas de visualização, filtragem, detecção de artefatos (por exemplo, piscadas e batimentos

cardíacos) e estimativa de fontes, podendo ser utilizado de forma autônoma ou em conjunto com o MATLAB (DAS et al., 2023).

Por sua vez, o MNE-Python é uma biblioteca em Python de código aberto voltada à visualização e processamento de dados M/EEG, suportando múltiplos formatos de arquivo e disponibilizando rotinas abrangentes de pré-processamento, estimativa de fontes, análises no domínio tempo-frequência, técnicas de aprendizado de máquina e estatística (DAS et al., 2023).

Além dessas soluções gratuitas, destacam-se também pacotes comerciais consolidados, como o BESA (*Brain Electrical Source Analysis*), reconhecido pelas ferramentas de filtragem, detecção de artefatos, análise espectral e especialmente pela estimativa de fontes cerebrais, sendo amplamente empregado em estudos de EEG clínicos e experimentais (DAS et al., 2023).

Consequentemente, a análise conjunta de diferentes quantificadores do sinal de EEG proporciona uma compreensão mais complexa e abrangente da atividade cerebral e da qualidade do processamento dos dados. Enquanto a Porcentagem de Contribuição de Potência (PCP) e a Frequência Mediana (FM) oferecem percepções sobre a dinâmica energética e espectral da atividade elétrica cerebral, a Coerência possibilita a avaliação da comunicação funcional entre distintas regiões cerebrais. A combinação dessas métricas, portanto, enriquece a análise, permitindo uma avaliação mais completa e consistente dos dados de EEG, fundamental para a investigação do estado neurológico e da resposta a intervenções terapêuticas, como a estimulação musical em pacientes comatosos.

Diante do exposto, este trabalho busca contribuir para a validação do Python como ferramenta eficaz no processamento de sinais de EEG, abrindo caminho para pesquisas futuras. Especificamente em relação ao Python, sua seleção como plataforma de processamento se justifica por ser uma linguagem de código aberto, gratuita e flexível, com uma comunidade ativa e vasta disponibilidade de bibliotecas científicas. Essa robustez torna o Python não apenas uma opção acessível, mas também adaptável às necessidades da pesquisa em neurociência, incentivando a transparência, a reproduzibilidade e a inovação no desenvolvimento de novos métodos de análise de sinais neurofisiológicos. Adicionalmente, este estudo visa aplicações

futuras como a investigação dos efeitos da estimulação musical na atividade cerebral de pacientes em estado de coma. Nesse contexto, a seleção dos quantificadores PCP, FM e Coerência permite avaliar se ambas as plataformas fornecem resultados consistentes na análise da dinâmica funcional cerebral, possibilitando a comparação objetiva entre diferentes plataformas de processamento.

## 1.2 JUSTIFICATIVA

A investigação sobre pacientes em estado de coma sob estimulação musical tem sido explorada por ser uma possível via para promover mudanças na atividade cerebral nesses indivíduos. Acredita-se que a música, com seus elementos rítmicos, melódicos e harmônicos, possa evocar respostas neuronais mesmo em estados de consciência alterada, potencialmente influenciando a plasticidade cerebral e auxiliando em processos que sugerem a recuperação neurológica (CASTRO et al., 2015). A análise da atividade eletroencefalográfica (EEG) durante a estimulação musical em pacientes comatosos pode fornecer informações cruciais sobre o processamento auditivo e a reatividade cerebral nesses estados, abrindo caminho para o desenvolvimento de intervenções terapêuticas mais direcionadas.

A utilização de sinais eletroencefalográficos (EEG) para monitorar pacientes em coma submetidos à estimulação musical é uma área de pesquisa promissora, com o potencial de fornecer percepções valiosas sobre a recuperação neurológica. A análise desses sinais complexos requer ferramentas computacionais precisas e confiáveis. Tradicionalmente, o MATLAB tem sido a escolha predominante para essa finalidade, devido às suas extensas bibliotecas e interface amigável (DELORME; MAKEIG, 2004). No entanto, o custo de licenciamento do MATLAB representa uma barreira significativa para muitos pesquisadores e instituições, limitando o acesso a essa ferramenta.

A justificativa deste estudo se apoia na crescente adoção de ferramentas de código aberto, como o Python, na pesquisa científica e na necessidade de garantir que os resultados gerados sejam equivalentes aos obtidos com softwares tradicionais

como o MATLAB. Dessa forma, o trabalho contribui para a padronização e validação de métodos computacionais aplicados à neuroengenharia, oferecendo subsídios para decisões tecnológicas em pesquisas futuras.

Além disso, a análise comparativa da atividade cerebral registrada durante períodos distintos como, por exemplo, de silêncio e durante uma estimulação musical permite identificar e quantificar as alterações na dinâmica neural induzidas pela intervenção sonora. Essa comparação entre os diferentes momentos do exame pode fornecer evidências sobre a eficácia da estimulação musical em promover mudanças na atividade cerebral de pacientes em estado de coma, complementando a avaliação da equivalência entre as ferramentas de análise.

Nesse contexto, apesar dos benefícios potenciais do Python, ainda há uma necessidade de validar sua eficácia e confiabilidade na análise de sinais de EEG. Embora estudos tenham demonstrado que o Python pode alcançar resultados comparáveis ao MATLAB em várias tarefas de análise de EEG (LOMBARDINO, 2025), uma comparação direta e sistemática é essencial para garantir a equivalência dos resultados e a reproduzibilidade da pesquisa.

Desta forma, este estudo busca contribuir realizando uma comparação abrangente do processamento de sinais de EEG em MATLAB e Python. Ao analisar dados de pacientes comatosos submetidos à estimulação musical, o estudo avaliará a capacidade do Python de reproduzir os resultados obtidos com o MATLAB, como Porcentagem de Contribuição de Potência (PCP), Frequência Mediana (FM) e Coerência.

Portanto, vislumbra-se o desenvolvimento deste estudo pela necessidade de validar o uso do Python como uma ferramenta eficaz e acessível para análise de sinais de EEG, garantindo a confiabilidade e a reproduzibilidade da pesquisa nessa área da neuroengenharia que é vista como crítica pela extrema vulnerabilidade clínica de pacientes em estado de coma, pela complexidade do diagnóstico e prognóstico em estados de inconsciência, pela janela terapêutica muitas vezes limitada para intervenções e pela complexidade da própria atividade cerebral a ser compreendida nesses estados. Ademais, a investigação da estimulação musical em pacientes

comatosos reveste-se de grande relevância clínica e científica. Compreender como o cérebro em estado de inconsciência processa estímulos musicais, através da análise de seus sinais elétricos cerebrais captados pelo EEG e processados com o Python, pode abrir novas perspectivas tecnológicas e científicas.

## 1.3 OBJETIVOS

### 1.3.1 Objetivo Geral

A análise de sinais eletroencefalográficos (EEG) tem se mostrado uma ferramenta essencial no acompanhamento do estado de consciência de pacientes comatosos, especialmente quando associada a estímulos externos, como a música. Para a realização dessa análise, diferentes plataformas computacionais podem ser utilizadas, sendo o MATLAB e o Python duas das mais recorrentes na área de Engenharia Biomédica.

Entretanto, embora ambas as plataformas ofereçam recursos robustos para o processamento de sinais, diferenças entre bibliotecas, algoritmos e rotinas de implementação podem resultar em variações nos resultados obtidos, o que pode comprometer a reproduzibilidade, a confiabilidade e até mesmo a interpretação clínica dos dados.

Nesse contexto, este trabalho tem como objetivo principal analisar e comparar os resultados do processamento de sinais EEG realizados nas plataformas MATLAB e Python, utilizando exames de pacientes comatosos submetidos à estimulação musical. Adicionalmente, este estudo realizará uma análise comparativa da atividade eletroencefalográfica de pacientes comatosos em dois momentos distintos do exame: durante um período basal de silêncio e durante a aplicação da estimulação musical.

Portanto, por meio dessas comparações, busca-se compreender, primeiramente, como as diferenças entre os ambientes de programação impactam quantificadores relevantes para a análise, como a Porcentagem de Contribuição de Potência (PCP), a Frequência Mediana (FM) e a Coerência, executar procedimentos padrão de processamento de sinais de EEG em Python, comparar a precisão dos

resultados obtidos e identificar desafios e limitações e, também, identificar alterações na atividade cerebral induzidas pela intervenção sonora, fornecendo percepções sobre a reatividade neural e o potencial da música como estímulo em pacientes comatosos.

### **1.3.2 Objetivos Específicos**

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

- **Utilizar rotinas já implementadas, padronizadas de processamento de sinais EEG na linguagem Python**, com foco na extração de quantificadores como Porcentagem de Contribuição de Potência (PCP), Frequência Mediana (FM) e Coerência;
- **Comparar quantitativamente e graficamente os resultados obtidos em cada plataforma**, por meio da aplicação de métricas de erro, como o erro relativo, visando identificar eventuais discrepâncias nos valores dos quantificadores Porcentagem de Contribuição de Potência (PCP), Frequência Mediana (FM) e Coerência;
- **Avaliar a confiabilidade e a reproduzibilidade dos resultados obtidos nas duas linguagens**, verificando a consistência dos valores obtidos diante da mesma base de dados e procedimentos, com atenção especial à viabilidade de uso científico dos métodos analisados;
- **Realizar uma análise comparativa** da atividade eletroencefalográfica do paciente em dois momentos distintos do exame: durante um período basal de silêncio e durante a aplicação da estimulação musical;
- **Identificar os principais desafios enfrentados na implementação e comparação dos algoritmos entre MATLAB e Python**, incluindo limitações técnicas, diferenças entre bibliotecas utilizadas e possíveis variações nos métodos matemáticos aplicados por cada ambiente de programação.

## 1.4 ORGANIZAÇÃO DO DOCUMENTO

Este trabalho está organizado da seguinte forma:

- **Capítulo 1** – Apresenta uma introdução ao tema, destacando a relevância do EEG para a ciência e a sociedade.
- **Capítulo 2** – Aborda os principais *software* utilizados no processamento de EEG, bem como uma comparação sucinta dessas ferramentas sob a perspectiva de desenvolvimento e implementação. Além disso, também aborda a análise da comparação do EEG quando realizados em pacientes comatosos em diferentes momentos sendo eles, o silêncio e sob estimulação musical.
- **Capítulo 3** - Detalha os procedimentos e o protocolo utilizados na pesquisa. Além disso, este capítulo aborda a metodologia empregada, descrevendo desde a base de dados utilizada e o processamento de sinais, até os quantificadores e a análise estatística, focando no desenvolvimento e cálculo do erro relativo entre os resultados obtidos em Python e MATLAB, visando validar a consistência e precisão do Python.
- **Capítulo 4**: Neste capítulo é apresentado os resultados obtidos, incluindo o processamento de códigos, resultados de coerência e a análise de tendências. Por fim, a discussão explora a consistência entre as plataformas MATLAB e Python, encerrando nas implicações da escolha da plataforma.
- **Capítulo 5**: Sintetiza os achados do estudo, reafirmando as contribuições para o processamento de sinais de EEG e a validação do Python em contextos clínicos. Ele aborda a equivalência dos resultados de quantificadores (FM e PCP) entre Python e MATLAB e discute as observações sobre a maior diferença em determinadas bandas de frequência e a análise da coerência, destacando a consistência do Python para análises realização dessas análises. Finalizando com a apresentação de sugestões para futuras investigações, visando aprofundar a compreensão da conectividade cerebral e aprimorar metodologias de análise.

## CAPÍTULO 2 - REVISÃO BIBLIOGRÁFICA

Este capítulo aborda os efeitos da estimulação musical em pacientes em estado de coma, as principais diferenças entre os *softwares* utilizados no processamento de EEG, bem como uma comparação dessas ferramentas sob a perspectiva de desenvolvimento e implementação. Além disso, também aborda os principais quantificadores a serem analisadas a fim de se realizar as comparações entre *softwares*, sendo eles, Python e MATLAB.

### 2.1 ESTIMULAÇÃO MUSICAL

A estimulação musical pode contribuir para melhorar o diagnóstico diferencial entre diferentes níveis de consciência. Estudos mostram que pacientes em estado minimamente consciente respondem de maneira mais pronunciada a estímulos musicais em comparação com pacientes em estado vegetativo persistente. Isso sugere que a música pode ser uma ferramenta diagnóstica complementar valiosa para identificar sinais sutis de percepção e consciência residual (LLOYD-FOX et al., 2015). Combinada ao EEG e à análise de conectividade funcional, essa abordagem permite detectar padrões de atividade que podem indicar maior integridade de redes neurais importantes, como a rede de modo padrão.

Notavelmente, a estimulação auditiva, particularmente através da música, frequentemente apresenta uma abordagem mais viável em comparação com os estímulos visuais, uma vez que o sistema visual costuma estar comprometido em pacientes em estado de coma, enquanto o sistema auditivo normalmente permanece funcional (LANCIONI et al., 2021). A análise das respostas fisiológicas desses pacientes à estimulação musical requer técnicas eficazes de processamento de sinais aplicadas aos dados coletados, como gravações de eletroencefalograma (EEG) (SPACCAVENTO et al., 2024).

A escolha da música utilizada na estimulação é um aspecto fundamental. Acredita-se que músicas familiares ao paciente, com forte carga emocional positiva,

possam ser mais eficazes em despertar respostas. No entanto, a individualidade das preferências musicais e a necessidade de evitar estímulos aversivos ou excessivamente complexos são considerações importantes. A intensidade, o ritmo e a estrutura da música também podem influenciar a resposta do paciente. Portanto, a seleção musical deve ser personalizada e adaptada às características e à história de vida de cada indivíduo (LI, X. et al., 2020).

Diante disso, a estimulação musical representa uma intervenção não invasiva e potencialmente benéfica para pacientes em estado de coma. A cuidadosa avaliação dos efeitos da música em comparação com períodos de silêncio, utilizando uma variedade de medidas fisiológicas, neurológicas e comportamentais, é essencial para compreender os mecanismos de ação e otimizar as estratégias de aplicação. Pesquisas futuras são necessárias para refinar os protocolos de estimulação, identificar os pacientes que mais se beneficiam dessa abordagem e integrar a musicoterapia de forma eficaz nos programas de reabilitação neurológica (LI, X. et al., 2020).

Para finalizar, há também evidências de que a estimulação musical pode modular respostas autonômicas, como a variabilidade da frequência cardíaca e a condutância da pele, indicando um impacto mais amplo da música sobre o sistema nervoso central e autônomo. Tais respostas fisiológicas, quando associadas à atividade cerebral captada por EEG, oferecem uma abordagem multimodal promissora para monitorar a recuperação de pacientes com desordem de consciência. A integração dessas técnicas pode fornecer indicadores objetivos de mudanças neurológicas, com implicações tanto para o prognóstico quanto para a personalização de intervenções terapêuticas (STEWART et al., 2015).

## 2.2 ELETROENCEFALOGRAMA (EEG)

O eletroencefalograma (EEG) representa um método fundamental na neurofisiologia, dedicado ao registro da atividade elétrica do cérebro (PAUL et al., 2024). Este exame neurofisiológico, de grande relevância para a comunidade médica

desde sua introdução em 1929, utiliza eletrodos posicionados sobre o couro cabeludo para captar as correntes elétricas cerebrais. Sua importância reside na capacidade de fornecer informações importantes sobre o funcionamento do cérebro, sendo empregada por exemplo, no diagnóstico da epilepsia e na identificação de distúrbios do sono. A ampla aceitação e utilização do EEG ao longo de décadas atestam sua eficácia e o estabelecem como uma ferramenta essencial na avaliação da função cerebral.

O funcionamento da eletroencefalografia baseia-se na medição não invasiva da atividade elétrica cerebral através de eletrodos fixados no couro cabeludo. Esses eletrodos sensíveis captam os impulsos elétricos, conhecidos como ondas cerebrais, produzidos pela atividade dos neurônios. As flutuações de tensão resultantes das correntes iônicas dentro dessas células nervosas são o substrato biofísico que o EEG registra (CACIOPPO; TASSINARY; BERNTSON, 2000; TEPLAN, 2002). Os sinais elétricos captados são então amplificados e transformados em gráficos que exibem os padrões da atividade elétrica cerebral (PAUL et al., 2024). Essa atividade é representada visualmente por meio de ondas em um eletroencefalograma. A análise dessas ondas, comparando-as com padrões considerados normais, permite aos especialistas identificar alterações e correlacioná-las com dados clínicos para auxiliar no diagnóstico. A natureza não invasiva do procedimento contribui significativamente para sua aplicabilidade em diversas faixas etárias, desde recém-nascidos até idosos.

As aplicações clínicas da eletroencefalografia são amplas e abrangem o diagnóstico e monitoramento de diversas condições neurológicas. Primordialmente, o EEG desempenha um papel essencial na identificação de alterações na atividade cerebral associadas à epilepsia e a outras condições convulsivas. Além disso, é uma ferramenta relevante na avaliação de pacientes com perda de consciência episódica de causa desconhecida. O EEG também é utilizado no diagnóstico de distúrbios do sono, encefalopatias metabólicas ou estruturais, tumores cerebrais, danos cerebrais decorrentes de traumatismos cranioencefálicos, inflamações cerebrais como a encefalite, acidentes vasculares cerebrais e na suspeita das doenças cerebrais. Em contextos de cuidados intensivos, o EEG é empregado para investigar e afirmar a morte cerebral em pacientes em coma. Técnicas específicas, como a hiperventilação,

a estimulação fótica e o registro durante o sono ou privação de sono, podem ser utilizadas para ativar o córtex cerebral e facilitar a detecção de anormalidades (PAUL et al., 2024).

Na área da neurociência, a eletroencefalografia possui uma importância histórica e contemporânea significativa. Sua capacidade de captar a atividade de milhares de neurônios por meio da diferença de potencial elétrico oferece informações significativas sobre as funções cerebrais, os estados de consciência e os processos cognitivos. Apesar de suas limitações em resolução espacial, a alta resolução temporal do EEG o torna uma ferramenta fundamental para investigar a dinâmica da atividade cerebral em estudos clínicos e experimentais, incluindo pesquisas sobre design emocional e a interação entre usuários e produtos.

Em suma, a eletroencefalografia é um exame neurofisiológico não invasivo de fundamental importância tanto para a prática clínica quanto para a pesquisa em neurociência. Sua capacidade de registrar e analisar a atividade elétrica cerebral permite o diagnóstico e monitoramento de diversas condições neurológicas, especialmente a epilepsia, além de contribuir significativamente para a compreensão das funções cerebrais e dos processos cognitivos. A evolução da técnica, desde os registros analógicos até os sistemas digitais sofisticados, continua a expandir suas aplicações e a consolidar seu papel como uma ferramenta indispensável no estudo do cérebro humano.

## 2.3 EEG EM PACIENTES EM ESTADO DE COMA

Um paciente em estado de coma encontra-se em um nível profundo de inconsciência, caracterizado pela ausência de resposta consciente a estímulos externos, como sons, luzes ou dor. Nesse estado, os olhos permanecem fechados, e o indivíduo não apresenta ciclos normais de sono e vigília. O coma pode resultar de diversas causas, incluindo traumatismos crânioencefálicos, acidentes vasculares cerebrais, infecções, intoxicações ou distúrbios metabólicos (MANUAL MSD, 2024). A manutenção da consciência depende da integridade do córtex cerebral e do sistema

de ativação reticular ascendente; lesões nessas áreas podem levar ao coma. Embora o paciente em coma não demonstre sinais evidentes de percepção, estudos sugerem que a audição pode ser o último sentido a ser perdido, indicando a importância de um ambiente cuidadoso e respeitoso ao redor desses pacientes (PUGGINA, Ana Cláudia Giesbrecht; SILVA, 2009).

O eletroencefalograma (EEG) tem se consolidado como uma ferramenta essencial para o monitoramento de pacientes em estado de coma ou com desordem de consciência, como o estado vegetativo e o estado minimamente consciente. Sua capacidade de detectar atividade elétrica cerebral em tempo real, de forma não invasiva e com alta resolução temporal, torna-o ideal para avaliar o funcionamento cortical residual em pacientes que não conseguem responder a comandos de forma comportamental. O EEG é frequentemente utilizado para distinguir entre diferentes níveis de consciência e para monitorar alterações ao longo do tempo, sendo fundamental para auxiliar no diagnóstico, prognóstico e tomada de decisões clínicas (SITT et al., 2014).

Além da avaliação visual dos padrões clássicos do EEG, como a presença de atividade alfa ou ritmos lentos, avanços nas análises quantitativas têm permitido extrair informações mais sutis sobre a conectividade funcional e a complexidade da atividade cerebral em pacientes com desordem de consciência. Técnicas como análise espectral, entropia, conectividade funcional e medidas de coerência entre regiões cerebrais revelam padrões que podem estar associados a estados de consciência residuais não detectáveis por métodos clínicos tradicionais. Esses indicadores têm sido propostos como potenciais biomarcadores de consciência, permitindo diferenciar com maior precisão pacientes em estado de mínima consciência (EMC) daqueles em estado vegetativo (EV) (CHENNU et al., 2017).

Pesquisas indicam que protocolos baseados em estímulos auditivos e visuais, bem como em tarefas de imaginação motora, são eficazes para avaliar a reatividade cerebral por meio de eletroencefalograma (EEG). A detecção de potenciais relacionados a eventos (PRE), como o P300, serve como evidência da preservação de processos cognitivos mesmo na ausência de respostas motoras voluntárias

observáveis (POLICH, 2007). O P300, um pico no EEG que ocorre aproximadamente 300 milissegundos após estímulos raros ou inesperados, é amplamente utilizado para avaliar a atenção e o reconhecimento em pacientes, sendo um indicador relevante de consciência residual em condições de coma ou estado vegetativo,

Complementarmente, um estudo de (PUGGINA; SILVA, 2015) com pacientes em coma e estado vegetativo demonstrou que estímulos auditivos significativos (música ou mensagem verbal) podem eliciar respostas fisiológicas e motoras sutis nesses indivíduos. Observou-se, por exemplo, alterações estatisticamente significativas na temperatura corporal, na expressão facial e na atividade muscular (sinais eletromiográficos) durante a exposição à música ou à mensagem. Notavelmente, essa investigação concluiu que a expressão facial e os sinais eletromiográficos foram indicadores mais confiáveis de consciência residual do que as variações em sinais vitais. Tais achados, em conjunto, são valiosos para aprimorar o diagnóstico e identificar pacientes com potencial de recuperação funcional por meio de terapias de reabilitação (POLICH, 2007).

A evolução dos métodos computacionais, impulsionada por técnicas de aprendizado de máquina e inteligência artificial, tem ampliado ainda mais o potencial do EEG no acompanhamento de pacientes em coma. Modelos automatizados têm demonstrado capacidade crescente de classificar estados de consciência a partir de grandes volumes de dados eletrofisiológicos. Esse avanço é especialmente relevante para centros com recursos limitados, onde a expertise para interpretar EEG pode ser escassa (LI, B.; CAO, 2024).

Por fim, o acúmulo de evidências científicas e o refinamento das metodologias têm contribuído para transformar o EEG em uma ferramenta não apenas diagnóstica, mas também prognóstica e terapêutica. Assim, o EEG pode ser usado para monitorar intervenções terapêuticas como estimulação elétrica, transcraniana ou musical, viabilizando uma abordagem mais personalizada e baseada em evidências (YIJUN WANG et al., 2008).

## 2.4 ESTIMULAÇÃO MUSICAL EM PACIENTES EM ESTADO DE COMA

A estimulação musical surgiu como uma intervenção promissora para indivíduos que sofrem de lesões cerebrais graves e distúrbios de consciência, abrangendo condições como coma. O potencial da música para influenciar redes neurais, promover a plasticidade cerebral e mitigar a privação sensorial oferece uma justificativa convincente para sua aplicação nesta população de pacientes (LANCIONI et al., 2021).

Diversos estudos apontam que a música pode atuar como um estímulo emocional e cognitivo poderoso, capaz de ativar regiões cerebrais relacionadas à memória, atenção, e consciência, mesmo em pacientes com distúrbios de consciência. A exposição à música familiar, especialmente quando associada a fortes vínculos afetivos, tem demonstrado provocar mudanças na atividade cerebral, sugerindo a promoção de reconexões sinápticas e engajamento de circuitos neurais preservados (ZHOU et al., 2020). Essas respostas podem ser observadas por meio de técnicas como a eletroencefalograma (EEG), que fornece uma visão não invasiva e em tempo real da atividade elétrica cerebral.

A aplicação da estimulação musical em pacientes em estado de coma representa uma área promissora e intrigante da neurorreabilitação. A música, com sua capacidade de evocar emoções e memórias, pode atuar como um estímulo sensorial capaz de alcançar áreas cerebrais preservadas, mesmo em estados de profunda alteração da consciência. Acredita-se que a estimulação auditiva rítmica e melódica possa modular a atividade cerebral, influenciando positivamente a plasticidade neuronal e, potencialmente, facilitando o retorno da consciência ou a melhora da responsividade (LI, X. et al., 2020).

A avaliação dos resultados da estimulação musical em pacientes em coma requer uma abordagem multimodal e longitudinal. É importante comparar os períodos de estimulação musical com momentos de silêncio para identificar mudanças significativas nas variáveis fisiológicas, neurológicas e comportamentais. A utilização

de ferramentas como o EEG quantitativo, a ressonância magnética funcional (fMRI) e escalas comportamentais específicas para avaliação do estado de consciência (como a *Coma Recovery Scale-Revised - CRS-R*) permite uma análise objetiva e detalhada das respostas do paciente. A identificação de padrões de resposta consistentes e reproduzíveis durante a estimulação musical, em contraste com a ausência de resposta durante o silêncio, fortalece a evidência de um efeito terapêutico (LI, X. et al., 2020).

Portanto, a estimulação musical surge como uma alternativa inovadora para a reabilitação de pacientes em estado de coma. A capacidade da música de acessar memórias, provocar emoções e estimular regiões cerebrais importantes mostra seu potencial para promover melhorias na consciência e responsividade desses indivíduos. Embora ainda existam muitos aspectos a serem explorados pela pesquisa científica, os resultados observados até agora são encorajadores e sugerem que a música pode ser uma ferramenta complementar importante no cuidado desses pacientes. Investir em estudos mais amplos e em protocolos de avaliação detalhados será fundamental para consolidar o uso da música neste contexto.

## 2.5 PYTHON E MATLAB PARA PROCESSAMENTO DE SINAIS EEG

MATLAB ou *Matrix Laboratory*, configura-se como um ambiente de programação multi-paradigma proprietário e uma linguagem de programação numérica de quarta geração, ou seja, uma linguagem de programação desenvolvida para serem mais próximas da linguagem humana do que as linguagens anteriores e focadas em facilitar e acelerar o desenvolvimento de programas, especialmente aplicações voltadas para bancos de dados, cálculos científicos, e processamento de alto nível. Em contraste, Python representa uma linguagem de programação de propósito geral, de alto nível, interpretada e com tipagem dinâmica, notável por sua sintaxe clara e versatilidade em diversas aplicações, incluindo desenvolvimento web, ciência de dados, inteligência artificial e automação.

O EEG é um método amplamente empregado e confiável para avaliar a função cerebral em indivíduos com consciência prejudicada, fornecendo informações valiosas sobre seu nível de consciência e reações a estímulos externos (HUANG et al., 2022). No contexto da engenharia biomédica, a escolha do ambiente de programação para tais tarefas de processamento de sinais é crítica. MATLAB e Python se destacam como duas plataformas proeminentes, cada uma oferecendo um conjunto distinto de ferramentas, características de desempenho, implicações de custo e atributos de facilidade de uso.

O *Integrated Development Environment* (IDE) do MATLAB, com sua interface intuitiva e recursos de visualização gráfica, facilita a manipulação e interpretação dos dados de EEG, permitindo uma análise mais interativa e eficiente. Essa característica foi essencial para a adoção do software por pesquisadores e clínicos que buscavam uma ferramenta completa e de fácil utilização (YOUNG, 2009).

Outro fator determinante para a consolidação do MATLAB no processamento de sinais biomédicos foi a formação de uma ampla e ativa comunidade de usuários, especialmente nas áreas de neurociência e análise de sinais. Essa rede colaborativa impulsionou o desenvolvimento de bibliotecas, scripts e tutoriais específicos, que não apenas ampliaram as capacidades da plataforma, mas também facilitaram significativamente a curva de aprendizado para novos usuários. A existência dessa infraestrutura de conhecimento compartilhado, aliada ao suporte técnico especializado e à documentação detalhada oferecidos pela MathWorks, contribuiu para reforçar a confiabilidade, a usabilidade e a atratividade do MATLAB como ferramenta padrão na pesquisa e prática clínica (SANEI; CHAMBERS, 2007).

Embora o MATLAB tenha desfrutado de uma posição dominante por anos, o cenário atual apresenta uma crescente adoção do Python na análise de EEG. Bibliotecas como, SciPy e NumPy oferecem funcionalidades comparáveis às do MATLAB, com a vantagem de serem de código aberto e gratuitas. A crescente comunidade de desenvolvedores Python e a disponibilidade de recursos de aprendizado de máquina têm impulsionado sua adoção em pesquisas nessa área a partir da possibilidade de realizar o processamento de sinais biomédicos de maneira eficiente e acessível (WEISSENBOCK et al., 2019).

Por sua vez, o Python se destaca como uma linguagem de programação versátil, ganhando cada vez mais espaço na área da neurociência. Sua natureza de código aberto elimina barreiras financeiras, permitindo que pesquisadores e instituições com recursos limitados acessem ferramentas de análise de dados de alta qualidade. Além disso, a comunidade de desenvolvedores do Python contribui para a criação de bibliotecas e ferramentas especializadas que simplificam o processamento e a análise de sinais de EEG. Logo, a capacidade do Python de integrar-se com outras ferramentas de análise de dados e aprendizado de máquina o torna uma opção atraente para pesquisas avançadas em neurociência. Por exemplo, o Python pode ser utilizado para desenvolver algoritmos de aprendizado de máquina que identificam padrões complexos nos sinais de EEG, auxiliando no diagnóstico e monitoramento de distúrbios neurológicos (GRAMFORT, 2013).

## 2.6 QUANTIFICADORES DE ANÁLISE DE SINAIS EEG

O monitoramento contínuo da atividade cerebral e dos sinais vitais é essencial para avaliar a resposta do paciente à estimulação musical e ajustar a intervenção conforme necessário (SANTOS; CAVALCANTE; SILVA, 2019). Nesse contexto, a escolha dos quantificadores Porcentagem de Contribuição de Potência (PCP), Frequência Mediana (FM) e Coerência se justifica por sua relevância na capacidade de fornecer informações cruciais sobre a atividade cerebral.

Quantificadores referem-se a métricas ou parâmetros computados a partir dos sinais elétricos cerebrais registrados. Esses quantificadores visam extrair informações relevantes sobre a atividade cerebral, permitindo a análise objetiva e a comparação entre diferentes estados cerebrais, condições ou grupos de indivíduos. Eles transformam a complexidade dos sinais de EEG em valores numéricos que podem ser estatisticamente analisados e interpretados, auxiliando na identificação de padrões, na caracterização de fenômenos neurológicos e na avaliação de intervenções.

A Porcentagem de Contribuição de Potência (PCP) permite quantificar a contribuição relativa de cada banda de frequência (delta, teta, alfa, beta, gama e

supergama e ruído) para a atividade cerebral total. Em pacientes comatosos, a análise das bandas de frequência é essencial para identificar padrões de atividade cerebral anormais, como o predomínio de ondas lentas (delta e teta) e a supressão de ritmos rápidos (alfa e beta), que podem indicar disfunção cortical e prognóstico desfavorável (YOUNG, 2009), primeiramente inicia-se o cálculo da potência total do sinal na época conforme a Equação 1:

$$\mathbf{P}_i = \int |S_x i(f)|^2 df \quad i = 1, 2, \dots, S \quad (1)$$

Onde:

- $P_i$  - Potência total do sinal na época  $i$  selecionada
- $S_x$  - Densidade espectral de potência
- $f$  - Frequência
- $i$  - Época considerada
- $S$  - Quantidade total de épocas

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

$$PCP_{ritmo} = \frac{\int_{f_{in ritmo}}^{f_{out ritmo}} |S_x i(f)|^2 df}{\mathbf{P}_i} \quad i = 1, 2, \dots, S \quad (2)$$

Onde:

- $PCP_{ritmo}$  - Porcentagem de potência espectral do ritmo, na época  $i$
- $S_x$  - Densidade espectral do ritmo específico na época  $i$
- $f$  - Frequência
- $i$  - Época considerada
- $P_i$  - Potência total do sinal na época  $i$  selecionada
- $f_{in}$  - Frequência inicial do ritmo
- $f_{out}$  - Frequência final do ritmo
- $S$  - Quantidade total de épocas

Já a Frequência Mediana (FM) fornece informações sobre a velocidade das oscilações cerebrais, auxiliando na identificação de mudanças na atividade cerebral

relacionadas a diferentes estados de consciência. Em pacientes comatosos, a análise da FM pode revelar alterações na dinâmica da atividade cerebral, como a desaceleração da frequência média, que pode indicar disfunção cortical difusa e prognóstico desfavorável (SANEI; CHAMBERS, 2007). Desse modo, o cálculo do quantificador FM é dado conforme a Equação 3:

$$F_{m_i} = \frac{\sum_{n=1}^m |S_x i(f)|_{faixa} \times f_{faixa}}{P_i} \quad (3)$$

Onde:

- $F_{m_i}$  - Frequência Mediana
- $S_x$  - Densidade espectral do ritmo específico na época i
- $f$  - Frequência
- $i$  - Época considerada
- $P_i$  - Potência total do sinal na época i
- $f_{faixa}$  - Vetor de frequências pertencentes à determinada faixa de frequências

Por outro lado, a Coerência se refere à medida da sincronização entre sinais de diferentes eletrodos, indicando o grau de comunicação funcional entre áreas cerebrais. Ela quantifica a consistência da relação de fase entre dois sinais de EEG em uma determinada faixa de frequência, variando de 0 (ausência de sincronização) a 1 (sincronização perfeita). A coerência é uma ferramenta valiosa para investigar a conectividade cerebral e identificar padrões de atividade neuronal associados a diferentes estados cognitivos e patologias (ANGHINAH et al., 2005). Desse modo, o cálculo do quantificador Coerência é dado conforme a Equação 4:

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

Onde:

- $\Gamma_{xy}$  - Coerência de magnitude

- $e^{j\omega}$  - Fator de frequência, onde  $\omega$  é a frequência angular
- $S_{xy}$  - Densidade espectral de potência cruzada
- $S_x$  - Densidade espectral do sinal X
- $S_y$  - Densidade espectral do sinal Y
- $i$  - Segmento considerado

A Equação 4 tem a propriedade abaixo (Equação 5):

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

Sendo que valores próximos de zero indicam baixa correlação e valores próximos a um indicam correlação alta dos sinais.

## 2.7 REVISÃO DE ESTUDO DE CASOS

A aplicação da estimulação musical em pacientes com distúrbios de consciência tem mostrado resultados promissores segundo diversos estudos. Por exemplo, (SCHNAKERS; MAGEE; HARRIS, 2016) investigou os efeitos de programas de estimulação sensorial, incluindo a musicoterapia, no tratamento de distúrbios de consciência, e apontou que a estimulação musical pode ativar redes neurais e potencialmente acelerar a plasticidade cerebral.

Outro estudo publicado (HU et al., 2021) explorou como a música pode influenciar pacientes com distúrbios de consciência, utilizando o eletroencefalograma (EEG) para monitorar as respostas cerebrais à estimulação musical com uso da GCS (*Glasgow Coma Scale*), e observou mudanças significativas na atividade cerebral dos pacientes após a intervenção musical demonstrando uma modulação da atividade metabólica no giro frontal médio, giro temporal superior e núcleo talâmico ventro-anterior em resposta ao programa de estimulação sensorial.

Dado o papel central do EEG nesses estudos para a avaliação das respostas cerebrais, torna-se igualmente relevante considerar as ferramentas utilizadas no processamento desses sinais. Embora a literatura seja rica em estudos que empregam uma ou outra linguagem de programação, como Python ou MATLAB, para

investigar diferentes aspectos da atividade cerebral (SCHNAKERS; MAGEE; HARRIS, 2016) (HU et al., 2021) observa-se uma relativa escassez de investigações que comparem diretamente a eficácia, o desempenho ou as nuances metodológicas entre essas plataformas, independentemente do tipo específico de estímulo aplicado, como a música.

A maioria dos trabalhos publicados tende a focar na aplicação de uma linguagem específica para responder a questões neurocientíficas particulares, sem aprofundar em uma análise comparativa direta das ferramentas de processamento em si, estudos empíricos dedicados a quantificar e qualificar as distinções no processamento de sinais EEG entre essas plataformas ainda são limitados.

Portanto, enquanto ambas as linguagens demonstram ser capazes de fornecer resultados válidos na análise de EEG, a falta de estudos comparativos diretos impede uma compreensão aprofundada das vantagens e desvantagens específicas de cada uma em termos de processamento de sinais. Investigações futuras que abordem essa lacuna seriam valiosas para orientar a escolha da plataforma mais adequada em diferentes contextos de pesquisa em neurociência.

## CAPÍTULO 3 - METODOLOGIA

Nesse tópico estão apresentados as características metodológicas e o protocolo utilizados, detalhando como a base de dados de interesse foi extraída e a análise estatística empregada.

### 3.1 BASE DE DADOS E AUTORIZAÇÃO ÉTICA PARA COLETA

A presente metodologia foi elaborada com base no protocolo apresentado no trabalho de SILVA 2025, este servirá como parâmetro comparativo para gerar os resultados deste trabalho. Com o objetivo de garantir consistência na comparação dos dados, optou-se por utilizar a mesma base de exames já coletados no trabalho citado anteriormente, garantindo integralmente as mesmas condições experimentais aplicadas no estudo anterior. Além disso, as técnicas de pré e pós-processamento dos sinais empregadas neste estudo foram iguais às utilizadas por SILVA 2025, assegurando uma base metodológica consistente para a comparação.

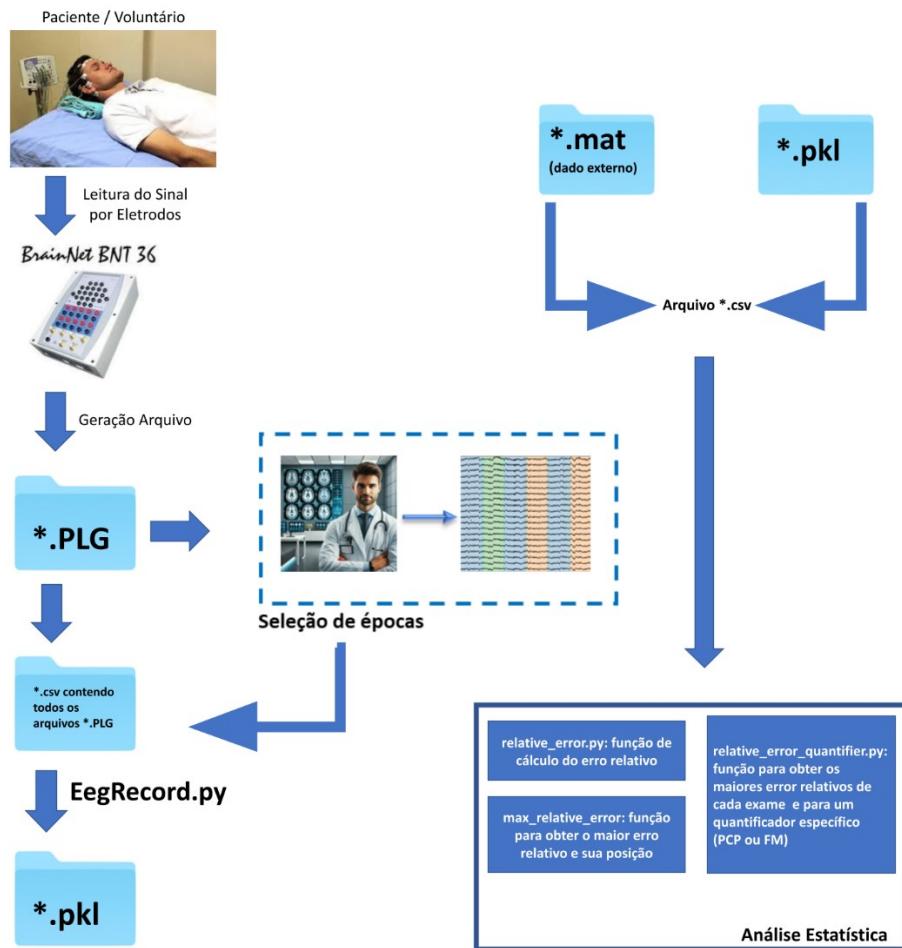
No entanto, esta pesquisa amplia a análise ao utilizar o Python como plataforma de processamento, substituindo o MATLAB empregado no trabalho de SILVA 2025. Diante disso, será realizada uma comparação entre os resultados obtidos em Python e em MATLAB para a mesma base de dados. Além de comparar os quantificadores PCP (Porcentagem de Contribuição de Potência) e FM (Frequência Mediana), este trabalho também apresenta uma análise do quantificador ‘Coerência’, e adota o Erro Relativo como método estatístico para avaliação comparativa entre plataformas de processamento distintas.

Os sinais de EEG utilizados neste estudo foram extraídos de bases experimentais construídas a partir de registros obtidos na Unidade de Terapia Intensiva do Hospital de Clínicas da Universidade Federal de Uberlândia (HC-UFG). Para a fase de teste, foram utilizados dados de pacientes normais e em estado de coma, a base de dados de pacientes normais, extraída de RAMOS 2017, foi construída sob aprovação do Comitê de Ética em Pesquisa (CEP/UFU, protocolo nº

54781615.6.0000.5152). Já a base de pacientes em estado de coma, de acordo com (COSTA, 2022) e descrita por (SILVA, 2025), teve seus registros extraídos sob aprovação do Comitê de Ética em Pesquisa (CEP/UFU, protocolo nº 82824017.5.0000.5152). Para a fase final do trabalho, com o objetivo de comparar diferentes plataformas de processamento, foram utilizados apenas dados de pacientes em estado de coma da base de (SILVA, 2025).

Os dados da base de pacientes em coma (SILVA, 2025) foram coletados com um sistema de EEG multicanal (BrainNet BNT-EEG), com taxa de amostragem de 400 Hz, utilizando 23 eletrodos posicionados conforme o sistema internacional 10-20, enquanto os pacientes permaneciam deitados, com olhos fechados. Na Figura 1 está ilustrado um diagrama que apresenta o fluxo desde a coleta dos dados (mostrando o posicionamento do paciente em estado de coma) até o processamento e a análise estatística.

**Figura 1 - Diagrama de sequência da coleta, processamento e análise estatística**



Fonte: produzida pela autora

O protocolo de estimulação, para os pacientes em estado de coma, seguiu uma sequência de seis estímulos auditivos com duração de três minutos cada: silêncio, música favorita do paciente, nota Lá contínua, ruído branco, canto gregoriano e a sonata de Mozart K144. Os estímulos foram apresentados em uma única sessão contínua de 20 minutos, intercalados por breves intervalos com sons de conversas humanas. Os áudios foram reproduzidos via laptop e transmitidos por caixas de som posicionadas próximas à cabeça do paciente.

Para o desenvolvimento deste trabalho, foram selecionados dois momentos específicos de interesse: o silêncio inicial e a estimulação musical com a sonata de Mozart K144. O período de silêncio foi utilizado como um ponto de referência fundamental na análise dos sinais de EEG, pois representa a atividade cerebral basal,

livre de estímulos auditivos externos, permitindo assim a comparação direta e confiável com a atividade evocada pelos estímulos musicais. Essa comparação é essencial para isolar as alterações neurais atribuídas à intervenção sonora.

A partir dos períodos de silêncio e de estímulo com Mozart, foram selecionadas, por neurologistas do setor de Neurofisiologia Clínica do HC-UFG, dez épocas de interesse para cada condição. Cada época corresponde a um trecho de 2 segundos do sinal de EEG. No contexto da análise de EEG, uma época é definida como um segmento de tempo no qual o sinal é considerado estacionário, permitindo a aplicação de técnicas de processamento e extração de características específicas. A duração de 2 segundos é considerada adequada para capturar eventos rápidos da atividade elétrica cerebral sem perder resolução temporal.

A seleção das épocas foi realizada com base na experiência clínica, conhecimento técnico e habilidades profissionais dos neurologistas envolvidos. Este processo considerou fatores como a ausência de artefatos, a estabilidade do sinal e a relevância das características elétricas observadas para os objetivos do presente estudo. Assim, os trechos escolhidos representam momentos com potencial para a análise das respostas cerebrais aos estímulos auditivos investigados em pacientes em estado de coma.

### 3.2 QUANTIFICADORES UTILIZADOS

Neste trabalho, além dos quantificadores já empregados por (SILVA, 2025), Porcentagem de Contribuição de Potência (PCP) e Coerência, será analisado também o quantificador Frequência Mediana (FM).

Todos os quantificadores foram aplicados às mesmas bandas cerebrais estabelecidas no estudo de referência: Delta (1–3,5 Hz), Teta (3,5–7,5 Hz), Alfa (7,5–12 Hz), Beta (12–30 Hz), Gama (30–80 Hz), Super Gama (80–100 Hz) e Ruído (58 – 62 Hz). Para a Coerência, foram analisados oito pares simétricos de eletrodos.

## 3.3 ANÁLISE ESTATÍSTICA

### 3.3.1 Desenvolvimento e análise do erro relativo entre plataformas

A acurácia dos resultados obtidos em processamento de sinais EEG é muito importante para o diagnóstico e prognóstico. Com o avanço das ferramentas computacionais, torna-se relevante a comparação entre diferentes meios de processamento, como Python e MATLAB, a fim de validar a consistência e a precisão dos resultados.

Este tópico detalha o desenvolvimento em Python de um algoritmo para o cálculo do erro relativo entre quantificadores derivados de sinais de EEG, especificamente o PCP e a FM. O objetivo principal foi quantificar as discrepâncias entre os valores obtidos a partir do processamento em Python e os de uma referência consolidada em MATLAB. Adicionalmente, este trabalho visa contribuir para a validação da implementação em Python para análises futuras, incluindo a avaliação de pacientes em condições neurológicas críticas, como o coma.

O erro relativo é uma métrica que quantifica a precisão de uma medição ou cálculo em relação ao valor verdadeiro ou de referência. O erro relativo expressa essa diferença como uma proporção do valor real, geralmente em porcentagem e, ao comparar ferramentas como Python e MATLAB para o processamento de sinais de EEG, a análise do erro relativo se torna uma abordagem relevante. Ambas as ferramentas possuem bibliotecas para processamento de sinais (por exemplo, SciPy para Python; *Signal Processing Toolbox* para MATLAB), e a implementação de algoritmos pode diferir, mesmo que de maneira sutil, devido a arredondamentos internos, precisão de ponto flutuante ou abordagens algorítmicas distintas.

#### 3.3.1.1 METODOLOGIA APLICADA

A metodologia de análise do erro relativo envolveu a comparação de dados de EEG processados em duas plataformas distintas: Python e MATLAB. Para tal, na fase inicial de desenvolvimento dessa rotina, foram utilizados conjuntos de dados de exames de EEG de pacientes, incluindo casos normais e comatosos. É importante

ressaltar que o traçado do EEG de um paciente normal e um paciente em estado de coma apresentam diferenças. Em um paciente normal e acordado, o EEG é caracterizado por uma atividade elétrica cerebral organizada e rítmica, com variações de frequência e amplitude dependendo do estado de alerta (ondas alfa, beta, teta e delta em diferentes proporções e padrões)(NIEDERMEYER; LOPES DA SILVA, 2005; TEPLAN, 2002). Já em um paciente em estado de coma, o EEG geralmente mostra uma atividade cerebral difusamente mais lenta e de menor voltagem, predominantemente com ondas teta e delta contínuas, ou até mesmo padrões de supressão de surto (burst suppression), onde há alternância entre períodos de atividade e inatividade, ou uma atividade isoelétrica (linha reta), indicando ausência de atividade elétrica cerebral significativa, o que pode ser um sinal de prognóstico reservado (NIEDERMEYER; LOPES DA SILVA, 2005; YOUNG, 2000).

O foco inicial do desenvolvimento do código de erro relativo consistiu em etapas progressivas, garantindo a funcionalidade da ferramenta antes de sua aplicação final a pacientes em estado de coma. Pacientes nessa condição frequentemente estão em unidades de terapia intensiva (UTIs), cercados por uma multiplicidade de equipamentos médicos vitais e esses dispositivos são fontes potenciais de ruído elétrico (artefatos) que podem contaminar o sinal do EEG. A movimentação de enfermeiros ou outros profissionais, a proximidade de cabos de alimentação e até mesmo a iluminação ambiente podem introduzir artefatos nos dados. A necessidade de monitoramento contínuo aumenta a complexidade de obter um sinal limpo e com melhor qualidade (BRONZINO, 2000).

### **3.3.2 Algoritmo para cálculo do erro relativo**

Inicialmente, o processo de desenvolvimento do código de erro relativo focou na comparação entre diferentes arquivos .pkl gerados em Python, realizando a comparação inicialmente, entre as variáveis PCP e FM. Esta etapa preliminar foi essencial para depurar a lógica do cálculo e garantir a funcionalidade básica do algoritmo antes de introduzir a complexidade da comparação interplataformas.

Posteriormente, o algoritmo foi estendido para calcular o erro relativo entre os resultados obtidos em Python (arquivos .pkl) e os resultados de referência obtidos em

MATLAB (arquivos .mat). Esta transição exigiu a adaptação do código para lidar com os diferentes formatos de arquivo e estruturas de dados.

O cálculo do erro relativo (Equação 6) foi implementado para duas variáveis importantes no processamento de EEG: Percentual de Contribuição de Potência e Frequência Mediana. O erro relativo é uma métrica que expressa a diferença entre um valor medido e um valor de referência em proporção ao valor de referência, onde o primeiro é o resultado obtido por uma das ferramentas de programação (para este trabalho, Python) para a variável em questão (Percentual de Contribuição de Potência ou Frequência Mediana) e, o valor de referência representa o valor considerado mais preciso (para este trabalho, MATLAB), que é usado como base para comparação.

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

Onde:

- Err - Erro relativo
- Vcalc - Valor calculado
- Vesper - Valor esperado

Neste contexto, a matriz1 (vinda do MATLAB) é considerada a "verdade" ou referência, e a matriz2 (vinda do Python) é considerada a "estimativa".

A base para o cálculo do erro relativo foi a função “relative\_error”, apresentada no arquivo “relative\_error.py” (ANEXO A). Esta função foi projetada para quantificar a discrepância entre duas matrizes de dados, representando os valores de uma mesma variável obtidos de diferentes fontes (neste caso, MATLAB e Python). O algoritmo da função “relative\_error” pode ser detalhado nos seguintes passos:

- 1. Verificação de Formato:** A função primeiramente verifica se as duas matrizes de entrada (matriz1 e matriz2) possuem o mesmo formato (*shape*). Esta é uma etapa que garante que a comparação elemento a elemento seja semanticamente válida e evitar erros dimensionais.

2. **Tratamento de Valores Especiais:** Para evitar divisões por zero ou resultados indefinidos, a função lida com valores NaN (*Not a Number*) e Inf (*Infinito*) presentes nas matrizes são substituídos por um valor NEAR\_ZERO ( $1 \times 10^{-10}$ ), que é uma constante definida para representar um valor muito pequeno, mas não exatamente zero.
3. **Substituição de Valores Próximos de Zero:** Além do tratamento de NaN e Inf, a função também substitui qualquer valor em ambas as matrizes que esteja muito próximo de zero (definido por NEAR\_ZERO) pelo próprio NEAR\_ZERO. Isso é feito para evitar instabilidades numéricas no cálculo do erro relativo, onde um divisor muito pequeno poderia levar a erros muito grandes.
4. **Cálculo do Erro Relativo:** O erro relativo é calculado elemento a elemento utilizando a Equação 6.
5. **Identificação do Maior Erro e Posição:** Após o cálculo da matriz de erros relativos, a função encontra o maior erro relativo presente nessa matriz.

A função “max\_relative\_error” (vide ANEXO B) é responsável por integrar essa funcionalidade, chamando a função “relative\_error” e realizando as etapas de carregamento dos dados dos arquivos .pkl e .mat. A rotina “max\_relative\_error” também mapeia os índices numéricos da posição do erro para rótulos descritivos (ex: “Banda 'Delta'”, “Época 1”, “Eletrodo 1”). A integridade da função “max\_relative\_error” é garantida por meio de um *assert* que verifica se o quantificador é ‘PCP’ ou ‘FM’, e por um bloco *try-except* que captura possíveis erros durante o processamento dos arquivos.

### 3.3.3 Processamento e análise dos dados

Para a análise do PCP e FM, o script “relative\_error\_by\_quantifier” (vide ANEXO C) recebe um arquivo CSV como parâmetro de entrada, sendo composto por duas colunas, onde a primeira coluna representa os arquivos Python (.pkl) e a segunda representa os arquivos Matlab (.mat) e cada linha representa um par .pkl/.mat a ser comparado. Além disso, foram criados dois arquivos CSV, um para processar 21 arquivos do momento da estimulação musical com ‘Mozart’ e, de forma análoga, criou-se também outro para comparação do momento ‘silêncio’, também com

21 pares de itens. As colunas com arquivos .mat de ambos os arquivos CSV consiste na base de dados completa de SILVA 2025. Os arquivos utilizados para a comparação foram nomeados com um prefixo ‘s’ simbolizando os dados do momento ‘silêncio’, seguido de uma numeração sequencial 1 a 21, e por fim da extensão do arquivo que identifica de qual plataforma ele foi processado (ex: s1.pkl a s21.pkl). De forma semelhante adotou-se o prefixo ‘m’ representando os dados da estimulação musical de ‘Mozart’ (ex: m1.mat a m21.mat). Para cada par de arquivos (ex: s1.pkl e s1.mat), que representa um exame de EEG, a função “max\_relative\_error” é chamada com o *quantifier\_name* ('PCP' ou 'FM') para determinar o maior erro relativo.

O arquivo CSV gerado pela função “relative\_error\_by\_quantifier” é nomeado seguindo o seguinte padrão: “maiores\_erros\_{*quantifier\_name*}\_{*file\_input\_base\_name*}.csv”, onde o “*quantifier\_name*” será substituído pelo nome do quantificador analisado ('PCP' ou 'FM') e o “*file\_input\_base\_name*” será substituído pelo nome do momento analisado ('silêncio' ou 'mozart'). Esse arquivo contém uma análise detalhada de erros relativos em que cada linha representa os resultados de um par específico de arquivos .pkl e .mat processados a partir do CSV de entrada (exemplo no ANEXO D). O arquivo de saída inclui seis colunas: “Nome Arquivo PKL”, “Nome Arquivo MAT”, “Maior Erro Relativo”, “Época”, “Eletrodo” e “Banda de Frequência”, exemplo contido no ANEXO E.

Além disso, a rotina programada identifica e exibe o maior erro global do quantificador (PCP ou FM) encontrado entre todos os exames processados, juntamente com sua localização detalhada (banda de frequência, época e eletrodo) e o nome do par de arquivos correspondente, exemplos apresentados no item 4.1.

A base dos caminhos para os arquivos .pkl e .mat é configurada a partir do diretório do arquivo CSV de entrada (*input\_csv\_path*), que por sua vez contém os nomes dos arquivos a serem comparados, como no exemplo do ANEXO D.

### 3.4 IDENTIFICAÇÃO E DESCRIÇÃO DAS VARIÁVEIS DE ENTRADA E SAÍDA DOS CÓDIGOS

A Tabela 1 abaixo detalha as variáveis de entrada utilizadas pelas funções desenvolvidas para análise estatística. Ela organiza as informações pelos nomes dos anexos, pelo nome de cada variável de entrada presente em cada anexo e suas respectivas descrições.

**Tabela 1 - Identificação e descrição das variáveis de entrada das funções desenvolvidas e seu respectivo ANEXO**

Anexo	Variável de entrada	Descrição
<b>A</b> <b>relative_error.py</b>	matriz1	matriz de escalares, para este estudo com formato de 21x10x7 (21 exames, 10 épocas e 7 bandas de frequência)
	matriz2	matriz de escalares com a mesma dimensão da matriz1
<b>B</b> <b>max_relative_error.py</b>	pkl_path	texto com o caminho do arquivo .pkl
	mat_path	texto com o caminho do arquivo .mat
	quantifier_name	texto definindo o quantificador que será analisado 'PCP' ou 'FM'
<b>C</b> <b>relative_error_quantifier.py</b>	results	lista de tupla, cada tupla com 6 itens cada (Nome Arquivo PKL, Nome Arquivo MAT, Maior Erro Relativo, Época, Eletrodo e Banda de Frequência)
	file_name	texto que representa o nome do arquivo CSV de saída
	file_path	variável da função "extract_name_files_for_comparation_by_csv" que é um texto que indica o caminho do CSV de entrada
	quantifier_name	texto com o nome do quantificador a ser analisado ('PCP' ou 'FM')
	input_csv_path	Variável da função "relative_error_by_quantifier" que é um texto que indica o caminho do CSV de entrada que contém os pares de arquivos .pkl e .mat a serem analisados

Já a Tabela 2 apresenta as variáveis de saída geradas pelas funções desenvolvidas para análise estatística. Ela está organizada igual à tabela anterior, mostrando as informações pelos nomes dos anexos, pelo nome de cada variável de saída presente em cada anexo e suas respectivas descrições.

**Tabela 2 - Identificação e descrição das variáveis de saída das funções desenvolvidas e seu respectivo ANEXO**

Anexo	Variável de saída	Descrição
<b>A</b> <b>relative_error.py</b>	relative_error	matriz de escalares, para este estudo com formato de 21x10x7 (21 exames, 10 épocas e 7 bandas de frequência)
	max_error	número real que representa o maior erro relativo encontrado
	position_max_error	é um vetor tridimensional que indica a posição do maior erro (banda de frequência, eletrodo e época)
<b>B</b> <b>max_relative_error.py</b>	max_error	número real que representa o maior erro relativo encontrado
	error_position	dicionário contendo as informações de onde está localizado o maior erro: eletrodo, época e banda de frequência
<b>C</b> <b>relative_error_quantifier.py</b>	maiores_erros_{quantifier_name}_{file_input_base_name}.csv	padrão de nome do arquivo CSV que é gerado com os valores e a posição do maior erro relativo de cada exame
	data (dados)	uma lista de dicionários onde cada dicionário representa um par de arquivos .pkl/.mat pelas variáveis 'pkl_file_name' e 'mat_file_name'
	final_result	texto impresso no console com as seguintes informações: O maior erro relativo global; A localização completa do maior erro global (banda de frequência, época e eletrodo); Os nomes dos arquivos (MAT e PKL) que representam o par onde ocorreu o maior erro global; E uma mensagem informando que o arquivo CSV com os maiores erros de todos os exames foi salvo

### 3.5 QUANTIFICAÇÃO DA ATIVIDADE CEREBRAL (MOZART X SILÊNCIO)

Em busca de comparar os dois estímulos, realizou-se a média dos quantificadores PCP e FM para cada um desses momentos. Os quantificadores extraídos para cada exame compõem de uma matriz com dimensão tridimensional igual a 20x10x6, representando um valor para cada um dos 20 canais de eletrodos, 10 épocas e 6 bandas de frequência. Nesse contexto, ao considerar todos os exames tem-se uma matriz tridimensional igual a 20x210x6, onde o 210 se trata dos 21 exames multiplicados pelas 10 épocas que os compõem, e ao realizar a média por eletrodo e banda de frequência essa matriz se reduz a uma dimensão igual a 20x6.

Vale ressaltar, que para essas análises de média não foi considerado o ‘Ruído’ por isso, para essas avaliações se trata de 6 bandas de frequência, sendo elas a Delta, Teta, Alfa, Beta, Gama e Super Gama. Os mesmos dados utilizados para cálculo do erro relativo também foram replicados para gerar topografias e tabelas com as médias dos quantificadores PCP e FM. Diante disso, essas médias foram calculadas separadamente para cada estimulação. Sendo assim, foram considerados 21 exames para a estimulação de ‘silêncio’ e 21 exames para a estimulação de ‘Mozart’ e cada um desses exames contendo 10 épocas e todas as coletas foram realizadas utilizando 20 canais.

Com isso, os resultados das médias para cada quantificador e durante cada estímulo foram tabelados. Para organização das tabelas tem-se uma coluna destinada a identificar os canais, portanto, nela estão contidos os nomes dos 20 canais de eletrodos (FP1, FP2, F7, F3, FZ, F4, F8, T3, C3, CZ, C4, T4, T5, P3, PZ, P4, T6, O1, OZ e O2) e outras seis colunas sendo uma para cada banda de frequência. Assim, obteve-se 4 tabelas como resultado dessa análise, sendo que cada uma foi preenchida com 120 valores de média, em que um valor correspondente a cada canal e ritmo cerebral. E, após essa organização, gerou-se também resultados em forma de mapas topográficos a fim de realizar uma avaliação mais completa e identificar as áreas cerebrais mais ativas em cada uma dessas avaliações separadamente, ou seja, para cada quantificador, em cada estimulação e para cada ritmo cerebral.

## CAPÍTULO 4 - RESULTADOS E DISCUSSÃO

Este capítulo apresenta os desfechos detalhados do processamento e da análise comparativa dos sinais eletroencefalográficos (EEG) de pacientes comatosos. Serão abordados os resultados da validação das implementações em Python frente ao MATLAB para os quantificadores Frequência Mediana (FM) e Porcentagem de Contribuição de Potência (PCP), bem como a análise da coerência na faixa de frequência delta, ilustrando as similaridades e as discrepâncias observadas entre as plataformas.

### 4.1 RESULTADOS DA COMPARAÇÃO ENTRE PYTHON E MATLAB

Para a análise comparativa entre as duas plataformas, a primeira análise foi em cima do quantificador PCP na estimulação de ‘silêncio’ e ‘Mozart’, no qual nos dois blocos abaixo pode-se visualizar as saídas do console ao executar a função “relative\_error\_by\_quantifier” para este quantificador em cada um desses momentos da estimulação. Destaca-se que os maiores erros encontrados tanto para ‘silêncio’ quanto para ‘Mozart’ estão na casa de  $10^{-13}$ . Ressalta-se ainda que as saídas dos blocos abaixo referentes ao quantificador PCP estão descritas na Tabela 3 e na Tabela 4.

A partir disso, a Tabela 3 abaixo apresenta os resultados do erro relativo para o quantificador PCP para a estimulação de ‘silêncio’. Para este conjunto de informações, observou-se que o erro relativo máximo é  $8,36886 \times 10^{-13}$  e o mínimo é  $4,07559 \times 10^{-13}$ . A Tabela 3 exibe os nomes dos arquivos PKL e MAT analisados, assim como o maior erro relativo encontrado, a época em que o erro foi registrado, o eletrodo envolvido e a banda de frequência identificada.

**Tabela 3 - Resultados dos maiores erros relativos e suas respectivas posições para o quantificador PCP no momento 'silêncio'**

Nome Arquivo PKL	Nome Arquivo MAT	Maior Erro Relativo	Época	Eletrodo	Banda de Frequência
s1.pkl	s1.mat	5,77815E-13	7	7	supergama
s2.pkl	s2.mat	6,0642E-13	6	3	supergama
s3.pkl	s3.mat	5,21553E-13	9	1	supergama
s4.pkl	s4.mat	5,42855E-13	4	19	supergama
s5.pkl	s5.mat	5,18147E-13	7	1	supergama
s6.pkl	s6.mat	5,42044E-13	5	15	supergama
s7.pkl	s7.mat	5,76531E-13	1	10	supergama
s8.pkl	s8.mat	5,40345E-13	3	10	supergama
s9.pkl	s9.mat	5,39717E-13	1	1	supergama
s10.pkl	s10.mat	4,07559E-13	8	2	supergama
s11.pkl	s11.mat	4,66358E-13	8	19	supergama
s12.pkl	s12.mat	5,52943E-13	2	17	supergama
s13.pkl	s13.mat	4,13834E-13	9	1	supergama
s14.pkl	s14.mat	7,68432E-13	2	0	ruido
s15.pkl	s15.mat	7,22405E-13	0	7	supergama
s16.pkl	s16.mat	6,39013E-13	1	18	supergama
s17.pkl	s17.mat	6,34148E-13	2	0	supergama
s18.pkl	s18.mat	6,19808E-13	9	18	supergama
s19.pkl	s19.mat	5,12236E-13	1	0	supergama
s20.pkl	s20.mat	4,44282E-13	9	2	supergama
s21.pkl	s21.mat	8,36886E-13	9	0	supergama

Analisando a Tabela 3 percebe-se que os maiores erros de encontram na banda de frequência "supergama" na maioria dos registros, visto que é a faixa que possui o maior range de frequências, com uma única ocorrência de "ruído" (no par de arquivos s14.pkl/s14.mat), que sugere uma resposta consistente do quantificador. A rotina ao final da execução exibiu o resultado apresentado a seguir:

```
Iniciando análise PCP...
---
Resultado Global (PCP - Silence):
Maior erro relativo: 8.3688577269e-13
Localização: Banda 'supergama', Época 9, Eletrodo 0
No par de arquivos: s21.pkl (.pkl) / s21.mat (.mat)
Tabela 'maiores_erros_PCP_silence.csv' salva!
---
```

De forma análoga, a Tabela 4 exibe os dados do CSV obtido a partir da análise do quantificador PCP na estimulação de ‘Mozart’. Para esse conjunto de dados, extraiu-se que o maior erro relativo é  $9,09861 \times 10^{-13}$  e o menor é  $3,03506 \times 10^{-13}$ .

**Tabela 4 - Resultados dos maiores erros relativos e suas respectivas posições para o quantificador PCP no momento 'Mozart'**

Nome Arquivo PKL	Nome Arquivo MAT	Maior Erro Relativo	Época	Eletrodo	Banda de Frequência
m1.pkl	m1.mat	5,1465E-13	2	11	supergama
m2.pkl	m2.mat	5,36223E-13	6	16	supergama
m3.pkl	m3.mat	4,36346E-13	9	18	supergama
m4.pkl	m4.mat	5,20462E-13	3	4	supergama
m5.pkl	m5.mat	4,32006E-13	6	8	supergama
m6.pkl	m6.mat	5,45722E-13	6	6	supergama
m7.pkl	m7.mat	5,30521E-13	4	16	supergama
m8.pkl	m8.mat	5,71683E-13	0	8	supergama
m9.pkl	m9.mat	3,03506E-13	7	7	supergama
m10.pkl	m10.mat	4,91215E-13	8	1	supergama
m11.pkl	m11.mat	5,78787E-13	4	7	supergama
m12.pkl	m12.mat	5,53992E-13	8	16	supergama
m13.pkl	m13.mat	4,86158E-13	9	16	supergama
m14.pkl	m14.mat	9,09861E-13	3	3	ruido
m15.pkl	m15.mat	5,75989E-13	5	6	supergama
m16.pkl	m16.mat	5,67835E-13	9	2	supergama
m17.pkl	m17.mat	5,08806E-13	9	5	ruido
m18.pkl	m18.mat	5,87065E-13	7	18	supergama
m19.pkl	m19.mat	5,06028E-13	4	2	supergama
m20.pkl	m20.mat	5,38657E-13	1	19	supergama
m21.pkl	m21.mat	6,68328E-13	4	19	supergama

A Tabela 4 apresentada anteriormente, evidencia mais uma vez que os maiores erros se encontram na banda de frequência “supergama” na maioria das entradas, com exceções pontuais de “ruído” nos pares de arquivos m14.pkl/m14.mat e m17.pkl/m17.mat. Ao final deste processamento, o resultado exibido é representado abaixo:

```
Iniciando análise PCP...

---
Resultado Global (PCP - Mozart):
Maior erro relativo: 9.0986143411e-13
Localização: Banda 'ruído', Época 3, Eletrodo 3
No par de arquivos: m14.pkl (.pkl) / m14.mat (.mat)
Tabela 'maiores_erros_PCP_mozart.csv' salva!

---
```

Diante do conjunto de dados apresentados anteriormente, para o quantificador PCP, a maioria dos arquivos demonstrou que os maiores erros se concentram na banda "supergama", com exceções pontuais nos registros 'm14.mat', 'm17.mat' (ambos no momento "mozart") e 's14.mat' (no momento "silêncio"), que indicaram a banda "ruído".

Dando sequência à análise comparativa, o mesmo procedimento foi aplicado ao quantificador FM durante a estimulação de 'silêncio' e 'Mozart'. Nos blocos subsequentes, podem ser visualizadas as saídas do console ao executar a função "relative\_error\_by\_quantifier" para este quantificador. Nota-se que os erros mais significativos encontrados tanto para 'silêncio' quanto para 'Mozart', estão na casa de  $10^{-14}$ . Ressalta-se também que as saídas referentes ao quantificador FM, apresentadas abaixo, estão descritas na Tabela 5 e Tabela 6.

Nesse contexto, na Tabela 5 são detalhados os resultados de erro relativo ao comparar as duas plataformas para o quantificador FM durante a estimulação de 'silêncio'. Para este caso, obtém-se que o erro relativo máximo é  $5,20049 \times 10^{-14}$  e o mínimo é  $1,73095 \times 10^{-14}$ , exibindo as informações dos pares de arquivos .pkl/.mat, seus maiores erros relativos e suas respectivas posições.

**Tabela 5 - Resultados dos maiores erros relativos e suas respectivas posições para o quantificador FM no momento 'silêncio'**

Nome Arquivo PKL	Nome Arquivo MAT	Maior Erro Relativo	Época	Eletrodo	Banda de Frequência
s1.pkl	s1.mat	3,60451E-14	1	3	supergama
s2.pkl	s2.mat	4,13224E-14	6	0	supergama
s3.pkl	s3.mat	3,69879E-14	5	19	supergama

s4.pkl	s4.mat	2,56012E-14	2	18	supergama
s5.pkl	s5.mat	3,89204E-14	2	10	supergama
s6.pkl	s6.mat	3,87638E-14	9	7	supergama
s7.pkl	s7.mat	3,57196E-14	9	12	supergama
s8.pkl	s8.mat	2,59377E-14	3	10	supergama
s9.pkl	s9.mat	2,99646E-14	0	11	supergama
s10.pkl	s10.mat	2,62214E-14	9	7	supergama
s11.pkl	s11.mat	3,2675E-14	3	16	supergama
s12.pkl	s12.mat	2,91396E-14	5	16	supergama
s13.pkl	s13.mat	2,30306E-14	1	18	supergama
s14.pkl	s14.mat	2,21936E-14	1	1	gama
s15.pkl	s15.mat	4,36831E-14	0	4	supergama
s16.pkl	s16.mat	3,62742E-14	9	17	supergama
s17.pkl	s17.mat	2,71916E-14	5	13	supergama
s18.pkl	s18.mat	4,40906E-14	7	6	supergama
s19.pkl	s19.mat	1,73095E-14	1	0	supergama
s20.pkl	s20.mat	2,86465E-14	3	1	supergama
s21.pkl	s21.mat	5,20049E-14	9	0	supergama

Em síntese, a Tabela 5 acima apresenta novamente a consistência da banda de frequência "supergama" para os maiores erros. O resultado obtido após essa execução está demonstrado abaixo:

```
Iniciando análise FM...
---
Resultado Global (FM - Silence):
Maior erro relativo: 5.2004948658e-14
Localização: Banda 'supergama', Época 9, Eletrodo 0
No par de arquivos: s21.pkl (.pkl) / s21.mat (.mat)
Tabela 'maiores_erros_FM_silence.csv' salva!
---
```

De forma semelhante, a Tabela 6 apresenta os resultados obtidos do arquivo CSV gerado para comparação das plataformas para o estímulo 'Mozart' e quantificador FM. O qual evidencia-se que o maior erro relativo é  $5,16091 \times 10^{-14}$  e o menor é  $8,5765 \times 10^{-15}$ , sendo mantida a mesma organização descrita anteriormente.

**Tabela 6 - Resultados dos maiores erros relativos e suas respectivas posições para o quantificador FM no momento 'Mozart'**

Nome Arquivo PKL	Nome Arquivo MAT	Maior Erro Relativo	Época	Eletrodo	Banda de Frequência
m1.pkl	m1.mat	3,60361E-14	9	9	supergama
m2.pkl	m2.mat	3,65138E-14	2	0	supergama
m3.pkl	m3.mat	1,95112E-14	6	8	supergama
m4.pkl	m4.mat	3,12353E-14	2	19	supergama
m5.pkl	m5.mat	2,35408E-14	1	0	supergama
m6.pkl	m6.mat	4,27421E-14	1	5	supergama
m7.pkl	m7.mat	2,89708E-14	5	14	supergama
m8.pkl	m8.mat	4,01885E-14	7	6	supergama
m9.pkl	m9.mat	8,5765E-15	3	19	supergama
m10.pkl	m10.mat	3,36357E-14	9	0	supergama
m11.pkl	m11.mat	2,70218E-14	0	13	supergama
m12.pkl	m12.mat	1,8189E-14	8	16	supergama
m13.pkl	m13.mat	3,71507E-14	8	16	supergama
m14.pkl	m14.mat	3,71971E-14	5	12	supergama
m15.pkl	m15.mat	4,05806E-14	3	18	supergama
m16.pkl	m16.mat	3,41159E-14	6	7	supergama
m17.pkl	m17.mat	2,91753E-14	1	7	supergama
m18.pkl	m18.mat	4,44396E-14	1	18	supergama
m19.pkl	m19.mat	2,41764E-14	4	2	supergama
m20.pkl	m20.mat	3,99948E-14	9	19	supergama
m21.pkl	m21.mat	5,16091E-14	5	2	supergama

Os resultados acima indicam a predominância do maior erro relativo na banda de frequência "supergama" em todas as análises. Essa rotina, ao final de sua execução, gerou o resultado a seguir:

```
Iniciando análise FM...

---
Resultado Global (FM - Mozart):
Maior erro relativo: 5.1609147017e-14
Localização: Banda 'supergama', Época 5, Eletrodo 2
No par de arquivos: m21.pkl (.pkl) / m21.mat (.mat)
Tabela 'maiores_erros_FM_mozart.csv' salva!

---
```

Assim, para o quantificador FM, todos os arquivos analisados (de 's1' a 's21' para "silêncio" e de 'm1' a 'm21' para "mozart") apresentaram resultados de maiores

erros relativos predominantemente na banda "supergama", com uma única exceção no registro 's14.mat' (no momento "silêncio") que indicou a banda "gama".

Por fim, as análises comparativas entre MATLAB e Python para os quantificadores FM e PCP em sinais de EEG de pacientes comatosos, durante os períodos de 'silêncio' e 'Mozart', revelaram consistentemente erros relativos extremamente baixos. Para o quantificador FM, os erros situaram-se na ordem de  $10^{-14}$  a  $10^{-15}$ . Para o PCP, os erros foram da ordem de  $10^{-13}$ . Estes desfechos demonstram uma alta concordância entre as plataformas de Python e MATLAB, reforçando a reproduzibilidade dos métodos de processamento para ambos os quantificadores.

A análise desses resultados permite:

- **Quantificar a magnitude dos erros relativos:** Valores baixos (ex:  $8.3688577269 \times 10^{-13}$  e  $5.1609147017 \times 10^{-14}$ ) indicam uma alta concordância entre as implementações em Python e MATLAB, validando o fluxo em Python.
- **Identificar as épocas, bandas e eletrodos mais propensos a divergências entre as plataformas:** Esta informação é importante para uma depuração e otimização futuras do código, caso haja discrepâncias significativas.

## 4.2 RESULTADOS COMPARATIVOS DO QUANTIFICADOR DE COERÊNCIA

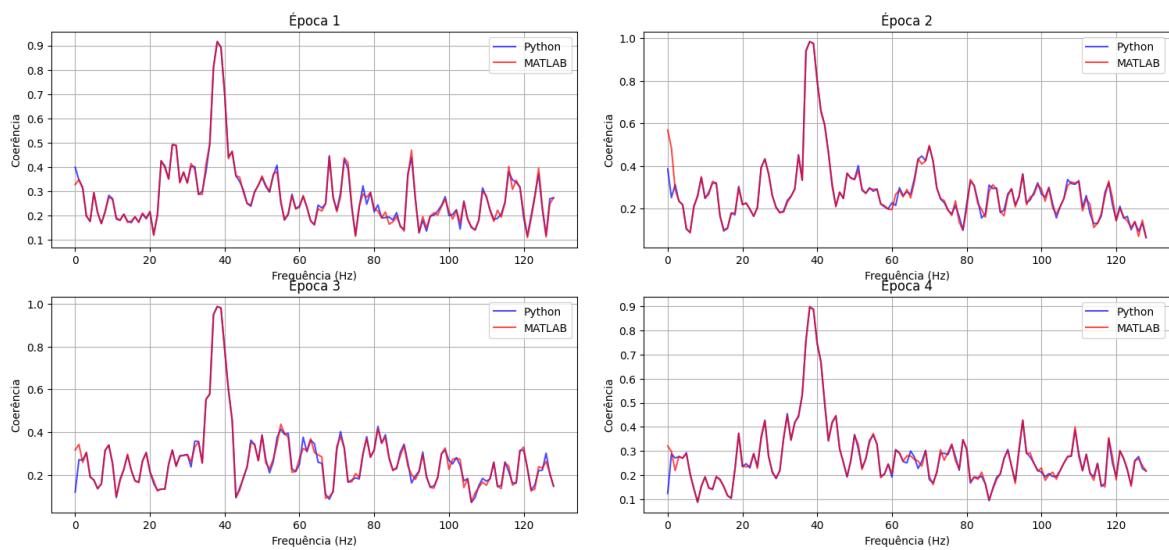
O intuito inicial era realizar as mesmas análises aplicadas aos quantificadores PCP e FM porém, após a obtenção dos primeiros dados de erro relativo para o quantificador de Coerência observou-se valores significativamente altos durante essa análise. Esse desvio, que se deve às diferenças fundamentais nos algoritmos e nas funções utilizadas pelas duas plataformas de análise, Python e MATLAB, demandou uma mudança na abordagem metodológica.

Isso implica que o impacto de parâmetros divergentes (como janelamento, sobreposição, comprimento da FFT) ou implementações algorítmicas pode ser mais pronunciado na presença de certas características do sinal, como níveis de ruído específicos, morfologia do sinal, ou distribuição de potência dentro da banda delta. Essa variabilidade desafia uma simples declaração de que "Python é diferente de MATLAB" e exige uma investigação mais aprofundada sobre as condições específicas que levam a essas diferenças.

Diante disso, para assegurar uma avaliação mais precisa e representativa do quantificador de Coerência, a análise foi reformulada, permitindo uma análise gráfica da qual faixa de frequência ocorre as maiores discrepâncias entre as plataformas analisadas.

Nesta abordagem, primeiramente plotou-se o gráfico da Coerência de ambas as plataformas, para compreender em qual momento as duas mais se divergiam. Com isso, obteve-se os primeiros gráficos dos valores de Coerência para Python e MATLAB utilizando o par de arquivos s1.pkl/s1.mat referente à estimulação de 'silêncio'. A Figura 2 ilustra essa primeira abordagem, onde o eixo X representando as 129 frequências e o eixo Y indicando o valor do quantificador de Coerência, sendo a linha vermelha identificando os valores de Coerência da plataforma MATLAB e a azul do Python.

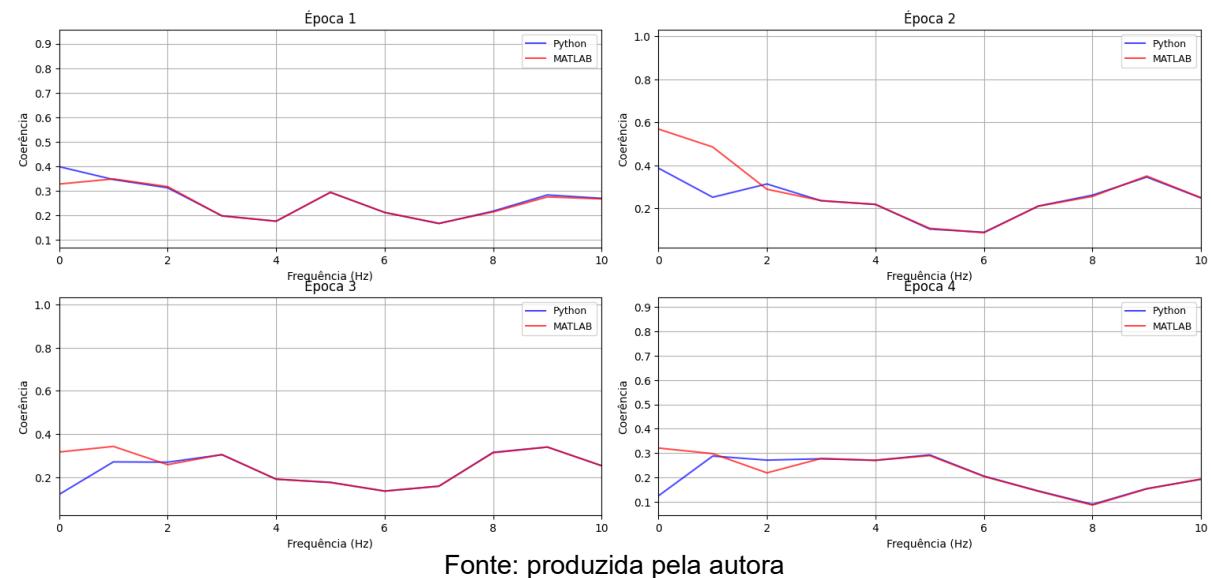
**Figura 2 - Gráficos com valores de Coerência de 0 a 129 Hz para as épocas de 1 a 4 no momento 'silêncio'**



Fonte: produzida pela autora

Observando os gráficos anteriores percebe-se que a maior divergência se encontra nas frequências iniciais de 0 a 10 Hz. Com isso, para melhor visualização, a próxima estratégia foi obter novos gráficos com o mesmo exame, porém, na faixa de frequência de 0 a 10 Hz que pode ser visualizado na Figura 3.

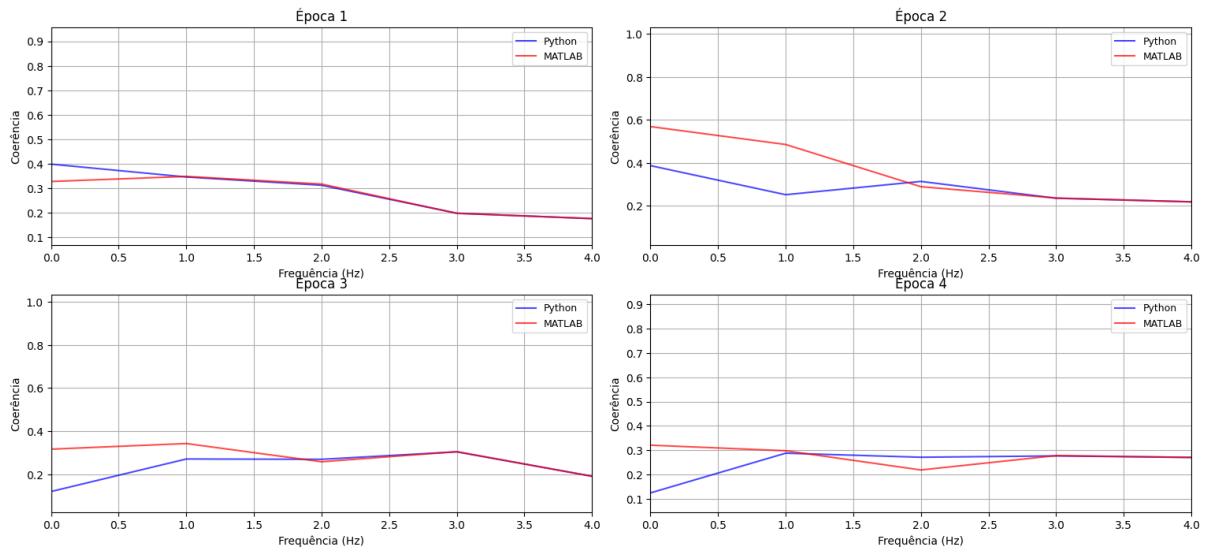
**Figura 3 - Gráficos com valores de Coerência de 0 a 10 Hz para as épocas de 1 a 4 no momento 'silêncio'**



Fonte: produzida pela autora

Mesmo reduzindo a faixa de frequência analisada, observou-se que as grandes variações estavam concentradas abaixo de 5 Hz. Assim, a próxima e última abordagem concentrou-se em extraír gráficos para o mesmo exame, mas na faixa de 0 a 4 Hz. A seguir na Figura 4 apresenta graficamente os valores do quantificador de Coerência na faixa de frequência de 0 a 4 Hz e para as épocas de 1 a 4. Esses resultados foram extraídos do par de arquivos s1.pkl/s1.mat da estimulação de ‘silêncio’.

**Figura 4 - Épocas de 1 a 4 da Coerência de 0 a 4 Hz**

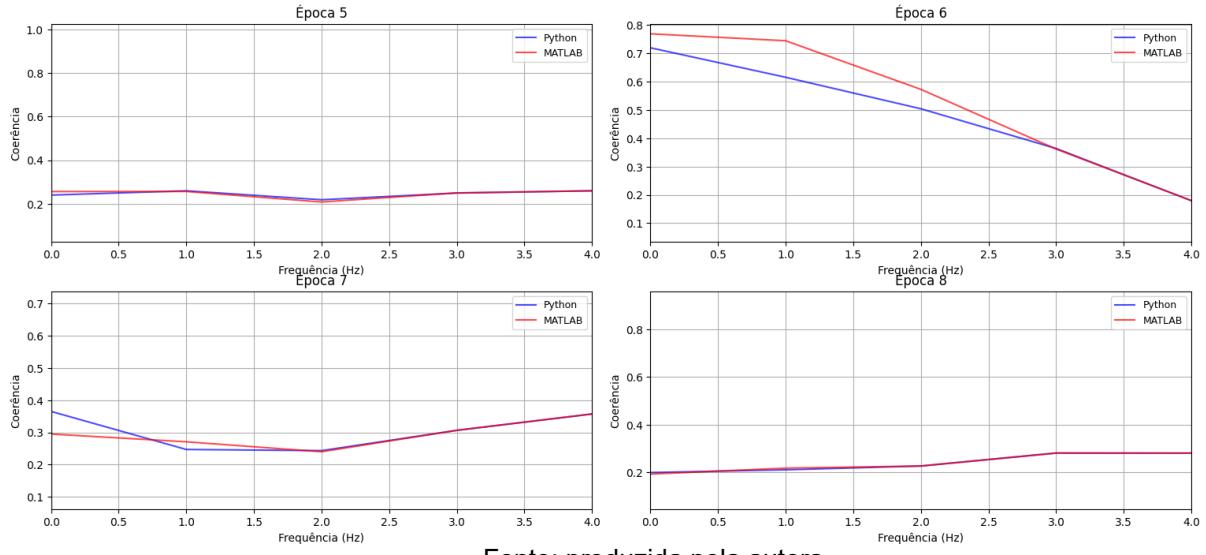


Fonte: produzida pela autora

Analizando as informações acima é possível observar que as variações entre as plataformas estão concentradas abaixo de 3 Hz e que o máximo valor de Coerência para o MATLAB está na época 2 enquanto para o Python está na Época 1, já os mínimos valores de Coerência para ambas as plataformas estão na Época 4.

Em continuidade, os gráficos da Figura 5, vem da mesma base da Figura 4 porém, apresentando os resultados para as épocas subsequentes, de 5 a 8 e mantendo a faixa de frequência de 0 a 4 Hz.

**Figura 5 - Épocas de 5 a 8 da Coerência de 0 a 4 Hz**

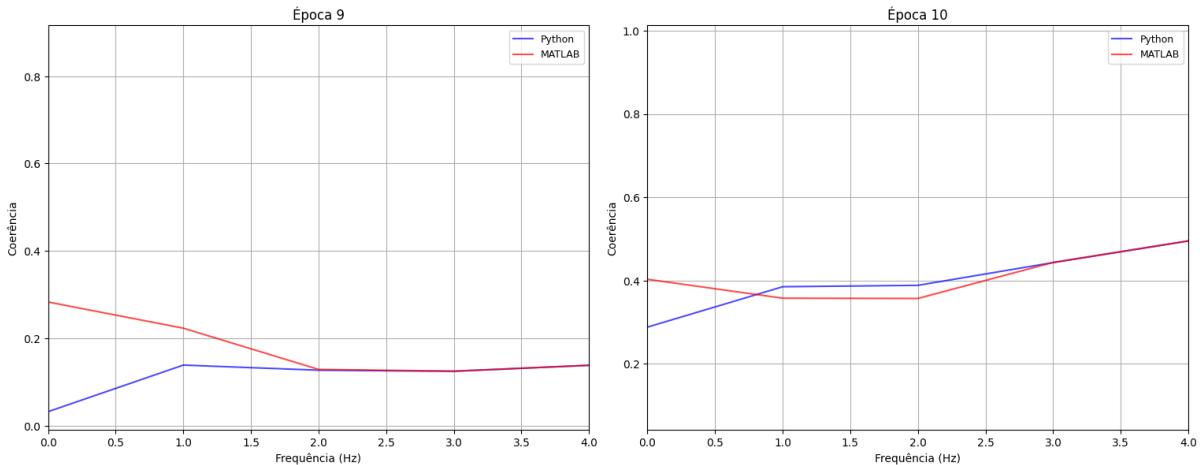


Fonte: produzida pela autora

Esse novo conjunto de gráfico referentes às épocas de 5 a 8 reafirmam que as variações ocorrem abaixo de 3 Hz. Entre essas épocas, os maiores valores de Coerência tanto do MATLAB quanto do Python estão na Época 6, já os menores valores de ambos estão na Época 8.

Por fim, os resultados da Figura 6, segue a mesma analogia e finalizam apresentando as representações gráficas das últimas épocas, a 9 e a 10.

**Figura 6 - Épocas 9 e 10 da Coerência de 0 a 4 Hz**



Fonte: produzida pela autora

As informações extraídas demonstram uma maior variabilidade entre as plataformas para a Coerência com frequências abaixo de 3 Hz. Entre a Época 9 e a Época 10, o valor máximo desse quantificador tanto para o MATLAB quanto para o Python está na Época 10, indicando que os menores valores de Coerência para ambas as plataformas se encontram na Época 9.

Em síntese, nas épocas analisadas na última abordagem (de 0 a 4 Hz), a coerência exibiu uma variação predominante entre 0.1 e 0.5, com picos ocasionais que atingiram valores mais elevados na Época 2 e na Época 6. A discrepância visível entre os resultados de Python e MATLAB, principalmente nas frequências iniciais (abaixo de 4 Hz), se deve aos diferentes algoritmos de processamento e janelamento de sinal utilizados em cada plataforma. Após esse trecho de baixas frequências, as linhas que representam os valores de Coerência para o MATLAB e o Python se sobrepõem, o que pode ser visualizado mais claramente na Figura 3.

#### 4.3 ANÁLISE SINAL ESTIMULAÇÃO MOZART X SILÊNCIO

Para aprofundar a análise dos efeitos de diferentes estimulações em pacientes em estado de coma, foi realizada a análise de médias extraídas dos quantificadores PCP e FM para cada eletrodo e banda de frequência (Delta, Teta, Alfa, Beta, Gama e

Super Gama). Para o cálculo dessas médias, foram considerados os 21 arquivos de dados, separando-se as estimulações de 'silêncio' e 'Mozart' para análise individual de cada momento.

A Tabela 7 compila as médias do quantificador PCP por eletrodo e por banda de frequência na condição basal de silêncio. Além disso, também apresenta os maiores e menores valores de média em cada ritmo cerebral.

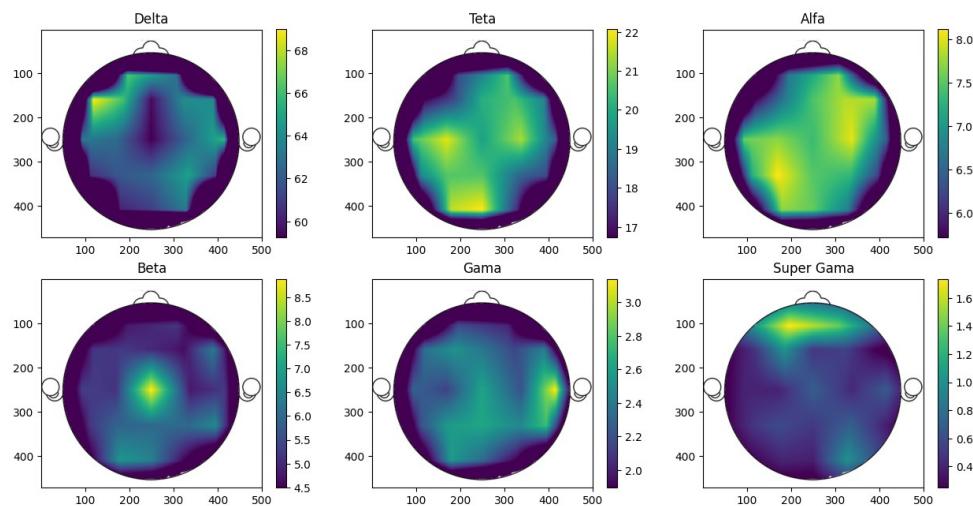
**Tabela 7 - Média de PCP por época e eletrodo para o momento 'silêncio'**

Eletrodo	Delta	Teta	Alfa	Beta	Gama	Supergama
FP1	66,24267	17,96084	6,716962	4,804716	2,190056	1,733787
FP2	62,8228	20,58722	7,717013	5,171186	2,024707	1,389782
F7	68,98132	16,72572	5,720661	5,190171	2,354301	0,477797
F3	66,17547	17,92764	6,724231	5,227691	2,53672	1,011987
FZ	59,53906	20,10011	7,453536	5,03268	2,393672	0,486337
F4	64,08462	20,56733	7,857176	4,669252	2,165395	0,543651
F8	63,90716	19,18843	7,816419	6,287352	2,438582	0,250438
T3	63,25915	20,51799	7,571704	5,333876	2,295107	0,395305
C3	62,65682	21,83313	7,709983	5,132844	2,149207	0,389144
CZ	59,2444	19,79959	7,364351	8,883166	2,622324	0,692386
C4	62,69622	21,38501	8,026357	4,799887	2,221555	0,424218
T4	65,69772	18,40962	6,491742	5,233306	3,137452	0,674362
T5	60,59174	19,31195	7,25555	5,232556	2,21545	0,478362
P3	61,7976	20,64782	8,118018	5,896805	2,56557	0,591721
PZ	62,4827	20,65098	7,487693	5,980055	2,628793	0,496446
P4	64,8275	18,4881	7,309888	6,022737	2,487309	0,703497
T6	60,99479	17,94787	6,248476	6,550822	2,749431	0,459373
O1	60,18448	21,57309	7,725925	6,820545	2,568983	0,405582
OZ	61,06958	22,07325	7,553768	6,425548	2,336678	0,377561
O2	63,27527	17,48526	6,794394	4,495012	1,896724	0,995503
<b>Maior média</b>	<b>68,98132</b>	<b>22,07325</b>	<b>8,118018</b>	<b>8,883166</b>	<b>3,137452</b>	<b>1,733787</b>
<b>Menor média</b>	<b>59,2444</b>	<b>16,72572</b>	<b>5,720661</b>	<b>4,495012</b>	<b>1,896724</b>	<b>0,250438</b>

A respectiva representação topográfica da Tabela 7 encontra-se na Figura 7, nesta estão apresentadas topografias de diferentes ritmos cerebrais, permitindo uma análise da Porcentagem de Contribuição de Potência (PCP) durante a estimulação de 'silêncio'. Observa-se que o ritmo cerebral com maior valor de média de PCP é o Delta, com valores que chegam a aproximadamente 68%, enquanto o ritmo Super Gama exibe o menor valor de média, variando entre 0.4 e 1.6. Em uma análise por ritmo, percebe-se que no Delta, a maior atividade cerebral se concentra nas regiões frontais

e pré-frontais. No Teta, a atividade mais intensa é vista nas regiões frontais e centrais. O ritmo Alfa se destaca nas regiões frontais, centrais e parietais. Já no ritmo Beta, a maior atividade está na região central. Por sua vez, o ritmo Gama apresenta sua maior ativação na região lateral-direita e central, e, por fim, o Super Gama tem sua atividade mais intensa nas regiões fronto-centrais do cérebro.

**Figura 7 - Mapeamento topográfico da média de PCP para o momento 'silêncio'**



Fonte: produzida pela autora

Em similaridade, a Tabela 8 exibe as médias de amplitude espectral, calculadas para o quantificador FM, para as seis bandas de frequência e em cada eletrodo no momento 'silêncio'. Para essa nova tabela também são apresentados os máximos e mínimos valores de média em cada ritmo cerebral.

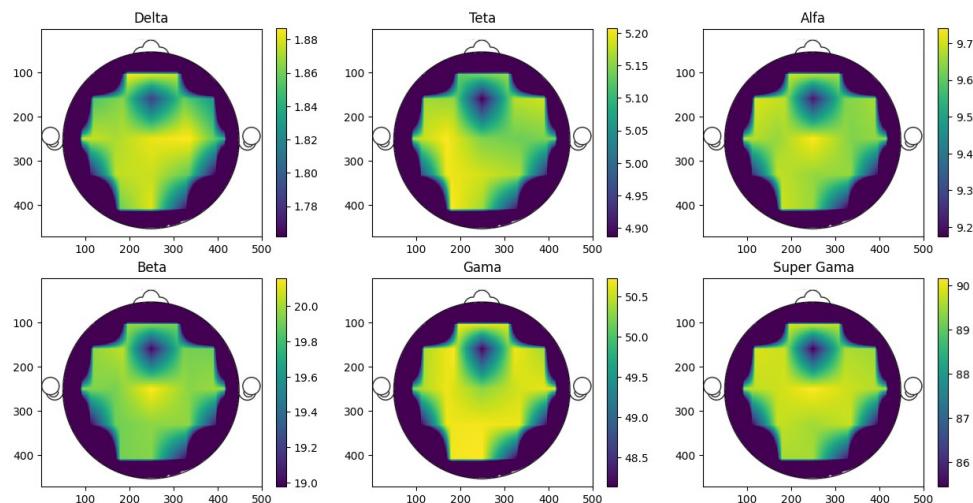
**Tabela 8 - Média de FM por época e eletrodo para o momento 'silêncio'**

Eletrodo	Delta	Teta	Alfa	Beta	Gama	Supergama
FP1	1,885131	5,129098	9,694663	19,97344	50,67178	89,846808
FP2	1,876113	5,156709	9,666813	19,91061	50,59327	89,700098
F7	1,85315	5,163686	9,710979	19,96677	50,42188	89,895896
F3	1,864761	5,156073	9,687208	20,04323	50,71957	89,791614
FZ	1,786557	4,886991	9,211523	19,00275	48,18068	85,444106
F4	1,857864	5,172413	9,63327	19,91727	50,68136	89,586157
F8	1,831096	5,184814	9,664804	19,90543	50,38204	89,48995
T3	1,878167	5,169068	9,691006	19,95065	50,34188	89,714363
C3	1,871091	5,205137	9,650548	19,91758	50,65509	89,792766
CZ	1,882786	5,145862	9,740118	20,15633	50,29514	90,16433

C4	1,886712	5,1362	9,631436	19,94376	50,56703	89,762692
T4	1,84468	5,147765	9,654902	20,0033	50,66655	89,591894
T5	1,76873	4,96282	9,244139	18,97767	48,15792	85,570341
P3	1,874801	5,200607	9,691005	19,90308	50,66003	89,772486
PZ	1,876631	5,184716	9,651742	19,95221	50,68188	89,50395
P4	1,856715	5,16711	9,650584	19,96132	50,65191	89,775032
T6	1,761699	4,925655	9,200656	19,07611	48,23514	85,545046
O1	1,859834	5,206647	9,697181	19,91288	50,68272	89,545045
OZ	1,881382	5,163392	9,653982	19,94572	50,72527	89,542384
O2	1,77029	4,91177	9,174178	19,0254	48,13356	85,781133
<b>Maior média</b>	<b>1,886712</b>	<b>5,206647</b>	<b>9,740118</b>	<b>20,15633</b>	<b>50,72527</b>	<b>90,16433</b>
<b>Menor média</b>	<b>1,761699</b>	<b>4,886991</b>	<b>9,174178</b>	<b>18,97767</b>	<b>48,13356</b>	<b>85,444106</b>

A topografia que ilustra a Tabela 8 encontra-se na Figura 8. Esta ilustração oferece uma análise topográfica dos ritmos cerebrais na estimulação de 'silêncio', mas agora para o quantificador a Frequência Mediana (FM). Observando as escalas de cores, percebe-se que a banda Delta demonstra o menor valor médio, oscilando entre 1.78 e 1.88. A distribuição da atividade cerebral também revela padrões distintos ao de PCP para a mesma estimulação: no ritmo Delta, a maior ativação é notada nas áreas frontais e pré-frontais, uma tendência que se repete de maneira similar nas bandas Gama e Super Gama. No ritmo Teta, a atividade mais intensa se concentra nas regiões parietais. A banda Alfa tem seu ponto mais alto de ativação nas regiões centrais e parietais, enquanto o ritmo Beta se destaca nas áreas centrais.

**Figura 8 - Mapeamento topográfico da média de FM para o momento 'silêncio'**



Fonte: produzida pela autora

Em continuidade, a Tabela 9 detalha as médias do quantificador PCP para as bandas de frequência em cada um dos eletrodos durante a audição da obra de Mozart. Para esse conjunto de informações apresentado abaixo, os maiores valores de média para cada banda de frequência também foram tabelados.

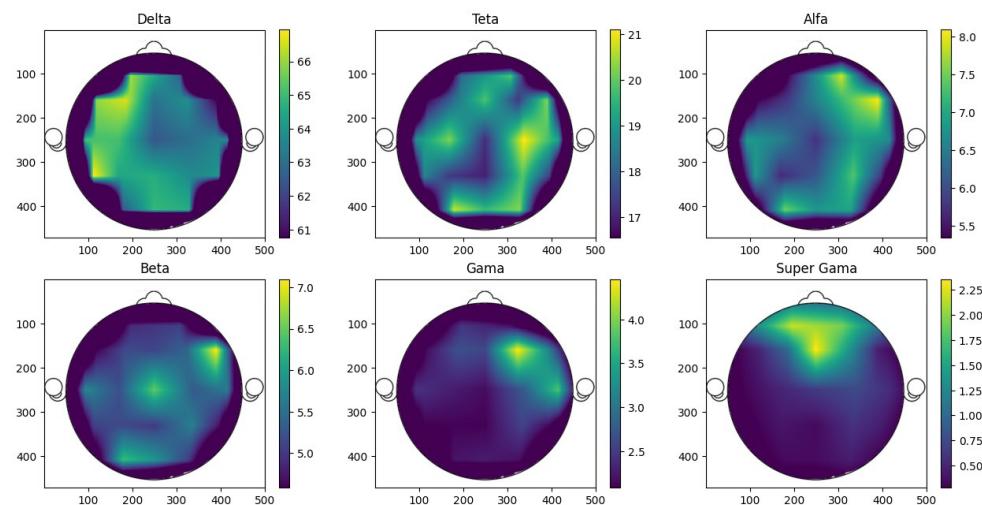
**Tabela 9 - Média de PCP por época e eletrodo para o momento 'Mozart'**

Eletrodo	Delta	Teta	Alfa	Beta	Gama	Supergama
FP1	66,07875	18,18032	5,607264	4,897211	2,456194	2,18539
FP2	62,7422	19,82191	7,897628	5,06008	2,183713	1,931314
F7	65,98723	16,5581	5,347025	4,582385	2,177596	0,478201
F3	66,58296	18,37094	5,825331	5,16989	2,676865	0,988494
FZ	63,10933	19,80403	6,571749	5,093984	2,603238	2,35525
F4	63,88404	17,34723	7,38146	5,402817	4,455237	1,387485
F8	60,75654	20,2379	8,090682	7,095909	3,247705	0,461239
T3	65,1594	18,86608	6,852749	5,7635	2,444635	0,321082
C3	65,12475	20,20257	6,541312	5,197035	2,283698	0,486762
CZ	62,46573	17,13555	5,763329	6,47392	2,160476	0,633195
C4	63,05694	21,10035	6,90823	5,292864	2,768085	0,74543
T4	63,7891	19,21281	6,699516	5,626815	3,788418	0,559021
T5	66,94812	18,65289	6,826784	5,070293	2,087469	0,280666
P3	64,45005	17,30864	5,68533	5,162378	2,108393	0,405026
PZ	64,63079	16,95614	6,094736	5,018432	2,103863	0,332373
P4	63,6875	19,90163	7,340671	5,672883	2,559287	0,5782
T6	63,94619	17,51986	5,883864	4,738061	2,126107	0,452613
O1	62,6184	20,7325	7,490784	6,296384	2,214134	0,338055
OZ	64,88539	19,64384	6,811835	5,913542	2,271821	0,342953
O2	64,64051	20,25688	6,968689	5,039908	2,1904	0,444484
<b>Maior média</b>	<b>66,94812</b>	<b>21,10035</b>	<b>8,090682</b>	<b>7,095909</b>	<b>4,455237</b>	<b>2,35525</b>
<b>Menor média</b>	<b>60,75654</b>	<b>16,5581</b>	<b>5,347025</b>	<b>4,582385</b>	<b>2,087469</b>	<b>0,280666</b>

A respectiva representação topográfica da Tabela 9 encontra-se na Figura 9. Nesta estão apresentadas as topografias das médias do quantificador PCP para a estimulação de 'Mozart'. Ao observarmos as escalas de cores, é perceptível que o ritmo cerebral com o valor mais elevado de média para PCP é a Delta, atingindo picos de aproximadamente 66%. Em contraste, a banda Super Gama exibe o menor valor médio, com sua escala de média para PCP oscilando entre 0.50% e 2.25%. A distribuição da atividade cerebral também revela particularidades para cada ritmo: no ritmo Delta, a ativação é mais proeminente nas regiões frontais e pré-frontais. Já no ritmo Teta, a atividade mais intensa se concentra nas regiões centrais e, em menor

grau, na área frontal. A banda Alfa tem seu pico de ativação nas regiões centrais, frontais e parietais. O ritmo Beta se destaca nas áreas centrais e frontais, com uma ênfase particular na região central esquerda. Por sua vez, a banda Gama tem sua maior atividade concentrada nas regiões temporal e central direita, enquanto o Super Gama mostra sua maior ativação nas áreas fronto-centrais do cérebro.

**Figura 9 - Mapeamento topográfico da média de PCP para o momento 'Mozart'**



Fonte: produzida pela autora

De forma similar, a Tabela 10 apresenta as médias de poder espectral, utilizando o quantificador FM, para as diferentes bandas de frequência em cada eletrodo durante a estimulação musical de 'Mozart'. Para este último conjunto de dados, os máximos valores de média para cada ritmo cerebral também foram incluídos na tabela.

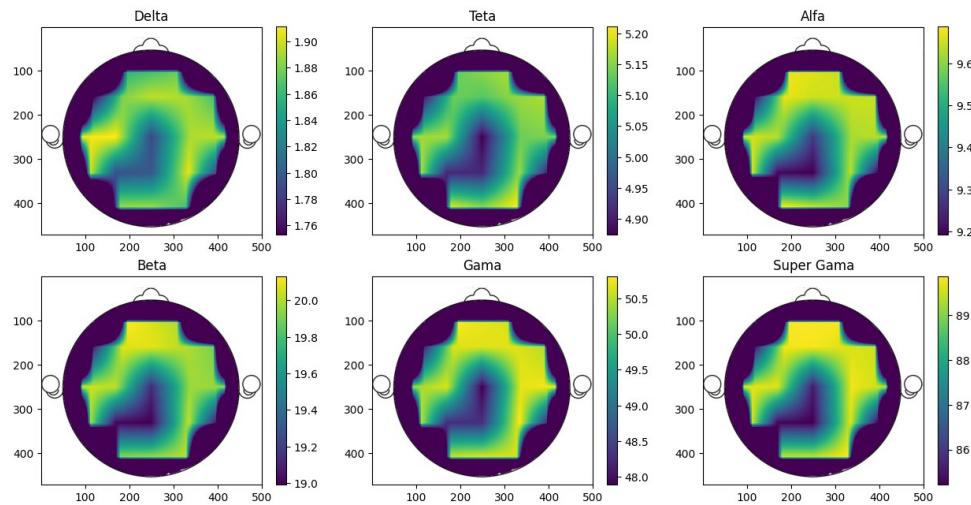
**Tabela 10 - Média de FM por época e eletrodo para o momento 'Mozart'**

Eletrodo	Delta	Teta	Alfa	Beta	Gama	Supergama
FP1	1,859108	5,135143	9,674917	20,13028	50,78607	89,854554
FP2	1,875971	5,168143	9,651592	20,00692	50,63255	89,803962
F7	1,752944	4,904021	9,212176	19,10926	48,23597	85,530132
F3	1,881011	5,137056	9,673526	20,08128	50,66727	89,772352
FZ	1,896041	5,123926	9,650944	20,08158	50,65945	89,790741
F4	1,892664	5,158048	9,652133	20,01137	50,69624	89,635936
F8	1,867556	5,170735	9,648769	19,90043	50,4723	89,497565
T3	1,908328	5,1633	9,662371	20,04523	50,38788	89,678126

C3	<b>1,911328</b>	5,165741	9,632886	20,01742	50,63422	<b>89,635769</b>
CZ	<b>1,788469</b>	4,87442	9,276924	19,13484	47,89342	<b>85,576977</b>
C4	<b>1,892264</b>	5,1362	9,626056	19,96495	50,69687	<b>89,754946</b>
T4	<b>1,896932</b>	5,15043	9,637743	19,95531	50,77408	<b>89,459488</b>
T5	<b>1,898044</b>	5,168159	9,655682	19,97542	50,49066	<b>89,517356</b>
P3	<b>1,792507</b>	4,913816	9,204063	19,01969	48,28591	<b>85,306355</b>
PZ	<b>1,796865</b>	4,913244	9,191759	18,99266	48,2941	<b>85,220444</b>
P4	<b>1,905601</b>	5,160398	9,63668	20,02491	50,80623	<b>89,642789</b>
T6	<b>1,793586</b>	4,915104	9,209026	19,0962	48,35547	<b>85,377589</b>
O1	<b>1,887815</b>	5,194157	9,68828	19,92918	50,58994	<b>89,463063</b>
OZ	<b>1,888473</b>	5,152996	9,647747	19,9543	50,66613	<b>89,446511</b>
O2	<b>1,866935</b>	5,21103	9,605159	20,00673	50,61349	<b>89,814323</b>
<b>Maior média</b>	<b>1,911328</b>	<b>5,21103</b>	<b>9,68828</b>	<b>20,13028</b>	<b>50,80623</b>	<b>89,854554</b>
<b>Menor média</b>	<b>1,752944</b>	<b>4,87442</b>	<b>9,191759</b>	<b>18,99266</b>	<b>47,89342</b>	<b>85,220444</b>

Finalizando essa análise, as topografias referentes à Tabela 10 estão ilustradas na Figura 10 oferecendo um panorama as topografias da Frequência Mediana (FM) dos ritmos cerebrais durante a estimulação de ‘Mozart’. Ao analisarmos as escalas de cores para este caso, percebemos que a banda Delta demonstra o valor médio mais baixo, com as médias de FM variando entre 1.76 e 1.90. A distribuição da atividade cerebral também exibe singularidades para cada ritmo: no Delta, a ativação mais forte é observada na região lateral esquerda, com menor concentração nas áreas frontais e centrais. Já no Teta, a atividade mais intensa se concentra nas regiões centrais e parietais. A banda Alfa tem seu ponto máximo de ativação nas regiões frontais e parietais. O ritmo Beta se destaca nas áreas frontais e centrais, enquanto a banda Gama tem sua maior atividade concentrada nas regiões frontais e pré-frontais. Por fim, o Super Gama mostra sua maior ativação nas áreas frontais e centrais do cérebro.

**Figura 10 - Mapeamento topográfico da média de FM para o momento ‘Mozart’**



Fonte: produzida pela autora

Diante desses dados, as topografias das médias de PCP mostram diferenças significativas entre as condições de silêncio e estimulação musical, indicando que o cérebro dos pacientes comatosos pode estar respondendo ao estímulo de ‘Mozart’. Uma dessas mudanças foi a diminuição sutil na escala da média na banda Delta, visto que durante a estimulação de ‘silêncio’ a escala da média de PCP nesta banda de frequência variou de aproximadamente 60% a 68% (por exemplo, no eletrodo CZ foi igual a 59,244, no F3 igual a 66,17547 e no F7 igual a 68,98132) e na estimulação de ‘Mozart’ a variação da escala diminuiu indo aproximadamente de 61% a 66% (por exemplo, no eletrodo F8 foi igual a 60,75654, no P4 igual a 63,6875 e no T5 igual a 66,94812). Além disso, a mudança do foco de Alfa das regiões posteriores durante o ‘silêncio’ para as regiões frontais e temporais durante ‘Mozart’ pode ser uma evidência de interação do sistema auditivo. Por fim, a análise das topografias cerebrais revelou uma mudança significativa na configuração espacial das ondas cerebrais ao comparar os momentos de 'silêncio' e 'Mozart'. Especificamente para as ondas Beta, Gama e Super Gama, que estão diretamente associadas a processos de atenção, percepção e integração, a atividade, que se mostrava mais difusa durante a estimulação de 'silêncio', reconfigurou-se espacialmente com a estimulação de ‘Mozart’. Neste caso, houve uma notável concentração dessas atividades em regiões importantes como as frontais e temporais, sugerindo que o cérebro, de forma mais focalizada e intensa, se

empenhouativamente em processos de atenção, percepção e integração para processar o estímulo de 'Mozart' (Figura 9).

Finalmente, as topografias das médias de FM revelam um padrão de resposta cerebral que pode ser descrito como uma aceleração localizada, ou seja, um aumento da Frequência Mediana em regiões específicas do cérebro. Diferentemente de uma ativação global e homogênea, que seria um aumento da FM em todo o córtex e em todas as bandas de frequência, a estimulação 'Mozart' causou mudanças principalmente quanto às regiões cerebrais que apresentaram maior atividade entre os diferentes estímulos. Quando comparada com a estimulação de 'silêncio', a topografia da média de FM para o momento 'Mozart' apresentou a concentração dessa aceleração principalmente nas regiões frontais e na área temporal direita. Essa resposta focada sugere que o cérebro do paciente comatoso não está simplesmente reagindo a um som, mas está se empenhando em um processamento de estímulos específico para as áreas neurais responsáveis pela atenção e pela interpretação de elementos musicais. A aceleração localizada, portanto, pode estar indicando uma atividade neural organizada e não aleatória.

## 4.4 DISCUSSÃO

### 4.4.1 Consistência entre MATLAB e Python para Quantificadores FM e PCP

Os resultados obtidos para os quantificadores Frequência Mediana (FM) e Porcentagem de Contribuição de Potência (PCP) demonstram uma notável consistência entre as duas plataformas. Isso foi evidenciado pelos erros relativos predominantemente na ordem de  $10^{-13}$  a  $10^{-15}$ . Essa baixa magnitude dos erros relativos sugere que, para as rotinas de processamento de sinais EEG empregadas neste trabalho, ambas as linguagens produzem resultados numericamente equivalentes, validando a reproduzibilidade e a confiabilidade dos métodos independentemente da ferramenta computacional utilizada.

A consistência observada é fundamental no contexto da Engenharia Biomédica, onde a precisão e a replicabilidade dos resultados são de suma

importância para a interpretação clínica e a validação científica. A similaridade dos valores obtidos em MATLAB e Python, mesmo com as inerentes diferenças entre bibliotecas, algoritmos e rotinas de implementação, reforça a robustez dos procedimentos padrão de processamento de sinais de EEG. Este dado atende ao objetivo de comparar quantitativamente os resultados e avaliar a confiabilidade e reproduzibilidade das duas linguagens, estabelecendo a credibilidade do Python como uma ferramenta viável para a pesquisa em neurociência e para o desenvolvimento de aplicações clínicas baseadas em EEG, incluindo a monitorização e a intervenção em pacientes comatosos.

#### **4.4.2 Implicações da Escolha da Plataforma (MATLAB vs. Python)**

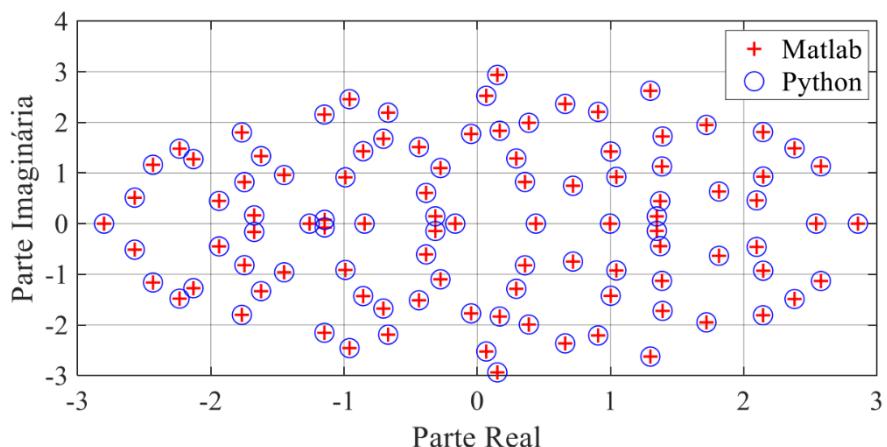
A escolha da plataforma para análise de sinais de EEG impacta diretamente a eficiência, a acessibilidade e os custos associados às pesquisas. O MATLAB, apesar de ter sido visto como a melhor escolha por anos, apresenta custos de licenciamento que podem ser limitantes para algumas instituições e pesquisadores. Por outro lado, o Python, como linguagem de código aberto, elimina essas barreiras financeiras, além de oferecer uma vasta comunidade de desenvolvedores e bibliotecas em constante evolução.

A capacidade do Python de integrar-se com outras ferramentas de análise de dados e aprendizado de máquina também o torna uma opção atraente para pesquisas avançadas em neurociência. Um estudo, como o de (GRAMFORT, 2013), compara o desempenho do Python e do MATLAB no processamento de sinais de EEG e mostra que o Python, utilizando a biblioteca MNE, pode alcançar resultados comparáveis ao MATLAB em diversas tarefas de análise de EEG, com a vantagem de ser gratuito e de código aberto. Essa capacidade de processamento eficiente e acessível torna o Python uma ferramenta valiosa para a pesquisa em neurociência e para o desenvolvimento de aplicações clínicas baseadas em EEG.

A importância da validação reside na necessidade de garantir que os resultados obtidos com o Python sejam consistentes e comparáveis aos resultados obtidos com o MATLAB, uma plataforma amplamente utilizada e validada na área de processamento de sinais de EEG. Essa validação se torna particularmente relevante

em contextos clínicos sensíveis, como a análise de EEG em pacientes comatosos submetidos à estimulação musical. Um estudo abrangente (O. DANIEL; L. VARRICCHIO, 2020), embora focado em sistemas elétricos de potência, oferece percepções relevantes sobre a comparabilidade de precisão entre Matlab e Python em métodos numéricos essenciais, como transformações tempo-frequência e álgebra linear. Os autores demonstram que, para a maioria das operações numéricas fundamentais, ambas as plataformas apresentam precisão notavelmente comparável, com Python emergindo como uma alternativa viável e convincente devido ao seu baixo custo e natureza de código aberto. Essa equivalência de precisão, ilustrada na figura extraída de O. DANIEL, L. VARRICCHIO 2020, apresenta a dispersão de componentes independentes no plano complexo, obtidos por ambos os softwares (MATLAB e Python), reforçando a confiança na utilização do Python em diversos contextos e aplicações quando comparado com MATLAB.

**Figura 11 - Equivalência de precisão de MATLAB x Python**



Fonte: (O. DANIEL; L. VARRICCHIO, 2020)

Para finalizar, estudos têm demonstrado o potencial da estimulação musical para modular a atividade cerebral em pacientes comatosos, podendo influenciar o despertar e a recuperação neurológica (O'KELLY et al., 2013). A análise precisa dos sinais de EEG durante essas intervenções, utilizando ferramentas como o Python e a biblioteca MNE-Python, é crucial para identificar padrões de resposta e avaliar a eficácia da estimulação.

#### **4.4.3 Variações da atividade cerebral (Mozart x Silêncio)**

As topografias cerebrais avaliadas revelam padrões de atividade que variam de forma marcante sob diferentes condições e métricas. A diferença observada entre os quantificadores PCP e FM nas estimulações de ‘silêncio’ e ‘Mozart’ sugere que esses quantificadores capturam aspectos distintos da dinâmica cerebral. A predominância do ritmo Delta na análise de PCP, tanto em silêncio quanto sob estímulo musical aponta para o fato de que esse ritmo é um dos marcadores eletroencefalográficos mais característicos do estado de coma (COSTA, 2022), refletindo uma disfunção cortical e a ausência de atividade neural complexa e organizada.

Por outro lado, analisando as médias do quantificador FM durante os dois estímulos, nas bandas de frequência Beta e Gama percebe-se uma aceleração durante o estímulo com ‘Mozart’ se concentrando principalmente nas regiões frontais e na área temporal direita o que pode ser um indicativo de tentativa do cérebro em processar e organizar o estímulo auditivo vindo dessa estimulação. As diferenças entre as regiões cerebrais também merecem destaque. A ativação frontal, frequentemente associada a funções de atenção, é proeminente em quase todas as condições, o que reforça o papel dessa região na organização e no controle da atividade cerebral. A resposta particular do cérebro à música de Mozart, com picos de atividade em diferentes ritmos e localizações, ecoa achados da literatura que indicam o efeito dessa música na estimulação cognitiva e emocional (JAUSOVEC; JAUSOVEC; GERLIC, 2006).

## CAPÍTULO 5 - CONCLUSÃO

Este capítulo final sintetiza os principais produtos do estudo, reafirmando as contribuições para a área de processamento de sinais de EEG e a validação do uso do Python em contextos clínicos. Além disso, serão apresentadas sugestões para futuras investigações, visando aprofundar a compreensão da conectividade cerebral em estados alterados de consciência e aprimorar as metodologias de análise.

O presente estudo teve como objetivo analisar e comparar o processamento de sinais eletroencefalográficos (EEG) utilizando as plataformas MATLAB e Python, com foco na validação do fluxo de processamento em Python para variáveis de Percentual de Contribuição de Potência (PCP) e Frequência Mediana (FM), bem como para a coerência em pacientes comatosos sob estimulação musical e em condição basal.

Os resultados obtidos para os quantificadores FM e PCP demonstraram uma equivalência precisa e notável consistência entre as implementações em Python e MATLAB, evidenciada por erros relativos predominantemente na ordem de  $10^{-13}$  a  $10^{-15}$ . Essa baixa magnitude de erros valida a reproduzibilidade e a confiabilidade dos métodos, reforçando que ambas as linguagens produzem resultados numericamente equivalentes para essas rotinas de processamento de EEG. A capacidade de quantificar essas diferenças por meio do Erro Relativo, calculado conforme a Equação 6, foi importante para avaliar a fidelidade dos resultados e garantir a confiabilidade em aplicações clínicas sensíveis, como a análise de pacientes em coma.

Em relação à análise das bandas de frequência com relação aos maiores erros relativos de cada exame, observou-se a predominância da banda "supergama" para FM e PCP tanto no período de "silêncio" quanto na estimulação "Mozart", com exceções pontuais da banda "gama" e "ruído". Embora a estimulação musical não tenha induzido alterações drásticas e generalizadas nas bandas de frequência para a maioria dos casos avaliados por esses quantificadores, a ocorrência de "ruído" e variações em registros específicos (como em "s14.mat") abre caminho para investigações mais aprofundadas sobre a reatividade neural em estados alterados de consciência.

A análise do erro relativo da Coerência, um biomarcador importante para a avaliação da conectividade funcional em pacientes comatosos, revelou valores elevados de erro relativo predominantemente na banda delta (0-4 Hz). O estudo identificou tendências e discrepâncias notáveis entre os resultados de coerência obtidos com Python e MATLAB, o que se deve às divergências de algoritmo entre essas plataformas. Embora o MATLAB tenha frequentemente apresentado valores de coerência mais elevados nas frequências mais baixas da banda delta em algumas épocas, outras épocas exibiram uma excelente concordância entre as duas plataformas. Essas diferenças, como discutido detalhadamente na seção 4.2, realçam um desafio inerente à reproduzibilidade em diferentes ambientes de software, atribuíveis em grande parte a variações nos parâmetros padrão de cálculo e pré-processamento.

Apesar dessas discrepâncias iniciais na coerência, o Python demonstrou ser uma plataforma altamente eficaz e flexível para o processamento de sinais de EEG. As diferenças observadas não indicam falhas intrínsecas do Python, mas sim a necessidade de padronização rigorosa dos parâmetros de processamento. A natureza de código aberto do Python, seu controle granular sobre os parâmetros e sua integração com outras ferramentas de análise de dados e aprendizado de máquina, conferem-lhe uma vantagem significativa em termos de reproduzibilidade, adaptabilidade e acessibilidade em comparação com softwares proprietários como o MATLAB, que possui custos de licenciamento limitantes. Essa transparência é fundamental para a validação científica e a replicação precisa das análises.

Além disso, a partir das análises entre as estimulações de ‘silêncio’ e ‘Mozart’, observou-se a presença do ritmo Delta na avaliação da média de PCP, tanto em para ambas as estimulações e isso apresenta características de disfunção cortical e da ausência de atividade neural complexa. Em contrapartida, as mudanças de regiões cerebrais ativadas para FM durante a estimulação de ‘Mozart’ sugerem que, pode ter tido um esforço cerebral para organizar esse estímulo auditivo.

Em suma, este trabalho valida o uso de rotinas padronizadas em Python para o processamento de sinais de EEG de pacientes comatosos, particularmente para o cálculo de FM e PCP, fornecendo uma base sólida para futuros estudos. A capacidade

do Python de gerar resultados consistentes e aprofundar a análise de fenômenos complexos, como a coerência, é crucial para a pesquisa em neurociência e para o desenvolvimento de aplicações clínicas, incluindo a monitorização e a intervenção em pacientes comatosos.

Com base nos achados deste estudo, várias direções para trabalhos futuros são sugeridas para aprimorar a comparabilidade e a validade das análises de EEG:

- **Continuidade na Análise da Coerência:** Dar continuidade à análise da coerência, explorando a extração de outras informações e métricas a partir dela para uma compreensão mais aprofundada da conectividade funcional.
- **Análise Visual das Regiões Cerebrais:** Realizar uma análise mais detalhada das regiões cerebrais por meio da geração de topografias de EEG. Essa abordagem visual permitirá comparar os padrões de atividade e conectividade espacialmente, correlacionando-os com os resultados quantitativos obtidos e auxiliando na interpretação clínica.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ANGHINAH, R. et al. Estudo da coerência do eletrencefalograma na banda de frequência alfa em indivíduos adultos normais: resultados preliminares em 10 casos. **Arquivos de Neuro-Psiquiatria**, v. 63, n. 1, p. 83–86, mar. 2005.
- BRONZINO, J. D. **The Biomedical Engineering Handbook**. [S.l: s.n.], 2000.
- CACIOPPO, J. T.; TASSINARY, L. G.; BERNTSON, G. G. **Handbook of psychophysiology**. [S.l: s.n.], 2000.
- CASTRO, M. et al. Boosting Cognition With Music in Patients With Disorders of Consciousness. **Neurorehabilitation and Neural Repair**, v. 29, n. 8, p. 734–742, 3 set. 2015.
- CHENNU, S. et al. Brain networks predict metabolism, diagnosis and prognosis at the bedside in disorders of consciousness. **Brain**, v. 140, n. 8, p. 2120–2132, 1 ago. 2017.
- COSTA, P. **Base de dados em eletroencefalografia (EEG)**. 2022. Dissertação de Mestrado—Universidade Federal de Uberlândia, 2022.
- DAS, R. K. et al. A Survey on EEG Data Analysis Software. **Sci**, v. 5, n. 2, p. 23, 1 jun. 2023.
- GRAMFORT, A. MEG and EEG data analysis with MNE-Python. **Frontiers in Neuroscience**, v. 7, 2013.
- HU, Y. et al. Can Music Influence Patients With Disorders of Consciousness? An Event-Related Potential Study. **Frontiers in Neuroscience**, v. 15, 9 abr. 2021.
- HUANG, H. et al. Comatose Patients After Cardiopulmonary Resuscitation: An Analysis Based on Quantitative Methods of EEG Reactivity. **Frontiers in Neurology**, v. 13, 3 jun. 2022.
- JAUSOVEC, N.; JAUSOVEC, K.; GERLIC, I. The influence of Mozart's music on brain activity in the process of learning. **Clinical Neurophysiology**, v. 117, n. 12, p. 2703–2714, dez. 2006.
- LANCIONI, G. E. et al. Music Stimulation for People with Disorders of Consciousness: A Scoping Review. **Brain Sciences**, v. 11, n. 7, p. 858, 28 jun. 2021.
- LAUREYS, S.; OWEN, A. M.; SCHIFF, N. D. Brain function in coma, vegetative state, and related disorders. **The Lancet Neurology**, v. 3, n. 9, p. 537–546, set. 2004.

- LI, B.; CAO, J. Classification of coma/brain-death EEG dataset based on one-dimensional convolutional neural network. **Cognitive Neurodynamics**, v. 18, n. 3, p. 961–972, 18 jun. 2024.
- LI, X. et al. Music Interventions for Disorders of Consciousness: A Systematic Review and Meta-analysis. **Journal of Neuroscience Nursing**, v. 52, n. 4, p. 146–151, ago. 2020.
- LIMA, J. G. F. et al. A INFLUÊNCIA DA MUSICOTERAPIA NOS PARÂMETROS HEMODINÂMICOS DE PACIENTES COMATOSOS / THE INFLUENCE OF MUSIC THERAPY ON THE HEMODYNAMIC PARAMETERS OF COMATOSE PATIENTS. **Brazilian Journal of Development**, v. 7, n. 3, p. 28054–28056, 2021.
- LLOYD-FOX, S. et al. Are you talking to me? Neural activations in 6-month-old infants in response to being addressed during natural interactions. **Cortex**, v. 70, p. 35–48, set. 2015.
- MANUAL MSD. Visão geral de coma e consciência comprometida. abr. 2024. Disponível em: <<https://www.msdmanuals.com/pt/profissional/dist%C3%BArbios-neurol%C3%B3gicos/coma-e-consci%C3%A3o-comprometida/vis%C3%A3o-geral-de-coma-e-consci%C3%A3o-comprometida>>. Acesso em: 2 ago. 2025.
- NIEDERMEYER, E.; LOPES DA SILVA, F. **Electroencephalography: Basic Principles, Clinical Applications, and Related Fields**. Philadelphia: Lippincott Williams & Wilkins, 2005.
- O. DANIEL, L.; L. VARRICCHIO, S. Ferramentas de Prototipação Aplicadas a Sistemas de Potência: Matlab versus Python. 14 ago. 2020, Rio de Janeiro: Anais do Simpósio Brasileiro de Sistemas Elétricos, 14 ago. 2020.
- O'KELLY, J. et al. Neurophysiological and Behavioral Responses to Music Therapy in Vegetative and Minimally Conscious States. **Frontiers in Human Neuroscience**, v. 7, 2013.
- OOSTENVELD, R. et al. FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data. **Computational Intelligence and Neuroscience**, v. 2011, p. 1–9, 2011.
- PAUL, J. O. et al. Explorando a Eletroencefalografia (EEG): Atividades Práticas em Laboratório. **RCMOS - Revista Científica Multidisciplinar O Saber**, v. 1, n. 2, 6 dez. 2024.
- POLICH, J. Updating P300: An integrative theory of P3a and P3b. **Clinical Neurophysiology**, v. 118, n. 10, p. 2128–2148, out. 2007.
- PUGGINA, Ana Claudia Giesbrecht; SILVA, M. J. P. da. Pacientes com desordem de consciência: respostas vitais, faciais e musculares frente música ou mensagem. **Revista Brasileira de Enfermagem**, v. 68, n. 1, p. 102–110, fev. 2015.

PUGGINA, Ana Cláudia Giesbrecht; SILVA, M. J. P. da. Sinais vitais e expressão facial de pacientes em estado de coma. **Revista Brasileira de Enfermagem**, v. 62, n. 3, p. 435–441, jun. 2009.

RAMOS, C. **Caracterização do eletroencefalograma normal em situação de vigília: elaboração da base de dados e análise quantitativa**. 2017. Dissertação de Mestrado—Universidade Federal de Uberlândia, 2017.

ROBERTO LOMBARDINO. **Development and Validation of a Python Algorithm for EEG-Based Emotion Recognition: A Comparison Study with Specifically Designed MATLAB Toolboxes**. 2025. Dissertação de Mestrado—Politecnico di Torino, 2025.

SANEI, S.; CHAMBERS, J. A. **EEG Signal Processing**. [S.I.]: Wiley, 2007.

SANTOS, T. R. M. S. dos; CAVALCANTE, T. B.; SILVA, J. F. Terapia musical em pacientes com distúrbios da consciência: uma revisão integrativa. **Cadernos Brasileiros de Terapia Ocupacional**, v. 27, n. 4, p. 873–884, 2019.

SCHNAKERS, C.; MAGEE, W. L.; HARRIS, B. Sensory Stimulation and Music Therapy Programs for Treating Disorders of Consciousness. **Frontiers in Psychology**, v. 7, 7 mar. 2016.

SILVA, A. V. A. da. **Avaliação quantitativa do sinal EEG medido em paciente comatoso: comparativo entre silêncio e estímulo musical**. 2025. Trabalho de Conclusão de Curso—Universidade Federal de Uberlândia, 2025.

SITT, J. D. et al. Large scale screening of neural signatures of consciousness in patients in a vegetative or minimally conscious state. **Brain**, v. 137, n. 8, p. 2258–2270, ago. 2014.

SPACCAVENTO, S. et al. Musical and electrical stimulation as intervention in disorder of consciousness (DOC) patients: A randomised cross-over trial. **PLOS ONE**, v. 19, n. 5, p. e0304642, 31 maio 2024.

STEWART, T. C. et al. Closed-Loop Neuromorphic Benchmarks. **Frontiers in Neuroscience**, v. 9, 15 dez. 2015.

TEPLAN, M. Fundamental of EEG Measurement. **MEASUREMENT SCIENCE REVIEW**, v. 2, jan. 2002.

WEISSENBOCK, J. et al. Dynamic Volume Lines: Visual Comparison of 3D Volumes through Space-filling Curves. **IEEE Transactions on Visualization and Computer Graphics**, v. 25, n. 1, p. 1040–1049, jan. 2019.

YIJUN WANG et al. Brain-Computer Interfaces Based on Visual Evoked Potentials. **IEEE Engineering in Medicine and Biology Magazine**, v. 27, n. 5, p. 64–71, set. 2008.

YOUNG, G. B. Coma. **Annals of the New York Academy of Sciences**, v. 1157, n. 1, p. 32–47, 30 mar. 2009.

\_\_\_\_\_. The EEG in Coma. **Journal of Clinical Neurophysiology**, v. 17, n. 5, p. 473–485, set. 2000.

ZHOU, T. et al. Influence of the Acoustic Environment in Hospital Wards on Patient Physiological and Psychological Indices. **Frontiers in Psychology**, v. 11, 21 jul. 2020.

## **ANEXO A - CÓDIGO RELATIVE\_ERROR**

```

import numpy as np

NEAR_ZERO = 1e-10

def relative_error(matriz1, matriz2): # Função para calcular o erro
    relativo
    """
    Função para calcular o erro relativo entre duas matrizes.

    Parâmetros:
    matriz1 -> Matriz com valores da variável (verdade).
    matriz2 -> Matriz com valores da variável (estimativa).

    Retorna:
    tuple: (relative_error, max_error, posição_maior_erro)
        - relative_error: matriz preenchida com valores de erro relativo
correspondentes para época, em cada eletrodo e em cada banda de frequência.
        - max_error: o valor do maior erro encontrado na matriz anterior.
        - posição_maior_erro: época, eletrodo e banda de frequência de
onde está posicionado o valor do maior erro relativo.
    """
    # Certificar que as duas matrizes têm o mesmo formato
    assert matriz1.shape == matriz2.shape, "As matrizes devem ter o mesmo
formato"

    # Garantir que não haja valores NaN ou Inf
    matriz1 = np.nan_to_num(matriz1, neginf=NEAR_ZERO, posinf=NEAR_ZERO,
nan=NEAR_ZERO)
    matriz2 = np.nan_to_num(matriz2, neginf=NEAR_ZERO, posinf=NEAR_ZERO,
nan=NEAR_ZERO)

    # Substituir valores próximos de zero em ambas as matrizes
    matriz1 = np.where(np.abs(matriz1) < NEAR_ZERO, NEAR_ZERO, matriz1)
    matriz2 = np.where(np.abs(matriz2) < NEAR_ZERO, NEAR_ZERO, matriz2)

    # Calcular o erro relativo: |ESTIMATIVA - VERDADE| / |VERDADE|
    relative_error = np.abs(matriz2 - matriz1) / np.abs(matriz1)

    # Encontrar o maior erro relativo e sua posição
    max_error = np.max(relative_error)
    position_max_error = np.unravel_index(np.argmax(relative_error),
relative_error.shape)

```

```
# np.unravel_index: pega o índice linear retornado por np.argmax e o
# converte em coordenadas que correspondem às dimensões originais da matriz.

# np.argmax: Encontra o índice linear ou posição do maior valor em um
array (ou matriz) multidimensional

return relative_error, max_error, position_max_error
```

## ANEXO B - CÓDIGO MAX\_RELATIVE\_ERROR

```

import pickle
import numpy as np
import scipy.io
from relative_error import relative_error

def read_pkl_file(path):
    """
    Lê um arquivo .pkl e retorna seu conteúdo.
    """
    with open(path, 'rb') as f:
        return pickle.load(f)

def read_pkl_file_and_extract_quantifier_and_band_frequencies(pkl_path,
quantifier_name='PCP'):
    """
    Lê um arquivo .pkl e retorna a matriz correspondente ao
    quantificador especificado,
    juntamente com os nomes das bandas de frequência.

    Parâmetros:
        pkl_path (str): Caminho para o arquivo .pkl.
        quantifier_name (str): Nome do quantificador a ser extraído
        ('PCP' ou 'FM').

    Retorna:
        matriz_pkl (np.ndarray): Matriz com os valores do quantificador
        extraído.
        Formato da matriz_pkl: (10, 7, 20)
            - 10 épocas
            - 7 bandas de frequência
            - 20 canais
        band_frequencies_name (list): Lista com os nomes das bandas de
        frequência.
    """
    # Lê o arquivo .pkl
    eeg_record = read_pkl_file(pkl_path)

    # Extrai os nomes das bandas a partir do primeiro objeto época
    usando band_frequence_signal_list
    first_epoch = eeg_record.epoch_list[0]
    first_band_signal = first_epoch.band_frequence_signal_list
    band_frequencies_name = [signal.band_frequence.name for signal in
    first_band_signal]

    # Extrai os valores do quantificador
    values_pkl = []

    for epoch in eeg_record.epoch_list:
        for band_signal in epoch.band_frequence_signal_list:
            if quantifier_name == 'PCP':
                values_pkl.append(band_signal.pcp)
            elif quantifier_name == 'FM':

```

```

        values_pk1.append(band_signal.fm)

amount_bands = len(band_frequencies_name)
amount_channels = len(values_pk1[0])

# Transforma a lista em um array NumPy e reorganiza suas dimensões
# antes: (70x20) -> (bandas de frequência X épocas, canais)
# depois: (10,7,20) -> (época, bandas de frequência, canais)
matriz_pk1 = np.array(values_pk1).reshape(
    len(eeg_record.epoch_list), # épocas
    amount_bands, # bandas
    amount_channels # canais
)

return matriz_pk1, band_frequencies_name

def read_mat_file_and_extract_quantifier(mat_path,
quantifier_name='PCP'):
    """
    Lê um arquivo .mat e retorna a matriz correspondente ao
    quantificador especificado.

    Parâmetros:
        mat_path (str): Caminho para o arquivo .mat.

        quantifier_name (str): nome do quantificador a ser extraido
        ('PCP' ou 'FM').

    Retorna:
        data: Matriz extraída do arquivo .mat após seu carregamento.
        Forma original da variável 'PCP': (1, 7) -> sendo as 7 bandas de
        frequência
        Dtype da variável 'PCP': object
        Após conversão de objeto para array: (7, 20, 10)
        - 7 bandas de frequência
        - 20 eletrodos
        - 10 épocas
        Forma final da matriz após fazer a transposta (épocas, bandas,
        canais): (10, 7, 20)
    """
    # Carrega os dados do arquivo .mat
    mat_data = scipy.io.loadmat(mat_path)

    # Extrai objeto desejado do dicionário carregado
    data = mat_data[quantifier_name]

    # Se a matriz estiver no formato de objeto (por exemplo, células no
    # MATLAB), converte para array NumPy
    if data.dtype == 'object':
        data = np.stack([np.array(item) for item in data.flatten()])

    # Reordena as dimensões da matriz lida do .mat que, inicialmente é
    (1,7)
        # e, quando transformada em um array se torna (7,20,10) -> (bandas,
        canais, épocas)

```

```

# então usamos transpose com a ordem (2, 0, 1) para transformar em
(10,7,20) -> (épocas, bandas, canais),
# facilitando comparações com dados do Python.
data = np.transpose(data, (2, 0, 1)) # (épocas, bandas, canais)

# Retorna a matriz sem validação rígida de shape
return data


def max_relative_error(pkl_path, mat_path, quantifier_name='PCP'):
    """
    Calcula o erro relativo entre as matrizes do quantificador
    indicado,
    entre o arquivo python (.pkl) e matlab (.mat), retornando o maior
    erro encontrado
    da matriz de erro relativo gerado na comparação desse quantificador,
    juntamente com
    a localização do erro para auxiliar em uma análise mais aprofundada.

    Parâmetros:
        pkl_path (str): Caminho do arquivo .pkl com os dados do EEG.
        mat_path (str): Caminho do arquivo .mat com os dados de
        referência.
        quantifier_name (str): Nome do quantificador a ser comparado
        ('PCP' ou 'FM').

    Retorna:
        max_error (float): O maior erro relativo encontrado.
        error_position (dict): Dicionário com informações da posição do
        erro (época, banda, eletrodo).
    """
    assert quantifier_name in ['PCP', 'FM'], "quantifier_name deve ser
    'PCP' ou 'FM'."

    # Retorna tanto a matriz quanto as bandas
    matriz_pkl, band_frequencies_name =
    read_pkl_file_and_extract_quantifier_and_band_frequencies(pkl_path,
    quantifier_name)
    matriz_mat = read_mat_file_and_extract_quantifier(mat_path,
    quantifier_name)

    assert matriz_mat.shape == matriz_pkl.shape, (
        f"As dimensões das matrizes não coincidem:\n"
        f".mat shape: {matriz_mat.shape}\n"
        f".pkl shape: {matriz_pkl.shape}"
    )

    _, max_error, position = relative_error(matriz_mat, matriz_pkl)
    epoch_idx, band_idx, canal_idx = position

```

```
error_position = {
    "Epoca": epoch_idx,
    "Banda": band_frequencies_name[band_idx],
    "Eletrodo": canal_idx
}

return max_error, error_position
```

## ANEXO C – CÓDIGO RELATIVE\_ERROR\_QUANTIFIER

```

import csv
import traceback
import os
from max_relative_error import max_relative_error

def create_csv(results, file_name):
    """
    Salva os resultados em um arquivo CSV com 6 colunas distintas,
    formatando o erro relativo com vírgula como separador decimal.

    - Coluna A (Nome Arquivos PKL): Nome do arquivo .pkl
    - Coluna B (Nome Arquivo MAT): Nome do arquivo .mat
    - Coluna C (Maior Erro Relativo): Contém os valores de maior erro
    relativo para cada exame
        - Coluna D (Época): Representa em qual época ocorreu o maior erro
        relativo em cada exame
        - Coluna E (Eletrodo): Representa em qual eletrodo ocorreu o maior
        erro relativo em cada exame
        - Coluna F (Banda de Frequência): Representa em qual banda de
        frequência ocorreu o maior erro relativo em cada exame

    Parâmetros:
        results (list): Uma lista de tuplas. Cada tupla contém as
        seguintes informações:
            - Nome Arquivo PKL (str)
            - Nome Arquivo MAT (str)
            - Maior Erro Relativo (float)
            - Época (int)
            - Eletrodo (int)
            - Banda de Frequência (str)
        file_name (str): Nome do arquivo de saída que será criado no
        formato .csv.
    """
    with open(file_name, mode='w', newline='', encoding='utf-8') as file:
        writer = csv.writer(file)

        # Cabeçalho com 6 colunas
        writer.writerow([
            "Nome Arquivo PKL",
            "Nome Arquivo MAT",
            "Maior Erro Relativo",
            "Época",
            "Eletrodo",
            "Banda de Frequência"
        ])

        for line in results:
            if len(line) != 6:
                raise ValueError(f'Linha inválida (esperado 6 elementos,
encontrado {len(line)}): {line}')

```

```

# Formata o erro relativo com vírgula
relative_error_formatted = str(line[2]).replace('.', ',,')

writer.writerow([
    line[0], # Nome Arquivo PKL
    line[1], # Nome Arquivo MAT
    relative_error_formatted, # Erro relativo (str, com
vírgula)
    line[3], # Época
    line[4], # Eletrodo
    line[5] # Banda de Frequência
])

def extract_name_files_for_comparation_by_csv(file_path):
"""
    Lê um arquivo CSV (delimitado por ';') e retorna os valores das
    colunas 'pkl_file_name' e 'mat_file_name'.

    Parâmetros:
        file_path (str): Caminho para o arquivo CSV contendo os pares de
        nomes dos arquivos .pkl e .mat.

    Retorna:
        list: Uma lista de dicionários, onde cada dicionário contém as
        chaves 'pkl_file_name' e 'mat_file_name',
        representando os nomes dos arquivos .pkl e .mat que de acordo
        com a correlação entre suas posições,
        formam os pares a serem comparados.
"""
    data = []

    try:
        with open(file_path, mode='r', encoding='utf-8') as file:
            reader = csv.DictReader(file, delimiter=';')

            # Verifica se as colunas esperadas existem no cabeçalho
            if 'pkl_file_name' not in reader.fieldnames or
'mat_file_name' not in reader.fieldnames:
                print("Erro: O arquivo CSV deve conter as colunas
'pkl_file_name' e 'mat_file_name'.")
                return []

            for row in reader:
                pkl_file_name = row['pkl_file_name'].strip()
                mat_file_name = row['mat_file_name'].strip()

                data.append({
                    'pkl_file_name': pkl_file_name,
                    'mat_file_name': mat_file_name
                })
    except FileNotFoundError:
        print(f"Erro: O arquivo '{file_path}' não foi encontrado.")

```

```

except Exception as e:
    print(f"Erro ao ler o CSV de entrada: {e}")
    traceback.print_exc()

return data

def relative_error_by_quantifier(quantifier_name='PCP',
                                 input_csv_path='input_files.csv'):
    """
        Executa a análise de erro relativo entre pares de arquivos .pkl e
        .mat,
        usando o quantificador especificado ('PCP' ou 'FM'), com base em um
        arquivo de entrada CSV.
        O arquivo CSV de entrada possui as seguintes informações:
        - Coluna A (pkl_file_name): Nome do arquivo .pkl
        - Coluna B (mat_file_name): Nome do arquivo .mat

        Parâmetros:
            quantifier_name (str): Quantificador que será analisado ('PCP'
            ou 'FM').
            input_csv_path (str): Caminho do arquivo CSV de entrada contendo
            os pares de arquivos.

        Resultado:
            Arquivo CSV nomeado com o padrão:
            "maiores_erros_{quantifier_name}_{file_input_base_name}.csv"
            Onde:
                - quantifier_name: representa o nome do quantificador
                comparado.
                - file_input_base_name: representa o nome do arquivo CSV
                de entrada

            Este arquivo contém o resultado da comparação com 6 colunas:
            - Coluna A (Nome Arquivos PKL): Nome do arquivo .pkl
            - Coluna B (Nome Arquivo MAT): Nome do arquivo .mat
            - Coluna C (Maior Erro Relativo): Contém os valores de
            maior erro relativo para cada exame
            - Coluna D (Época): Representa em qual época ocorreu o
            maior erro relativo em cada exame
            - Coluna E (Eletrodo): Representa em qual eletrodo
            ocorreu o maior erro relativo em cada exame
            - Coluna F (Banda de Frequência): Representa em qual
            banda de frequência ocorreu o maior erro relativo em cada exame

            As seguintes informações também são impressas no console:
            - O maior erro relativo global.
            - A localização completa do maior erro global (banda de
            frequência, época e eletrodo).
            - Os nomes dos arquivos (MAT e PKL) que representam o par
            onde ocorreu o maior erro global.
            - Mensagem informando que o arquivo CSV com os maiores erros
            de todos os exames foi salvo.
    """
    try:

```

```

        files_info =
extract_name_files_for_comparation_by_csv(input_csv_path)
except Exception as e:
    print(f"Erro ao ler o CSV de entrada: {e}")
    return

# Extrair o diretório do arquivo CSV para usar como base_path
base_path = os.path.dirname(input_csv_path)

# Extrair o nome base do arquivo CSV (ex: 'Mozart', 'Silence')
file_input_base_name =
os.path.splitext(os.path.basename(input_csv_path))[0]

# Variáveis para armazenar o maior erro global
max_global_error = -float('inf')
global_localization = {}
global_name_exam = ""

results = []

print(f"\nIniciando análise {quantifier_name.upper()}...")

# Itera sobre os pares de arquivos obtidos do CSV
for file_data in files_info:
    pkl_file_name = file_data['pkl_file_name']
    mat_file_name = file_data['mat_file_name']

    # Monta o caminho completo com base no diretório do CSV
    pkl_file_path = os.path.join(base_path, pkl_file_name)
    mat_file_path = os.path.join(base_path, mat_file_name)

    compared_pair_file_names = f"{pkl_file_name} (.pkl) / \
{mat_file_name} (.mat)"

    try:
        # Chama a função que calcula o erro máximo
        max_error, localization = max_relative_error(pkl_file_path,
mat_file_path, quantifier_name=quantifier_name)

        if isinstance(max_error, float) and max_error >
max_global_error:
            max_global_error = max_error
            global_localization = localization
            global_name_exam = compared_pair_file_names

        results.append((
            pkl_file_name, # Nome do arquivo .pkl (Coluna A)
            mat_file_name, # Nome do arquivo .mat (Coluna B)
            max_error, # Maior erro relativo (Coluna C)
            localization['Epoca'], # Época (Coluna D)
            localization['Eletrodo'], # Eletrodo (Coluna E)
            localization['Banda'] # Banda de Frequência (Coluna F)
        ))
    
```

```
except Exception as e:
    print(f"Erro ao processar {pkl_file_name} e {mat_file_name}:
{e}")
    traceback.print_exc()

# Salva os resultados em um arquivo CSV
if results:
    name_file_output =
f"maiores_erros_{quantifier_name}_{file_input_base_name}.csv"
    create_csv(results, name_file_output)
    print(f"\n---")
    print(f"Resultado Global ({quantifier_name.upper()} -
{file_input_base_name.capitalize()}:")
        print(f"  Maior erro relativo: {max_global_error:.10e}")
        print(f"  Localização: Banda '{global_localization.get('Banda',
'N/A')}', ")
            f"  Época {global_localization.get('Epoca', 'N/A')}, "
            f"  Eletrodo {global_localization.get('Eletrodo', 'N/A')} ")
    print(f"No par de arquivos: {global_name_exam}")
    print(f"  Tabela '{name_file_output}' salva!")
print(f"\n---")
```

## ANEXO D - EXEMPLO DO ARQUIVO CSV DE ENTRADA PARA O CÓDIGO DO ANEXO C

pkl_file_name	mat_file_name
m1.pkl	m1.mat
m2.pkl	m2.mat
m3.pkl	m3.mat
m4.pkl	m4.mat
m5.pkl	m5.mat
m6.pkl	m6.mat
m7.pkl	m7.mat
m8.pkl	m8.mat
m9.pkl	m9.mat
m10.pkl	m10.mat
m11.pkl	m11.mat
m12.pkl	m12.mat
m13.pkl	m13.mat
m14.pkl	m14.mat
m15.pkl	m15.mat
m16.pkl	m16.mat
m17.pkl	m17.mat
m18.pkl	m18.mat
m19.pkl	m19.mat
m20.pkl	m20.mat
m21.pkl	m21.mat

## ANEXO E – EXEMPLO DO ARQUIVO CSV DE SAÍDA PARA O CÓDIGO DO ANEXO C

Nome Arquivo PKL	Nome Arquivo MAT	Maior Erro Relativo	Época	Eletrodo	Banda de Frequência
m1.pkl	m1.mat	5,1465E-13	2	11	supergama
m2.pkl	m2.mat	5,36223E-13	6	16	supergama
m3.pkl	m3.mat	4,36346E-13	9	18	supergama
m4.pkl	m4.mat	5,20462E-13	3	4	supergama
m5.pkl	m5.mat	4,32006E-13	6	8	supergama
m6.pkl	m6.mat	5,45722E-13	6	6	supergama
m7.pkl	m7.mat	5,30521E-13	4	16	supergama
m8.pkl	m8.mat	5,71683E-13	0	8	supergama
m9.pkl	m9.mat	3,03506E-13	7	7	supergama
m10.pkl	m10.mat	4,91215E-13	8	1	supergama
m11.pkl	m11.mat	5,78787E-13	4	7	supergama
m12.pkl	m12.mat	5,53992E-13	8	16	supergama
m13.pkl	m13.mat	4,86158E-13	9	16	supergama
m14.pkl	m14.mat	9,09861E-13	3	3	ruido
m15.pkl	m15.mat	5,75989E-13	5	6	supergama
m16.pkl	m16.mat	5,67835E-13	9	2	supergama
m17.pkl	m17.mat	5,08806E-13	9	5	ruido
m18.pkl	m18.mat	5,87065E-13	7	18	supergama
m19.pkl	m19.mat	5,06028E-13	4	2	supergama
m20.pkl	m20.mat	5,38657E-13	1	19	supergama
m21.pkl	m21.mat	6,68328E-13	4	19	supergama