UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUÍ
FACULDADE DE ENGENHARIA DE COMPUTAÇÃO

FABLENA KATHLLEN NASCIMENTO DIAS

INTERFACE CÉREBRO-MÁQUINA BASEADA EM POTENCIAIS VISUALMENTE EVOCADOS: ANÁLISE DE EXTRAÇÃO DE ÉPOCAS

TUCURUÍ
2023

FABLENA KATHLLEN NASCIMENTO DIAS

INTERFACE CÉREBRO-MÁQUINA BASEADA EM POTENCIAIS VISUALMENTE EVOCADOS: ANÁLISE DE EXTRAÇÃO DE ÉPOCAS

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia de Computação, do Campus Universitário de Tucuruí, da Universidade Federal do Pará, como requisito parcial para obtenção do título de Bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Cleison Daniel Silva

TUCURUÍ
2023

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

D541i Dias, Fablena Kathllen Nascimento.
INTERFACE CÉREBRO-MÁQUINA BASEADA EM POTENCIAIS VISUALMENTE EVOCADOS: : ANÁLISE DE EXTRAÇÃO DE ÉPOCAS / Fablena Kathllen Nascimento Dias. — 2023.
57 f. : il. color.

Orientador(a): Prof. Dr. Cleison Daniel Silva
Trabalho de Conclusão de Curso (Graduação) - Universidade Federal do Pará, Campus Universitário de Tucuruí, Faculdade de Engenharia da Computação, Tucuruí, 2023.

1. Machine Learning. 2. Brain Computer Interface. 3. Steady State Visual Evoked Potential. I. Título.

CDD 621.3822

FABLENA KATHLLEN NASCIMENTO DIAS

INTERFACE CÉREBRO-MÁQUINA BASEADA EM POTENCIAIS VISUALMENTE EVOCADOS: ANÁLISE DE EXTRAÇÃO DE ÉPOCAS

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia de Computação, do Campus Universitário de Tucuruí, da Universidade Federal do Pará, como requisito parcial para obtenção do título de Bacharel em Engenharia de Computação.

Data da aprovação: ____/____/_____

Conceito: _____

BANCA EXAMINADORA

_____

Prof. Dr. Cleison Daniel Silva
Faculdade de Engenharia Elétrica – UFPA
Orientador

_____

Prof. Dr. Daniel Da Conceição Pinheiro
Faculdade de Engenharia de Computação – UFPA
Membro da Banca Examinadora

_____

Prof. Dr. Bruno Merlin
Faculdade de Engenharia de Computação – UFPA
Membro da Banca Examinadora

Dedico a todos que partiram de cidades pequenas com sonhos grandes, que este seja uma prova de que a educação é a chave para desbravar horizontes e transformar realidades. Este trabalho é dedicado aos que ousam sonhar.

AGRADECIMENTOS

Nenhuma combinação de palavras do dicionário poderia expressar corretamente a imensa gratidão que sinto por aquela que é responsável pela geração da minha vida, a quem tenho a honra de chamar de mãe, Kemi Nascimento Dias. Cada fibra do meu ser carrega um reflexo de você, hoje só posso afirmar com convicção que sou a pessoa que sou, pois você é quem você é. Suas lições, sua coragem, seu amor e sua força são o impulso que alimenta a minha jornada em busca pelos meus objetivos. Obrigada por ser a minha luz. Amo você além das palavras.

Aos meus familiares que me incentivaram e sempre serviram de base quando eu não estava me sentindo bem, agradeço do fundo do meu coração por estarem sempre presentes. Em especial ao meu irmão, ao meu pai e a minha namorada que são fonte constante de alegria, apoio e compreensão.

Aos meus amigos da Fecomp18 pela valiosa troca de conhecimento, pelos grupos de estudos dedicados a provas e trabalhos, pelas orientações e pela disposição.

Em particular, desejo destacar e expressar a minha gratidão ao meu trio de trabalho acadêmico, Roberta da Silva Paiva e Asaf Gama Silva de Souza. Vocês desempenharam papéis cruciais em minha jornada acadêmica, sendo fontes inestimáveis de apoio e inspiração. Agradeço, especialmente, ao Romulo Matheus da Silva Dantas, um amigo de faculdade que transcendeu os limites acadêmicos, se tornando um amigo para a vida inteira.

Ao meu orientador, Prof. Dr. Cleison Daniel Silva, por compartilhar seu conhecimento e se dedicar não somente a mim, mas a todos os seus orientandos. Foi uma honra poder aprender com um excelente profissional e educador.

“Sejam fortes e corajosos. Não tenham medo nem fiquem apavorados por causa delas, pois o Senhor, o seu Deus, vai com vocês; nunca os deixará, nunca os abandonará.”

(Deuteronômio 31:6)

RESUMO

A Interface Cérebro-Máquina (ICM) busca não apenas compreender, mas também otimizar os complexos processos neurais, estabelecendo uma comunicação entre o cérebro e um dispositivo eletrônico. A neurociência aplicada à ICM envolve o estudo dos sinais cerebrais para identificar padrões associados a intenções específicas, permitindo a criação de algoritmos capazes de interpretar essas intenções em comandos para controle de dispositivos, a evolução dessa área promissora se destaca por impulsionar a compreensão dos processos cerebrais e oferecer soluções práticas, como melhorias na qualidade de vida para pessoas com limitações motoras. Os sistemas ICM baseados em *Steady State Visually Evoked Potential* (SSVEP) usam respostas cerebrais a qualquer estímulo visual piscando em uma frequência constante como comando de entrada para um aplicativo ou dispositivo externo, embora seja amplamente utilizado para muitas aplicações, existem características do sistema que devem ser analisadas e discutidas visando aumentar o desempenho da aplicação. Este estudo aborda o pré-processamento, extração de características e classificação nas etapas de processamento digital de sinais em uma ICM baseada SSVEP. Os resultados incluem análises comparativas da extração de épocas em cinco diferentes tamanhos (2s, 1s, 500ms, 250ms, 125ms) para sinais de eletroencefalograma (EEG) em uma Interface Cérebro-Máquina diante de estímulos em três frequências distintas de SSVEP (8Hz, 14Hz e 28Hz). As acurácias de classificação são apresentadas para cada análise. Os resultados obtidos por meio da classificação do sistema revelam que épocas com durações maiores apresentam melhor desempenho. Entretanto, é notório que, ao analisar épocas com menor duração, estas possuem desempenho razoável, oferecendo eficácia para o cenário e proporcionando maior número de comandos aplicáveis em uma configuração de ICM-SSVEP.

Palavras-chave: Interface Cérebro-Máquina. Steady State Visually Evoked Potential. Processamento Digital de Sinais. Extração de Épocas.

ABSTRACT

The Brain-Computer Interface (BCI) seeks not only to understand, but also to optimize complex neural processes, establishing communication between the brain and an electronic device. Neuroscience applied to BCI involves studying brain signals to identify patterns associated with specific intentions, allowing the creation of algorithms capable of interpreting these intentions into commands to control devices, the evolution of this promising area stands out for boosting the understanding of brain processes and offering practical solutions, such as improvements in the quality of life for people with motor limitations. BCI systems based on Steady State Visually Evoked Potential (SSVEP) use brain responses to any visual stimulus flashing at a constant frequency as input command to an application or external device, although it is widely used for many applications, there are system characteristics that must be analyzed and discussed to increase the application's performance. This study addresses pre-processing, feature extraction and classification in the digital signal processing steps in an SSVEP-based BCI. The results include comparative analyzes of the extraction of epochs in five different sizes (2s, 1s, 500ms, 250ms, 125ms) for electroencephalogram (EEG) signals in a Brain-Computer Interface in front of stimuli at three different SSVEP frequencies (8Hz, 14Hz and 28Hz). Classification accuracies are presented for each analysis. The results obtained through the system classification reveal that epochs with longer durations present better performance. However, when analyzing shorter duration epochs, they have reasonable performance, offering efficiency for the scenario and providing a greater number of commands applicable in an BCI-SSVEP configuration.

Keywords: Brain-Computer Interface. Steady State Visually Evoked Potential. Digital Signal Processing. Extraction of Epochs.

LISTA DE ILUSTRAÇÕES

Figura 1: Áreas funcionais do córtex cerebral. Fonte: SILVERTHORN, D. U. (2017). 18
Figura 2: Mapeamento com a localização e a nomenclatura dos eletrodos intermediários de 10%. Fonte: Sociedade Americana de Eletroencefalografia. 21
Figura 3: Etapas de uma Interface Cérebro-Máquina (ICM). Fonte: Autoria própria. 23
Figura 4: Exemplo do experimento e da duração. Fonte: Autoria própria. 27
Figura 5: (a) Sinal bruto; (b) Sinal filtrado em 8Hz; (c) sinal filtrado em 14Hz; (d) Sinal filtrado em 28Hz. Fonte: Autoria própria. 29
Figura 6: Esquema do processo de extração de épocas. Primeiro o sinal bruto passa por um banco de filtro onde ocorre a limpeza do sinal, depois é dividido em épocas distintas. Fonte: Autoria própria.. 30
Figura 7: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 2s. Fonte: Autoria própria. 32
Figura 8: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 1s. Fonte: Autoria própria. 32
Figura 9: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 500ms. Fonte: Autoria própria. 33
Figura 10: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 250ms. Fonte: Autoria própria. 33
Figura 11: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 125ms. Fonte: Autoria própria. 34
Figura 12: Diagrama do processo de criação da matriz de características. Fonte: Autoria própria. 35
Figura 13: Matriz de confusão para decisão binária, uma classe representa a primeira frequência e a outra classe representa a segunda frequência. Fonte: Autoria própria. 37
Figura 14: Desempenho do Sujeito 1 para o classificador LDA combinado em 8Hz e 14Hz, para todas as épocas. Fonte: Autoria própria. 39
Figura 15: Desempenho do Sujeito 1 para o classificador LDA combinado em 8Hz e 28Hz, para todas as épocas. Fonte: Autoria própria. 40
Figura 16: Desempenho do Sujeito 1 para o classificador LDA combinado em 14Hz e 28Hz, para todas as épocas. Fonte: Autoria própria. 40
Figura 17: Desempenho do Sujeito 2 para o classificador LDA combinado em 8Hz e 14Hz, para todas as épocas. Fonte: Autoria própria. 41
Figura 18: Desempenho do Sujeito 2 para o classificador LDA combinado em 8Hz e 28Hz, para todas as épocas. Fonte: Autoria própria. 42
Figura 19: Desempenho do Sujeito 2 para o classificador LDA combinado em 14Hz e 28Hz, para todas as épocas. Fonte: Autoria própria. 42

Figura 20: Desempenho do Sujeito 3 para o classificador LDA combinado em 8Hz e 14Hz, para todas as épocas. Fonte: Autoria própria. 43
Figura 21: Desempenho do Sujeito 3 para o classificador LDA combinado em 8Hz e 28Hz, para todas as épocas. Fonte: Autoria própria. 44
Figura 22: Desempenho do Sujeito 3 para o classificador LDA combinado em 14Hz e 28Hz, para todas as épocas. Fonte: Autoria própria. 44
Figura 23: Desempenho do Sujeito 4 para o classificador LDA combinado em 8Hz e 14Hz, para todas as épocas. Fonte: Autoria própria. 45
Figura 24: Desempenho do Sujeito 4 para o classificador LDA combinado em 8Hz e 28Hz, para todas as épocas. Fonte: Autoria própria. 46
Figura 25: Desempenho do Sujeito 4 para o classificador LDA combinado em 14Hz e 28Hz, para todas as épocas. Fonte: Autoria própria. 46

LISTA DE TABELAS

Tabela 1: Faixa de frequência dos ritmos do EEG. Fonte: TAVARES, 2011. 20
Tabela 3: Bibliotecas utilizadas. Fonte: Autoria própria. 26

LISTA DE ABREVIATURAS E SIGLAS

ICM	INTERFACE CÉREBRO-MÁQUINA
BCI	BRAIN COMPUTER INTERFACE
SSVEP	STEADY STATE VISUAL EVOKED POTENTIAL
EEG	ELETROENCEFALOGRAMA
ICM-SSVEP	INTERFACE CÉREBRO-MÁQUINA BASEADO EM STEADY STATE VISUAL EVOKED POTENTIAL
Hz	HERTZ
S	SEGUNDO
Ms	MILISSEGUNDOS
Fp	FRONTAL POLAR
F	FRONTAL
C	CENTRAL
T	TEMPORAL
P	PARIENTAL
O	OCCIPITAL
Oz	OCCIPITAL CENTRAL
PSD	POWER SPECTRUM DENSITY
LDA	LINEAR DISCRIMINANT ANALYSIS
VP	VERDADEIRO POSITIVO
VN	VERDADEIRO NEGATIVO
FP	FALSO POSITIVO
FN	FALSO NEGATIVO
CCA	CANONICAL COMPONENT ANALYSIS

SUMÁRIO

1 INTRODUÇÃO 15
2 FUNDAMENTAÇÃO TEÓRICA 17
2.1 ANATOMIA CEREBRAL 17
2.1.1 LOBOS CEREBRAIS 18
2.1.1.1 LOBO OCCIPITAL 18
2.2 ELETROENCEFALOGRAMA 19
2.2.1 POSICIONAMENTO DOS ELETRODOS 20
2.3 APRENDIZADO DE MÁQUINA 21
2.4 INTERFACE CÉREBRO-MÁQUINA (ICM) 22
2.4.1 STEADY STATE VISUALLY EVOKED POTENTIAL (SSVEP) 23
3 METODOLOGIA 25
3.1 LINGUAGEM DE PROGRAMAÇÃO E BIBLIOTECAS 25
3.1.1 AMBIENTE DE DESENVOLVIMENTO 26
3.2 MATERIAIS E MÉTODOS 26
3.2.1 AQUISIÇÃO DE SINAL 27
3.2.2 PRÉ-PROCESSAMENTO 27
3.2.2.1 FILTRO PASSA-FAIXA 28
3.2.3 EXTRAÇÃO DE CARACTERÍSTICA 29
3.2.3.1 EXTRAÇÃO DE ÉPOCAS 29
3.2.3.2 MÉTODO DO PERIODOGRAMA 30
3.2.4 CLASSIFICAÇÃO 34
3.2.4.1 ANÁLISE DO DISCRIMINANTE LINEAR (LDA) 35
3.2.5 MÉTRICAS 36
4 RESULTADOS E DISCUSSÕES 39
4.1 SUJEITO 1 39
4.2 SUJEITO 2 41
4.3 SUJEITO 3 43
4.4 SUJEITO 4 45
5 CONCLUSÃO 48
6 SUGESTÕES PARA TRABALHOS FUTUROS 49
REFERÊNCIAS BIBLIOGRÁFICAS 50
ANEXO A – LINK DE ACESSO AO REPOSITÓRIO DO GITHUB 52

ANEXO B – ARTIGO PUBLICADO..... 53

1 INTRODUÇÃO

O cérebro humano detém funções indispensáveis e que são essenciais para o bom funcionamento do corpo, ele é responsável por coordenar as funções motoras, sensoriais e cognitivas do corpo humano. Para investigar de forma eficaz o bom funcionamento deste órgão, algumas áreas de estudos se dedicaram a desenvolver conhecimentos específicos sobre o funcionamento do cérebro humano, resultando simultaneamente a esse desenvolvimento o surgimento da Interface Cérebro-Máquina (ICM) (SOUZA et al., 2015).

A ICM é uma técnica que permite a comunicação direta entre o cérebro e uma máquina, permitindo que pessoas com deficiências motoras ou sensoriais possam controlar dispositivos externos. As técnicas de ICM não têm a capacidade de ler mentes ou decifrar pensamentos, em vez disso, seu objetivo é interpretar a intenção do usuário por meio do monitoramento da atividade cerebral (SOUZA et al., 2015).

O fenômeno neurofisiológico utilizado para decodificar a intenção do usuário da ICM pode variar, sendo o *Steady-State Visually Evoked Potential* (SSVEP) o mais comum, pois é relativamente fácil de gerar e de processar os sinais resultantes. O SSVEP é gerado pela atividade neural em resposta a um estímulo visual com frequência constante e ocorre no córtex visual, localizado no lobo occipital, área responsável pela percepção visual. Quando o usuário focaliza o olhar em uma frequência de estímulo permanente é possível observar um aumento da atividade cerebral na mesma frequência e harmônicos, na região do córtex visual (GARCIA-MOLINA; ZHU, 2011).

O cérebro reage com uma resposta elétrica na frequência correspondente ao estímulo visual que o usuário está prestando atenção. Um dos métodos utilizados para capturar os sinais cerebrais é o Eletroencefalograma (EEG) que consiste em uma técnica de neuroimagem e é definido como um método não invasivo, onde os sinais elétricos são coletados por eletrodos em contato com couro cabeludo. Esses sinais representam o fluxo de correntes elétricas que são observáveis durante as excitações sinápticas neurais (VILAS BOAS, 2021).

Na literatura sobre o desempenho de sistemas ICM baseados em SSVEP, inúmeras pesquisas têm se dedicado a examinar a eficácia de diferentes métodos para a classificação de sinais e extração de características. No que se refere a extração de épocas, alguns estudos utilizam épocas de estímulos com uma duração fixa de 2 ou 3 segundos conforme proposto

por Bakardjian, Tanaka e Cichocki (2010), e por Carvalho et al. (2015), enquanto outros buscam relacionar a acurácia da classificação dos sinais e a variação da duração das épocas, abrangendo intervalos de 1 a 3 segundos, como mostrado por Giuliani et al. (2021) e por Ma et al. (2022).

Em ambientes onde a agilidade de um sistema seja imprescindível, nota-se que o uso de épocas com duração menor, em comparação com os estudos mencionados, proporciona vantagens significativas. Essa abordagem permite que o sistema responda mais rápido aos estímulos, sendo uma escolha estratégica para eventos que necessitam de respostas ágeis.

Este trabalho tem como objetivo realizar a análise comparativa da extração de épocas com cinco tamanhos diferentes de sinais de eletroencefalograma (EEG) de sistema Interface Cérebro-Máquina na presença de estímulos em 3 frequências distintas de SSVEP: 8Hz, 14Hz e 28Hz. Para avaliar o desempenho de classificação de um sistema ICM-SSVEP ao processar sinais de EEG, as épocas possuem tempo com duração igual ou inferior a 2 segundos, desta forma, possibilitando respostas rápidas aos sistemas.

Os objetivos específicos são definidos a fim de alcançar o objetivo geral deste trabalho e são descritos a seguir: Conhecer o conjunto de dados utilizado para o desenvolvimento; aplicar técnicas de filtragem de sinal; implementar as extrações de épocas para cinco as épocas distintas: 2s, 1s, 500ms, 250ms, 150ms; aplicação do método de Periodograma; realizar classificação binária entre as frequências e comparar os resultados obtidos.

A pesquisa realiza a análise comparativa de cinco épocas de sinais de EEG com duração diferente para cada um dos sujeitos e estímulos disponibilizados. Destaca-se que quanto maior da duração da época maior tende a ser a acurácia de classificação do sistema ICM-SSVEP. Porém, a utilização de épocas com menor duração, como as épocas de 125ms ou 250ms podem proporcionar maior quantidade de comandos gerados pelo sistema ICM-SSVEP por unidade tempo.

2 FUNDAMENTAÇÃO TEÓRICA

A fundamentação teórica apresentada neste capítulo, além de realizar a revisão da literatura, está relacionada a compreensão da interface cérebro-máquina. Particularidades relacionadas a anatomia cerebral, captura de sinais, aprendizado de máquina e paradigma SSVEP são mostradas com detalhes para auxiliar no entendimento da pesquisa e na realização dos objetivos propostos para este trabalho.

2.1 ANATOMIA CEREBRAL

De acordo com Santos (2002), o cérebro, um órgão notavelmente complexo, reflete as complexidades do mundo ao ser responsável por funções como inteligência, memória, consciência e linguagem. Ele exerce controle sobre sensações e órgãos, trabalhando em conjunto com outras partes do encéfalo. Santos destaca que o cérebro é considerado o ápice da evolução, sendo o único órgão consciente de si mesmo. Assim, para a melhor compreensão da ICM, faz-se necessário compreender o funcionamento básico do cérebro e das suas atividades.

Derivado do telencéfalo, o cérebro é a parte mais desenvolvida do encéfalo sendo composto por membranas finas, porém protetoras, que possuem o nome de meninges, ele é constituído por células da glia e neurônios. Estima-se que o encéfalo humano adulto contenha cerca de cem bilhões de neurônios (MARTIN, 2013). Reconhecido como a unidade funcional primária do sistema nervoso, o neurônio facilita a transmissão dos impulsos por meio da sinapse, dendritos e axônios. O cérebro e a medula espinhal enviam comandos aos sistemas e órgãos orgânicos por meio dos nervos (SANTOS, 2002).

Os neurônios possuem extensões por meio das quais estabelecem redes, comunicando-se uns com os outros, em alguns casos essas extensões chegam a ter vários centímetros (IZQUIERDO, 2018). As extensões que transmitem informações na forma de sinais elétricos para outros neurônios são chamadas de axônios, por outro lado as extensões que recebem as informações dos axônios são chamadas de dendritos. De acordo com Izquierdo (2018) “Os pontos onde as terminações axônicas mais se aproximam dos dendritos se chamam sinapses, as quais são os pontos reais de intercomunicação de células nervosas”.

2.1.1 LOBOS CEREBRAIS

O cérebro consiste em dois hemisférios cerebrais (direito e esquerdo) e em que cada um dos seus hemisférios são divididos em quatro lobos dissemelhantes: o frontal, o parietal, o occipital e o temporal (Figura 1).

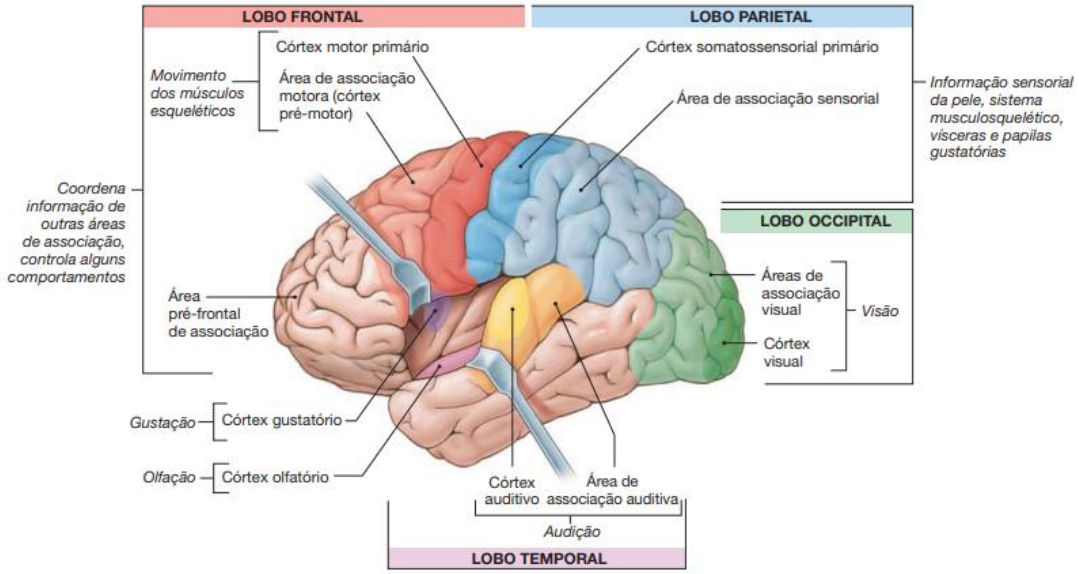


Figura 1: Áreas funcionais do córtex cerebral. Fonte: SILVERTHORN, D. U. (2017).

A pesquisa de Silverthon (2017) diz que o córtex cerebral exerce a função de centro integrador para a informação sensorial e atua também como uma região de tomada de decisão para diferentes tipos de respostas motoras. Com base em análises, o córtex cerebral pode ser dividido em três áreas principais:

- Áreas sensoriais: responsáveis por receber e processar estímulos sensoriais, traduzindo-os em percepções conscientes;
- Áreas motoras: responsáveis por direcionar o movimento do músculo esquelético;
- Áreas de associação: que integram os estímulos recebidos, permitindo a elaboração de comportamentos voluntários.

2.1.1.1 LOBO OCCIPITAL

O Lobo Occipital é o menor lobo do cérebro e fica localizado na região posterior da cabeça, essas estruturas são responsáveis pela percepção visual, englobando elementos como

cor, forma e movimento. Além disso, o Lobo Occipital está ligado ao córtex visual primário e as áreas de associação visual conforme a Figura 1. Ao ocorrer lesões no córtex visual primário, pode-se observar o desenvolvimento de cegueira cortical, como na síndrome de Anton. Nessa condição, os pacientes não são capazes de reconhecer objetos visualmente e muitas vezes não percebem sua deficiência, fazendo descrições imaginárias do que veem (HUANG, 2021).

Essa área do cérebro é responsável pelo processamento da informação visual, sendo que o nível de desempenho desta região pode ser medido através da energia da atividade elétrica cerebral. Através da variação desta energia, é possível identificar se a pessoa está com os olhos abertos ou fechados, se está concentrada ou relaxada, ou ainda se está recebendo um estímulo luminoso de frequência conhecida (BUENO, 2017).

2.2 ELETROENCEFALOGRAMA

O Eletroencefalograma (EEG) é um método de neuroimagem que pode ser definido como um método não-invasivo, onde os sinais elétricos são coletados por eletrodos colocados em contato com o couro cabeludo. Esses sinais representam o fluxo de correntes elétricas que são observáveis durante as excitações sinápticas neuronais (VILAS BOAS, 2021). A comunicação eletroquímica entre os neurônios ocasiona nas atividades elétricas do cérebro que corresponde ao fluxo de informações e ocorre em diferentes regiões, dependendo da atividade.

A detecção do sinal é feita por meio de eletrodos que podem ser passivos, fazendo uso de um gel ou pasta condutora, ou através de eletrodos ativos que possuem circuito de pré-amplificação integrado (BARROS, 2005). Em geral, os eletrodos passivos são mais adequados para uso em aplicações de curto prazo, enquanto os eletrodos ativos são mais apropriados para aplicações de longo prazo (YOO; YOO, 2011). Isso acontece porque com o passar do tempo ocorre desidratação do gel eletrolítico nos eletrodos passivos, o que leva a uma mudança na impedância do eletrodo durante o monitoramento contínuo (PRUTCHI; NORRIS, 2005).

Com base nas pesquisas de Tavares (2011), o ritmo alfa é caracterizado por sinais com amplitude na faixa de 20 a 200 μV e frequência entre 8 e 13 Hz, sendo mais bem detectado sobre a região occipital. Este ritmo aparece com maior intensidade em sujeitos normais, em estado desperto, sem realizar nenhuma atividade e com os olhos fechados. Já o ritmo beta apresenta frequências compreendidas na faixa dos 14 Hz aos 30 Hz, raramente chegando aos 50 Hz, seguindo com o ritmo teta que está associado ao estado de sonolência, sendo mais comum na infância, a faixa de frequências para este ritmo situa-se entre os 4 e os 7 Hz. Por fim, o pesquisador relata sobre o ritmo delta é o mais lento dentre os citados, sendo composto por ondas com frequência igual ou inferior a 3 Hz.

Ritmos	Frequência (Hz)	Descrição
Alfa	8 – 13	Occipital, associado com sujeito desperto e relaxado; mais intenso com os olhos fechados.
Beta	14 – 30	Mais evidente nas derivações frontais-parietais; mais bem observado com alfa bloqueado
Delta	1 – 3	Presente em: crianças com menos de 1 ano; durante o sono normal; em doenças do cérebro; em anestesia profunda
Teta	4 – 7	Predominante em crianças dos 2 aos 5 anos; mais evidente nas derivações parietais-temporais

Tabela 1: Faixa de frequência dos ritmos do EEG. Fonte: TAVARES, 2011.

2.2.1 POSICIONAMENTO DOS ELETRODOS

Os impulsos elétricos emitidos pelo cérebro podem ser captados através de exames utilizando eletrodos EEG, esses eletrodos são conectados a um monitor do aparelho de eletroencefalograma que transmite os sinais e permite sua conversão em gráficos de linha. Os eletrodos coletam correntes elétricas emitidas pelos neurônios e envia para o monitor, para isso, o posicionamento dos eletrodos deve ser ajustado de forma correta.

Segundo Marinho (2017), é importante que a colocação dos eletrodos seja determinada por medidas específicas, utilizando pontos de referência no crânio que levem em consideração o tamanho e a forma individual do paciente, sempre que possível. Os eletrodos são denominados de forma padrão com uma letra que é baseada na região cerebral e um número indicando a sua lateralização. Assim, como apresentado na Figura 2 tem-se Fp para frontal polar, F para frontal, C para central, T para temporal, P para parietal e O para Occipital.

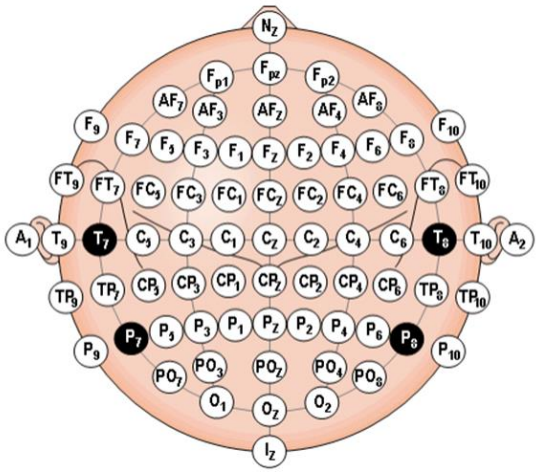


Figura 2: Mapeamento com a localização e a nomenclatura dos eletrodos intermediários de 10%.
Fonte: Sociedade Americana de Eletroencefalografia.

2.3 APRENDIZADO DE MÁQUINA

Com a crescente complexidade dos problemas computacionais e do volume de dados, tornou-se evidente a necessidade da criação de ferramentas computacionais sofisticadas e autônomas, restringindo qualquer interferência humana (FACELI et al. 2011). Posteriormente, com a aparente necessidade, algumas técnicas foram criadas com intuito de resolver problemas a partir de experiências passadas dando origem ao Aprendizado de Máquina.

O Aprendizado de Máquina é um subcampo da Inteligência Artificial que se concentra no desenvolvimento de algoritmos utilizando dados estatísticos para aprender a reconhecer padrões e tomar decisões automatizadas. O conceito de aprendizado de máquina foi apresentado algumas vezes na literatura e dentre elas está a definição de Mitchell (1997) que diz que Aprendizado de Máquina é a capacidade de melhorar a performance durante a realização de tarefas por meio das experiências adquiridas.

Decerto que para se ter um comportamento inteligente, é imprescindível o processo de aprendizagem. Segundo Faceli et al. (2011), atividades envolvendo memorização, observação e exploração para adquirir conhecimento, aprimorar habilidades motoras/cognitivas e organizar novas informações para representações adequadas podem ser consideradas atividades relacionadas ao aprendizado.

Em síntese, o processo de aprendizagem de máquina surgiu com o propósito de solucionar problemas computacionais complexos e tem buscado eficácia na realização de aplicações que hoje são utilizadas constantemente.

2.4 INTERFACE CÉREBRO-MÁQUINA (ICM)

A Interface Cérebro-Máquina (BCI, do inglês *Brain Computer Interface*) é uma tecnologia que permite a interação direta entre a atividade cerebral do usuário e dispositivos específicos que não dependem dos músculos e nervos periféricos. As BCIs traduzem intenção, pensamento e respostas a estímulos externos em comandos de controle de entrada, permitindo ao usuário operar dispositivos ou aplicativos externos (ZAMBALDE, 2018).

Atualmente, as abordagens de processamento de sinais cerebrais distinguem entre EEG espontâneo e evocado. EEG espontâneo refere-se à medição de ondas cerebrais contínuas, incluindo o delta (até 4Hz), ondas teta (4-8Hz), alfa (8-12Hz), beta (12-30Hz) e gama (30-100+Hz), enquanto o EEG evocado representa potenciais cerebrais com duração limitada que são registrados em resposta a estímulos específicos, como visual, auditivo, somatossensorial ou olfativo (NAMAZI et al., 2018). Desta forma, a ICM pode ser baseada tanto por sinais cerebrais espontâneos quanto por evocados.

A estrutura padrão que compõe uma ICM pode ser simplificadamente dividida, conforme ilustrado na Figura 3. As etapas organizadas nesse esquema incluem a aquisição de dados por meio do método de eletroencefalograma, o processamento de sinal, a implementação de comandos, a aplicação em algum dispositivo e o feedback que se refere à comunicação entre o sistema e o usuário, proporcionando informações sobre o estado do sistema ou as ações realizadas pelo usuário.

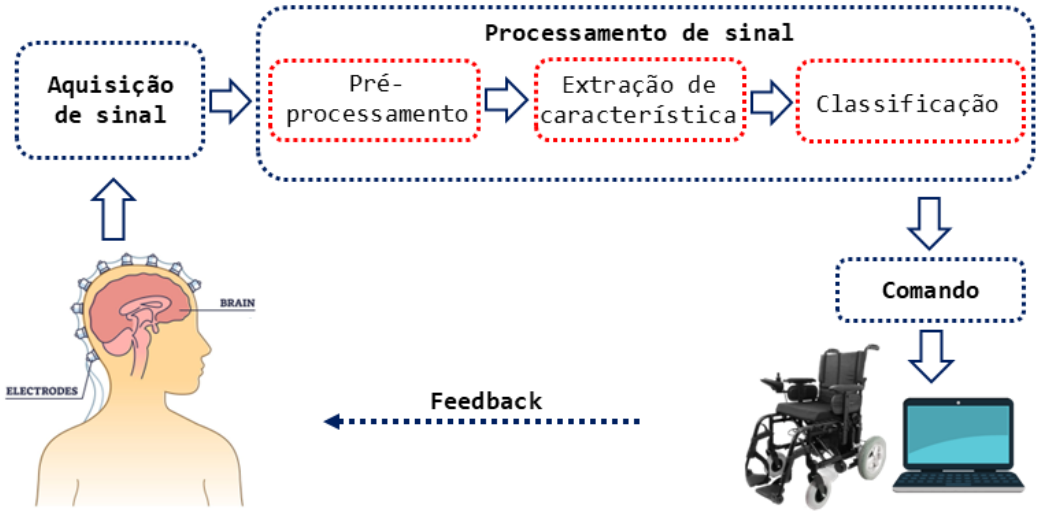


Figura 3: Etapas de uma Interface Cérebro-Máquina (ICM). Fonte: Autoria própria.

Inicialmente, os dados correspondentes à atividade cerebral são coletados por meio de eletrodos. A etapa de processamento digital do sinal cerebral se particiona em pré-processamento, extração de características e classificação: O pré-processamento busca melhorar a qualidade do sinal em termos de sua relação sinal/ruído; Na extração de características, são calculados parâmetros que possibilitam identificar e distinguir os comandos que o usuário pretende realizar; A classificação gera o comando de controle com base nas características do sinal de entrada, que, por meio de uma interface, pode ser empregado em uma aplicação específica.

2.4.1 STEADY STATE VISUALLY EVOKED POTENTIAL (SSVEP)

O Potencial Visualmente Evocado de Regime Estacionário (SSVEP, do inglês *Steady State Visually Evoked Potential*) é gerado pela atividade neural em resposta a uma frequência constante e ocorre no córtex visual, localizado no lobo occipital, área responsável pela percepção visual. Quando o usuário foca o olhar em uma frequência de estímulo permanente, é possível observar um aumento da atividade cerebral na mesma frequência e nas harmônicas, na região do córtex visual (GARCIA-MOLINA; ZHU, 2011).

A Interface Cérebro-Máquina baseada em SSVEP pode ser usada para controlar uma variedade de dispositivos, como próteses robóticas, cadeiras de rodas ou um teclado virtual.

Para isso, o usuário é apresentado a uma série de estímulos visuais piscantes, cada um com uma frequência diferente. O SSVEP reflete no sinal EEG a frequência dos estímulos visuais observados pelo usuário em uma tela de vídeo ou outra fonte de estímulo (GARCIA, 2014).

Quando o usuário está focado a sua atenção para uma frequência de estímulo constante, o cérebro responde gerando uma resposta elétrica em uma frequência correspondente a esse estímulo visual. Essa resposta, capturada através do eletroencefalograma, pode ser utilizada para efetuar o controle de uma máquina, estabelecendo uma conexão entre a atividade cerebral do indivíduo e as ações operacionais do sistema.

3 METODOLOGIA

No desenvolvimento deste trabalho, foi empregada uma metodologia destinada à análise de duas fases, incluindo a linguagem de programação, os materiais e os métodos. Inicialmente, apresenta-se a linguagem de programação utilizada, suas bibliotecas e o ambiente de desenvolvimento. Posteriormente, são discutidos os materiais e métodos empregados no desenvolvimento das etapas que compõem a ICM.

3.1 LINGUAGEM DE PROGRAMAÇÃO E BIBLIOTECAS

Criada por Guido Van Rossum[1] e lançada pela primeira vez em 1991, *Python* é uma linguagem de programação de alto nível, legível, interpretada, multiplataforma, funcional, orientada a objetos, possui *frameworks* populares e sintaxe clara. Em resumo, a linguagem foi projetada com o objetivo de ser fácil de aprender e usar, por essa razão, tornou-se a favorita tanto para os desenvolvedores iniciantes quanto para os que possuem experiência na área. A capacidade de integração com outras linguagens, o sistema de bibliotecas sofisticadas, os comandos especializados para diversas áreas de conhecimento tornaram o *Python* um ecossistema avançado. A seguir serão apresentadas as bibliotecas utilizadas para o desenvolvimento deste projeto.

Biblioteca	Função
NUMPY	O NumPy possui suporte a operações matemáticas avançadas, álgebra linear e funcionalidades de indexação. Foi projetado para melhorar o desempenho computacional e simplificar a implementação de tarefas relacionadas a computação científica, fornecendo uma infraestrutura eficiente para a manipulação de dados.
MATPLOTLIB	O Matplotlib é amplamente utilizado para visualização de dados, ele visa permitir que os usuários gerem gráficos de alta qualidade com facilidade, controlando detalhes estéticos e personalizando

[1] https://computerhistory.org/profile/guido-van-rossum/

	visualizações conforme necessário.
SCIPY	O SciPy complementa o NumPy, oferecendo algoritmos especializados e métodos numéricos avançados para aplicações científicas. Ele visa preencher as lacunas deixadas pelo NumPy, adicionando módulos especializados como otimização, processamento de sinais, estatísticas, entre outros.
SKLEARN	Scikit-learn (sklearn), é uma biblioteca em Python para aprendizado de máquina e mineração de dados. Ela oferece uma ampla variedade de ferramentas e algoritmos para tarefas como classificação, regressão, agrupamento, redução de dimensionalidade, seleção de modelos e pré-processamento de dados.

Tabela 2: Bibliotecas utilizadas. Fonte: Autoria própria.

3.1.1 AMBIENTE DE DESENVOLVIMENTO

O ambiente de desenvolvimento utilizado para o desenvolvimento da pesquisa foi o *Google Colaboratory*[2]. O *Google* oferece um serviço de nuvem gratuito hospedado por ele mesmo, com o objetivo de incentivar a pesquisa em Aprendizado de Máquina e Inteligência Artificial. Além disso, o *Google Colaboratory* é um ambiente colaborativo que permite que os usuários possam compartilhar seus códigos para que outros indivíduos sejam capazes de executar e modificar.

3.2 MATERIAIS E MÉTODOS

O objetivo desta seção é descrever os materiais e métodos utilizados na experimentos. A aquisição de sinal de EEG é explicada inicialmente. Em sequência, é mostrado o pré-processamento onde é filtrado o sinal. Após, é relatado sobre a extração de característica, onde ocorre a extração de épocas e a aplicação do método de Periodograma. Por fim, é exibido o classificador utilizado para obter o desempenho do sistema.

[2] https://colab.research.google.com

3.2.1 AQUISIÇÃO DE SINAL

O conjunto de dados utilizado nesta pesquisa tem os direitos autorais da base de dados detida pela RIKEN-LABSP e pelo Dr. Hovagim Bakardjian, e está disponível em um repositório[3] de domínio público. O conjunto em questão contém os sinais EEG de 4 sujeitos submetidos a 3 diferentes frequências de estimulação SSVEP (8 Hz, 14 Hz e 28 Hz), sendo disponibilizado para cada sujeito 5 arquivos distintos para cada estímulo de frequência, representando cada tentativa. Os dados aquisitados contém 128 sinais de EEG, cada eletrodo é posicionado no escalpo de acordo com o padrão 10−10 de posicionamento internacional, exibido na Figura 2, porém para esse estudo específico foi utilizado apenas o eletrodo principal do lobo occipital (*Oz*).

Na documentação, o experimento conta com a frequência de amostragem é de 256 Hz, proporcionando 256 amostras por segundo em cada eletrodo. A duração completa do experimento é de 24 segundos por tentativa e o período do estímulo visual ocorre de 5 segundos a 20 segundos, conforme mostrado na Figura 4.

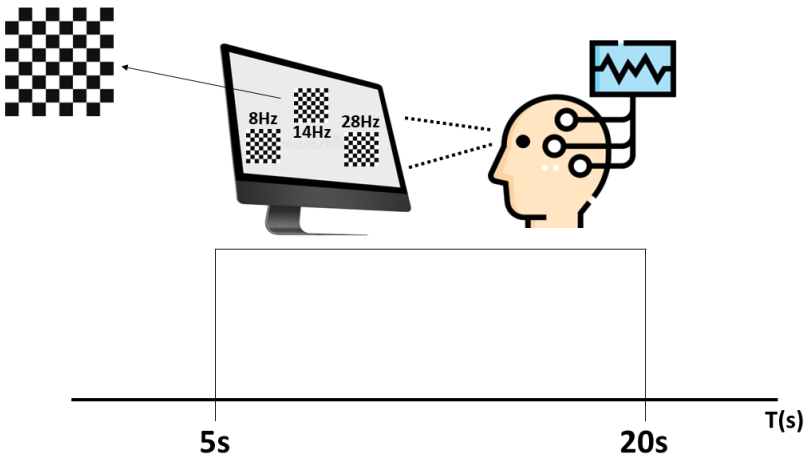


Figura 4: Exemplo do experimento e da duração. Fonte: Autoria própria.

3.2.2 PRÉ-PROCESSAMENTO

O pré-processamento de dados é um procedimento crucial, ele permite preparar e organizar os dados para análise e predições posteriores. Essa fase é essencial para garantir a qualidade dos resultados, pois quando o sinal EEG é coletado ele apresenta diversos sinais de

[3] http://www.bakardjian.com/work/ssvep_data/readme.txt

ruídos e interferências que frequentemente mascaram o sinal de resposta do indivíduo ao estímulo visual (JÚNIOR, 2017).

3.2.2.1 FILTRO PASSA-FAIXA

Um dos objetivos primários do uso de filtros em processamento de sinais é reduzir o ruído para preservar o sinal de interesse. O filtro passa banda busca identificar a informação dos sinais e atenuar ruídos, mantendo o conteúdo espectral em uma faixa de interesse. Contudo, para aplicá-los, é necessário definir parâmetros que delimitam a faixa de frequências desejada (VILAS BOAS, 2021).

Os estímulos visuais, SSVEP, tendem a modular a atividade elétrica cerebral na mesma frequência do estímulo. Assim, a detecção de estímulos na frequência F_0 pode ser realizada filtrando os sinais de EEG numa banda de frequência centrada em torno de F_0. Para realçar e preservar as informações espectrais em torno do estímulo, é comum utilizar filtros passa-faixa. Os filtros necessitam de parâmetros que definem a faixa de frequências de interesse, como o intervalo $\Delta f = [F_l, F_u]$, onde F_l e F_u representam as frequências de corte inferior e superior em *Hertz*, respectivamente (VILAS BOAS, 2021). Filtros passa-faixa *Butterworth* de 5ª ordem são utilizados para selecionar as frequências compendiadas por Δf.

Foram utilizadas duas funções fundamentais: a *butter()*, utilizada para projetar filtros *Butterworth* e a função *freqz()*, utilizada para calcular a resposta em frequência de um sistema de filtragem. Ambas as funções pertencem à biblioteca *SciPy* que desempenha um papel crucial no processo de filtragem e análise de sinais.

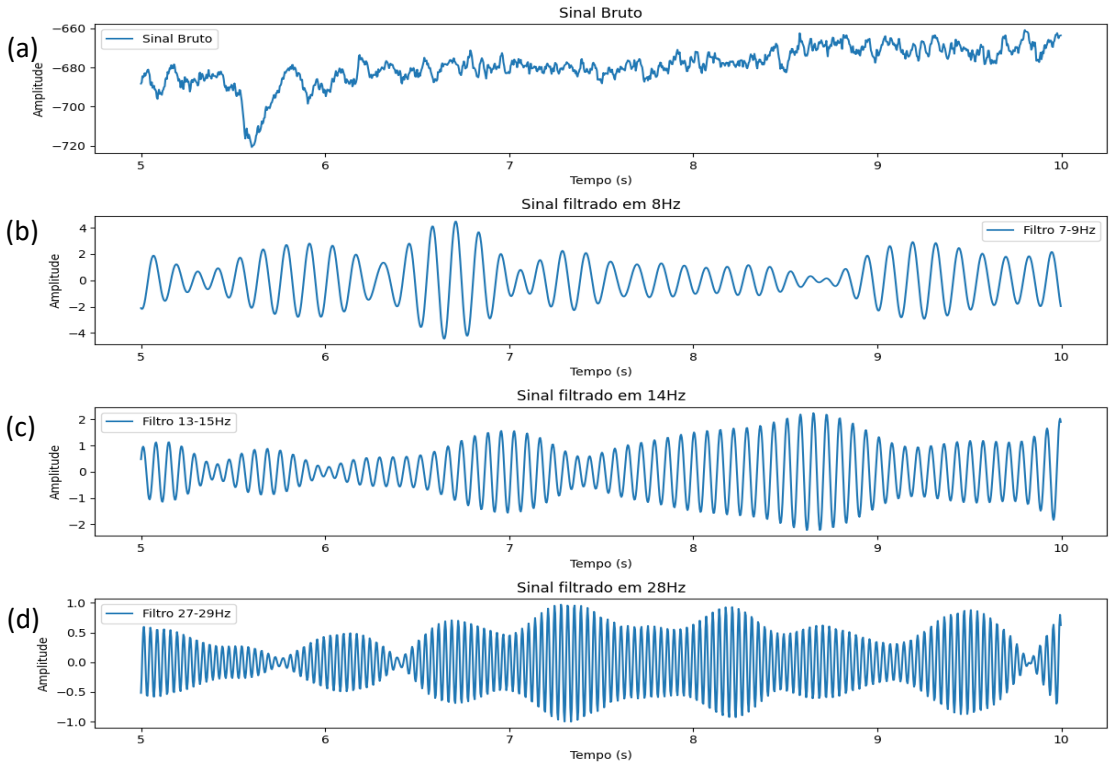


Figura 5: (a) Sinal bruto; (b) Sinal filtrado em 8Hz; (c) sinal filtrado em 14Hz; (d) Sinal filtrado em 28Hz. Fonte: Autoria própria.

3.2.3 EXTRAÇÃO DE CARACTERÍSTICA

Após a etapa de pré-processamento, onde o sinal EEG é filtrado e reduzido a elementos ruidosos menores, proporcionando uma representação mais clara e precisa do sinal, a etapa de extração de característica é crucial para a aplicação de técnicas, que permitem obter informações mais confiáveis e relevantes para a etapa de classificação.

3.2.3.1 EXTRAÇÃO DE ÉPOCAS

A extração de épocas em um sistema de ICM consiste em dividir os dados cerebrais em intervalos de tempo específicos, chamados épocas, para análise subsequente. A escolha das épocas se dá com base nos eventos relacionados à tarefa ou estímulo que o usuário está realizando. Após a etapa de filtragem do sinal, é necessário dividir os dados em épocas de tempo para análise. Conforme delineado na descrição do *dataset* (BAKARDJIAN;

TANAKA; CICHOCKI, 2010), o período de estimulação visual ocorre entre 5 e 20 segundos, definindo a duração do estímulo a 15 segundos para cada ensaio.

Com base nessa observação, os sinais de EEG são segmentados em 5 épocas distintas: 125ms, 250m, 500ms, 1s e 2s, respectivamente. Vale ressaltar que o conjunto de dados compreende cinco ensaios, implicando que cada época será replicada pela quantidade de ensaios, ampliando assim a quantidade de informações disponíveis. Portanto, são obtidos 600 exemplos para a época de 125ms, 300 exemplos para a época de 250ms, 150 exemplos para a épocas de 500ms, 75 exemplos para a épocas de 1s e 35 exemplos para a épocas de 2s.

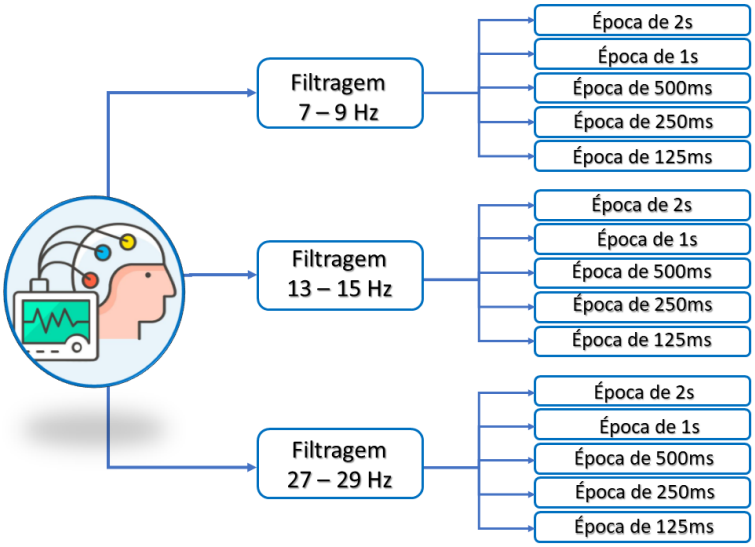


Figura 6: Esquema do processo de extração de épocas. Primeiro o sinal bruto passa por um banco de filtro onde ocorre a limpeza do sinal, depois é dividido em épocas distintas. Fonte: Autoria própria.

3.2.3.2 MÉTODO DO PERIODOGRAMA

O periodograma é uma técnica utilizada no processamento de sinais para identificar as frequências mais significativas em um sinal, ele funciona dividindo o sinal em seus componentes de frequência usando a transformada de *Fourier*. Em linhas gerais, a transformada de *Fourier* realiza a transição do sinal do domínio do tempo para o domínio da frequência, proporcionando um espectro contínuo de frequências. Sinais estacionários são sinais que possuem propriedades estatísticas constantes ao longo do tempo, ao estimar a densidade espectral destes sinais, podemos obter informações sobre o seu conteúdo de frequência e identificar quaisquer padrões ou tendências que possam estar presentes.

A partir do periodograma pode-se estimar a densidade espectral de potência (*Power Spectrum Density* - PSD) de um sinal, o que tem proporcionado o uso em várias análises baseadas em EEG (CHOWDHURY et al., 2020). Ademais, PSD é uma técnica usada para extrair características de sinais que respondem a SSVEP.

Os sinais são amostrados, logo para calcular o periodograma de um sinal discreto filtrado $x[n]$, faz-se uso da equação:

$$\hat{P}(k) = \frac{1}{N}\left|\sum_{n=0}^{N-1} x[n]e^{-j\frac{2\pi}{N}nk}\right|^2, \forall k = 0, 1, \dots, N-1 \quad (1)$$

em que $\hat{P}$ representa o periodograma, k é o ordinal no domínio da frequência, n é o ordinal no domínio do tempo discreto, o comprimento da sequência a ser transformada é representado por N (CHOWDHURY et al., 2020). Utilizando essa fórmula, é possível analisar a relação entre a amplitude e a frequência de um sinal e obter informações precisas sobre a distribuição de energia em diferentes frequências.

Para esta fase de desenvolvimento, a função *periodogram()* da biblioteca *SciPy* foi empregada para calcular o espectro de potência de um sinal a partir de sua série temporal. Posteriormente, mediante a aplicação do periodograma, a energia do sinal foi obtida utilizando a função *sum()* da biblioteca *NumPy*. Vale ressaltar que a energia é uma métrica crucial do sinal, representando a quantidade total de energia contida em todas as suas frequências.

A seguir será apresentado o PSD, obtido através do periodograma, para diversas épocas (2s, 1s, 500ms, 250ms, 125ms) e para o estímulo de 8Hz filtrado em 8Hz. Este procedimento visa destacar a relação entre a amplitude e a frequência do sinal.

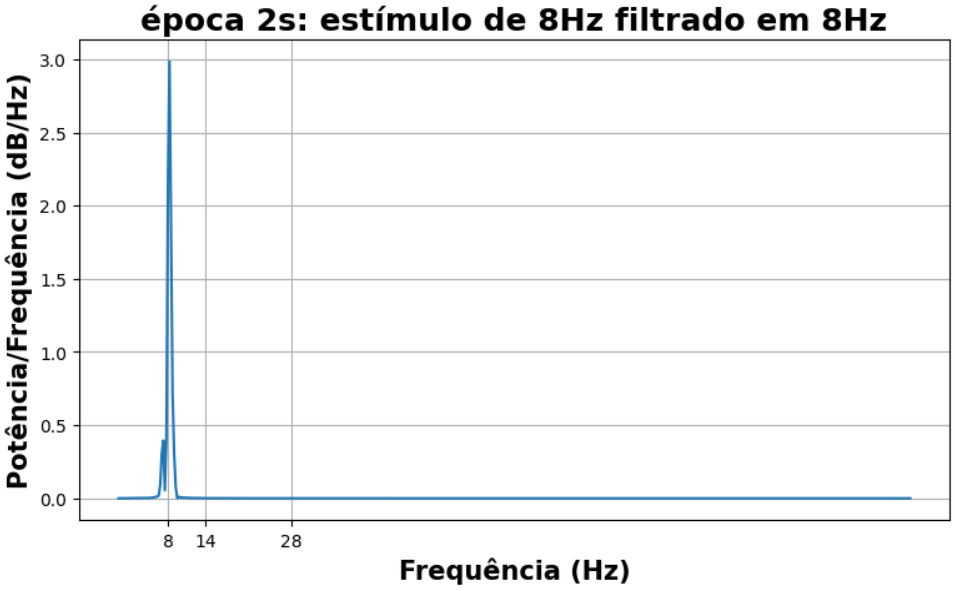


Figura 7: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 2s. Fonte: Autoria própria.

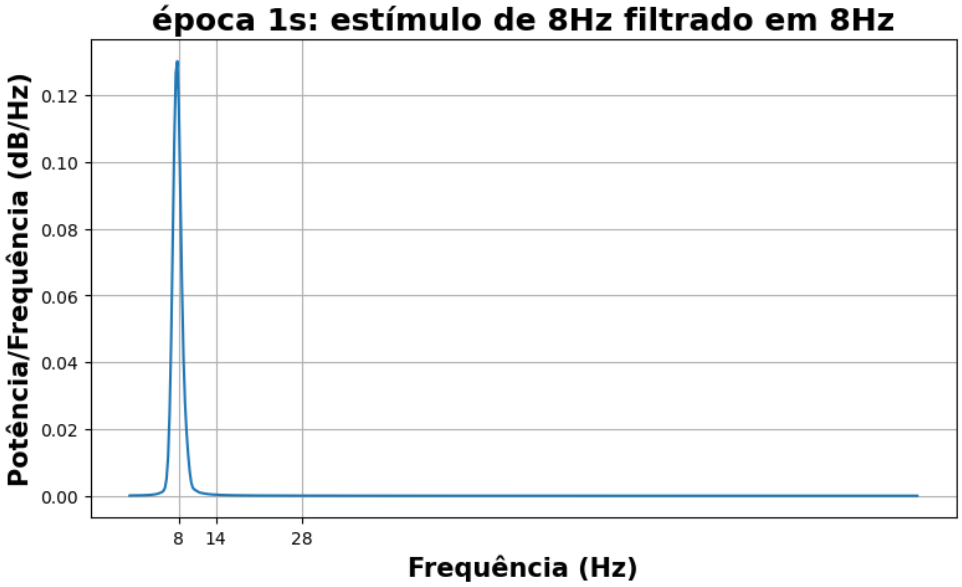


Figura 8: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 1s. Fonte: Autoria própria.

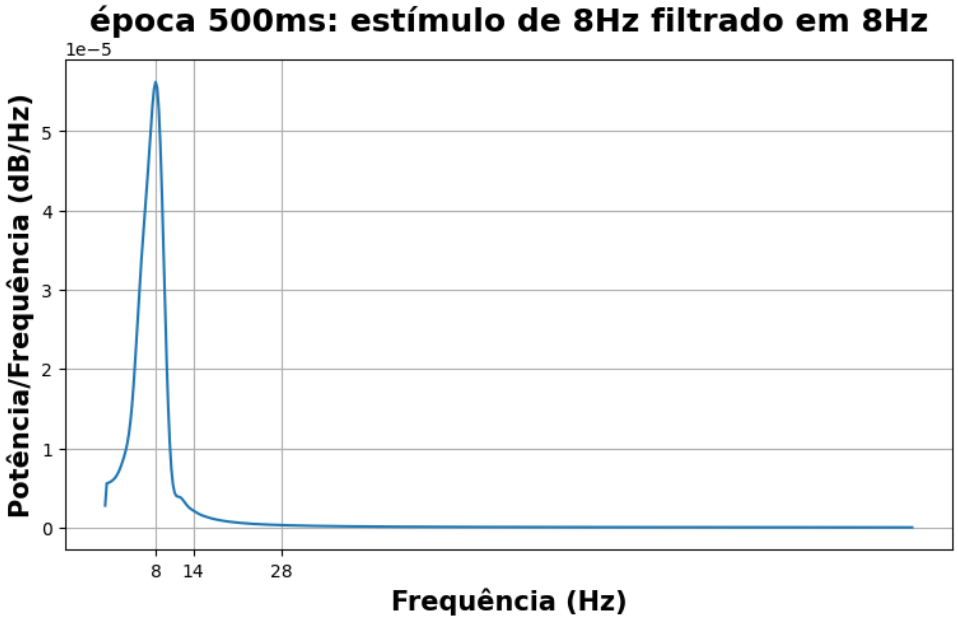


Figura 9: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 500ms.
Fonte: Autoria própria.

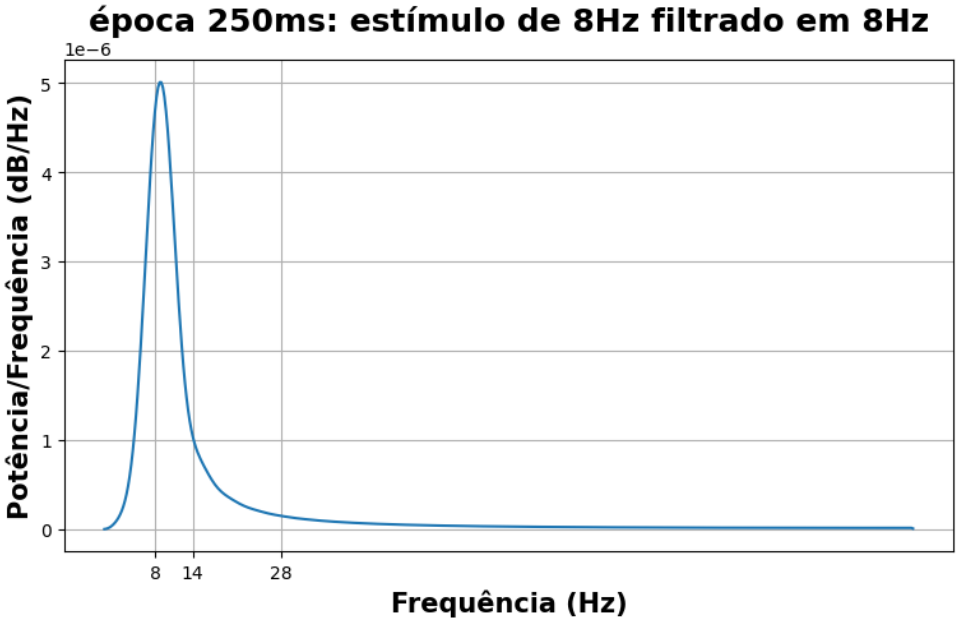


Figura 10: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 250ms.
Fonte: Autoria própria.

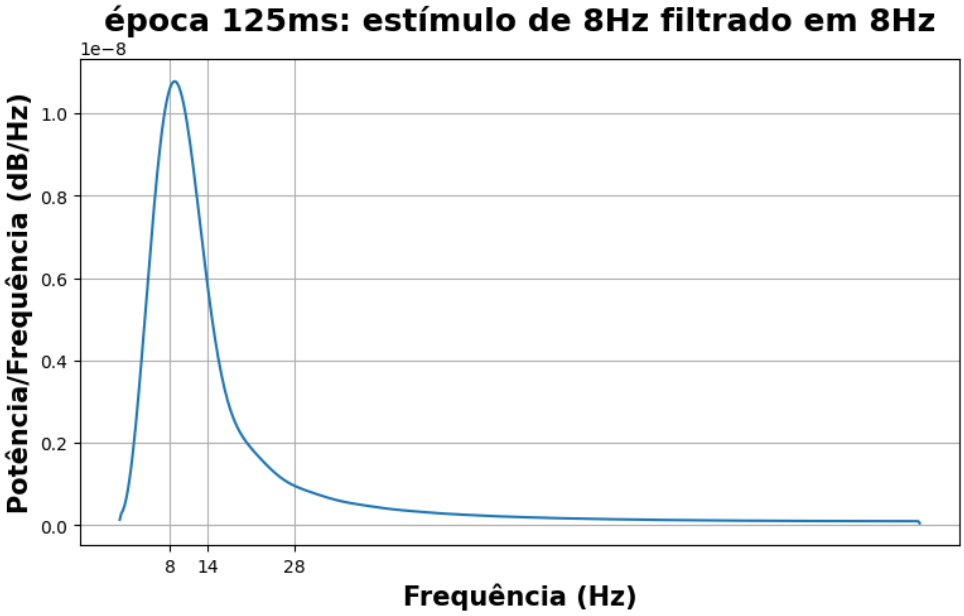


Figura 11: Densidade espectral de potência do estímulo de 8Hz filtrado em 8 Hz da época de 125ms.
Fonte: Autoria própria.

3.2.4 CLASSIFICAÇÃO

A partir do processo de extração de características, é gerada a matriz de atributos que consiste nas PSDs calculadas a partir do periodograma para cada época. A fase de classificação tem como objetivo identificar o estímulo no qual o indivíduo manteve o foco, utilizando o conjunto de atributos extraídos.

Diferentes quantidades de exemplos são obtidas para cada época de tempo durante a extração de características. Para realizar a classificação dos sinais é necessário separá-los. No trabalho é adotado o método *holdout* no qual os dados são divididos, guardando 70% para ajuste dos parâmetros do classificador (treinamento) e 30% para realizar o teste do classificador ajustado. Esta classificação é feita a partir dos sinais extraídos do canal *Oz* nas frequências de 8Hz, de 14Hz e de 28Hz.

Durante o processo, são realizadas três combinações binárias entre as frequências para a criação das matrizes de características, que são aplicadas no classificador: 8Hz e 14Hz; 8Hz e 28Hz; e 14Hz e 28Hz. É crucial enfatizar que cada combinação é aplicada para a mesma

época, desta forma possuindo o mesmo número de segmentos. De maneira geral, a combinação de 8Hz e 14Hz é aplicada para a época de 2s, de 1s, de 500ms, de 250ms e de 125ms. Esse feito repete-se para todas as combinações, como mostrado na figura 12, de modo que o procedimento garante uma análise sólida durante o experimento e permite a associação dos resultados entre as diferentes combinações de frequências e durações das épocas.

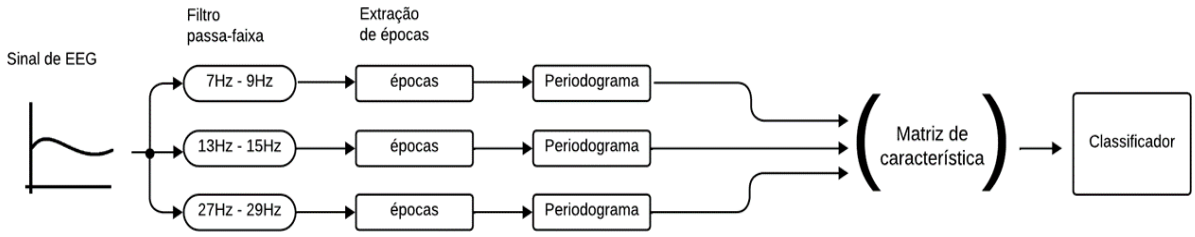


Figura 12: Diagrama do processo de criação da matriz de características. Fonte: Autoria própria.

3.2.4.1 ANÁLISE DO DISCRIMINANTE LINEAR (LDA)

Observa-se que o conjunto de características pode ser linearmente separável, sendo possível definir dois planos que separam as classes. O algoritmo de Análise do Discriminante Linear (LDA) está entre os mais populares para classificar sinais de EEG em sistemas ICMs (CALVINHO, 2021). Nos sistemas ICM-SSVEP, os classificadores lineares são capazes de serem utilizados para determinar a classe de um sinal de entrada e é representado por:

$$Y = w^T X, \tag{2}$$

onde Y é a saída do classificador, o símbolo T indica a transposição de w que é o vetor de pesos que desempenha a função crucial de definir os planos geométricos que separam as características analisadas (SENA, 2018).

A determinação do vetor w é realizada por meio de uma técnica de treinamento do classificador, descrita pela seguinte expressão:

$$\widehat{w} = (X^T X)^{-1} X^T R, \tag{3}$$

em que R representa um vetor de rótulos (0 e 1), enquanto X é a matriz de características extraídas do sinal filtrado de entrada, sendo $X = \sum_k [\hat{P}_1(k), \hat{P}_2(k), \hat{P}_3(k)]^T$. A fórmula (3) é fornecida para determinar o vetor de pesos destinado à saída Y do classificador mencionado na equação (2), indicando a capacidade do modelo em discriminar a classe à qual um sinal pertence. Valores positivos de Y são associados à classe 1, enquanto valores negativos indicam pertencimento à classe 2 (SENA, 2018). Considerando as 3 classes (frequência 8Hz, 14Hz e 28Hz), foram implementados 3 classificadores binários com as seguintes combinações: 8Hz e 14Hz; 8Hz e 28Hz; 14Hz e 28Hz.

3.2.5 MÉTRICAS

A acurácia de classificação representa um importante recurso para análise de dados de modelos de classificação, pois fornece informações capazes de medir a taxa de acerto de um sistema em discriminar os estímulos visuais. Embora a acurácia seja grandemente utilizada, em sistemas de ICM-SSVEP mais complexos, é necessário um relatório de classificação mais completo.

Uma métrica que oferece informações mais detalhada do desempenho de classificação e a matriz de confusão, ela exibe as saídas esperadas do classificador como linhas e as saídas previstas como colunas. A figura 13 representa uma matriz de confusão para a classificação de duas classes, a diagonal principal representa o número de exemplos classificados de forma correta em contraposição com os demais elementos da matriz que expressam as classificações incorretas (VILAS BOAS, 2021).



Figura 13: Matriz de confusão para decisão binária, uma classe representa a primeira frequência e a outra classe representa a segunda frequência. Fonte: Autoria própria.

A partir da matriz de confusão pode-se obter a acurácia de classificação,

$$Acc_{global} = \frac{VP - VN}{VP + FP + VN + FN} \quad , \tag{4}$$

o numerador ($VP - VN$) realiza a diferença entre quantidade de exemplos que o modelo classificou corretamente, chamado de Verdadeiros Positivos (VP), e a quantidade de exemplos que foram classificados como não pertencentes à classe, denominado de Verdadeiro Negativo (VN), já o denominador ($VP + FP + VN + FN$) é a soma de todas as classificações realizadas pelo modelo, onde os Falsos Negativos (FN) são os exemplos classificados como não pertencentes à classe, entretanto pertencem a ela, e o Falsos Positivos (FP) são os exemplos classificados como pertencentes à classe quando não pertencem (VILAS BOAS, 2021).

A matriz de confusão é uma ferramenta versátil que permite avaliar o desempenho global de um modelo (4) e entender como o modelo se comporta em termos de classificação para cada classe individualmente dado por:

$$Acc_{individual} = \frac{VP}{VP + FN} \quad . \tag{5}$$

Refere-se à acurácia calculada para cada classe específica, ela é obtida dividindo os verdadeiros positivos (VP) pela soma dos verdadeiros positivos (VP) e falsos negativos (FN) para uma classe específica (VILAS BOAS, 2021). Isso é particularmente útil em cenários onde o interesse está na performance específica para cada classe do problema.

4 RESULTADOS E DISCUSSÕES

Neste estudo, as matrizes de confusão foram geradas a fim de obter a acurácia individual de cada frequência. Acurácia é mostrada para cada sujeito disponível no conjunto de dados, para cada janelas de extração de épocas e para cada combinação de frequências evocadas, utilizando apenas os atributos extraídos do canal Oz, com a finalidade de treinamento e teste.

4.1 SUJEITO 1

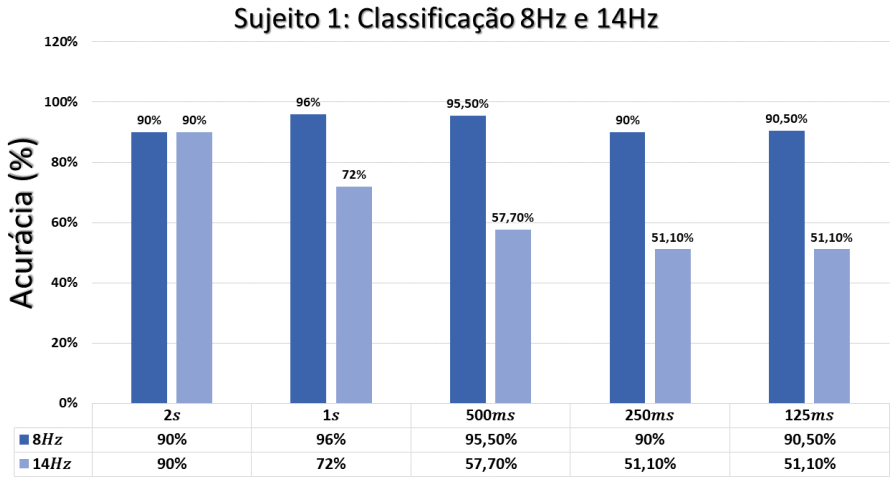


Figura 14: Desempenho do Sujeito 1 para o classificador LDA combinado em 8Hz e 14Hz, para todas as épocas. Fonte: Autoria própria.

A Figura 14 apresenta o relatório de análise de dados para o classificador LDA combinado nas frequências de 8Hz e de 14Hz, para o sujeito 1. No geral, nota-se que o desempenho do sujeito é superior na frequência de 8Hz, alçando o 96% de acurácia na época de 1s. Na época de maior duração, o classificador apresenta 90% de acertos para ambas as frequências de estímulo, enquanto o menor intervalo de tempo, o desempenho do classificador é de 90,5% para a frequência de 8Hz.

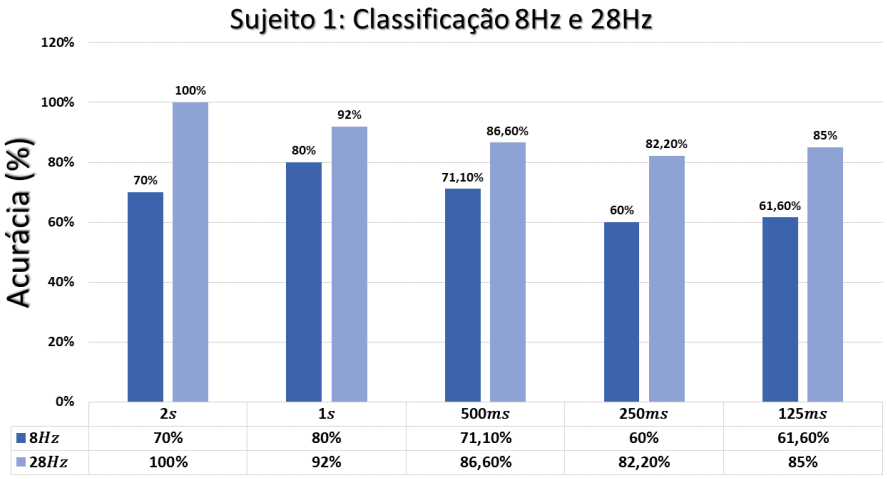


Figura 15: Desempenho do Sujeito 1 para o classificador LDA combinado em 8Hz e 28Hz, para todas as épocas. Fonte: Autoria própria.

Na Figura 15, observa-se que o classificador para o sujeito 1 apresenta maior assertividade para a frequência de 28Hz, atingindo 100% de acertos para a época de 2s. No intervalo mais curtos, época de 125ms, o voluntário alcança 85% para a mesma frequência, a segunda época mais longa, com duração de 1s, obtém uma acurácia de 92% para a frequência de 28Hz e 80% para a frequência de 8Hz, evidenciando uma habilidade distintiva do sujeito em reagir às diferentes frequências de estímulo.

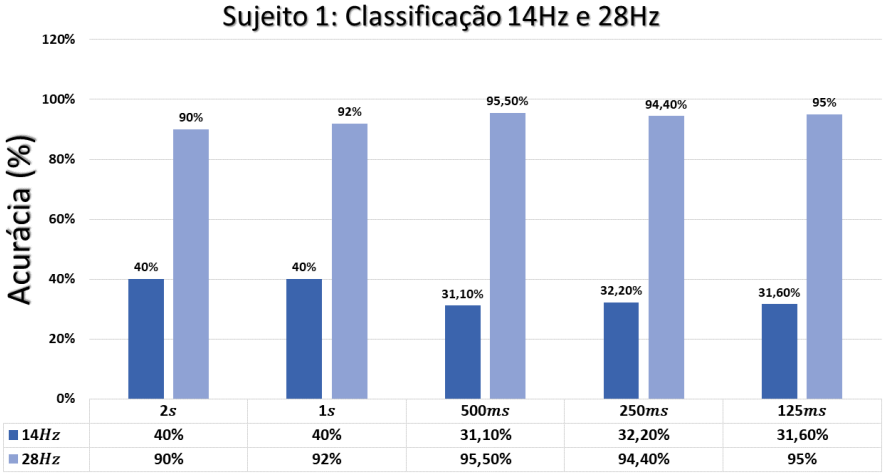
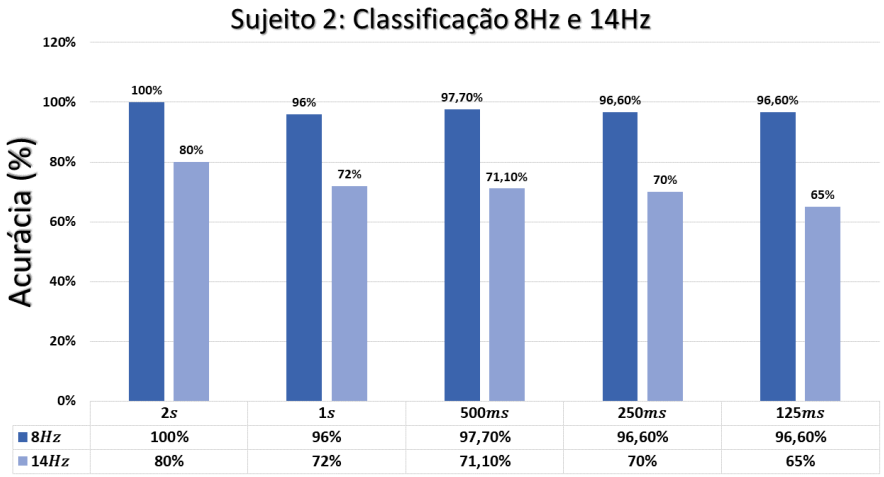


Figura 16: Desempenho do Sujeito 1 para o classificador LDA combinado em 14Hz e 28Hz, para todas as épocas. Fonte: Autoria própria.

O classificador para o sujeito 1, na figura 16, demonstrou consistentemente uma acurácia mais elevada para a frequência de 28Hz em comparação com a frequência de 14Hz, destacando as Épocas de 500ms e 125ms que alcançaram um desempenho excepcionalmente alto de 95,5% e 95 de acurácia, respectivamente. Para a mesma frequência, as demais épocas mantiveram um desempenho maior e igual a 90% de acertos.

4.2 SUJEITO 2



	2s	1s	500ms	250ms	125ms
8Hz	100%	96%	97,70%	96,60%	96,60%
14Hz	80%	72%	71,10%	70%	65%

Figura 17: Desempenho do Sujeito 2 para o classificador LDA combinado em 8Hz e 14Hz, para todas as épocas. Fonte: Autoria própria.

O classificador para o sujeito 2 atingiu melhor acurácia para a frequência de 8Hz, enquanto para a frequência de 14Hz houve uma ligeira queda no desempenho, como mostrado na Figura 17. O classificador manteve um desempenho alto para a frequência de 8Hz em todas as épocas, evidenciando a época de 2s que chegou a 100% de acurácia, vale enfatizar que para essa frequência todos os desempenhos foram maiores que 96%.

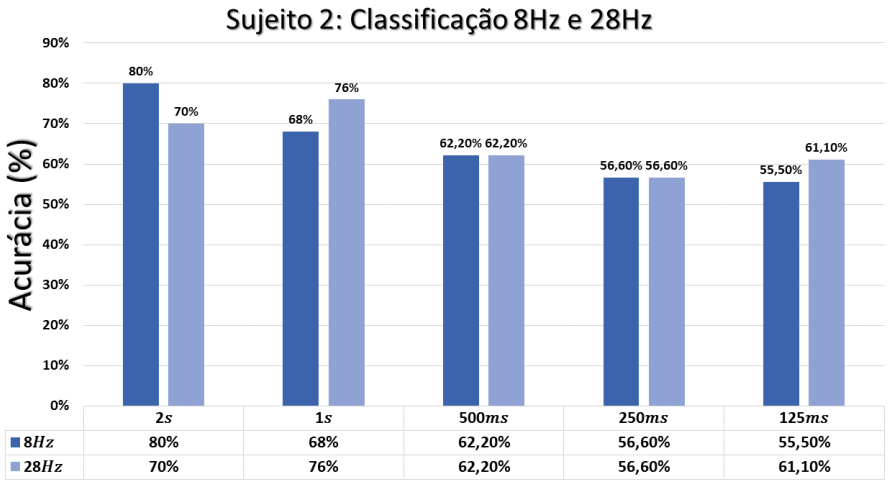


Figura 18: Desempenho do Sujeito 2 para o classificador LDA combinado em 8Hz e 28Hz, para todas as épocas. Fonte: Autoria própria.

A Figura 18 é exibido um relatório de análise de dados para o classificador combinado nas frequências de 8Hz e de 28Hz, para o sujeito 2. Observa-se que o sujeito apresenta bom desempenho para ambas as frequências. Nas épocas 500ms e 250ms, ele obtém acurácia idêntica para os dois estímulos 62,2% e 56,60%, respectivamente. Para a frequência de 8Hz a época com maior acurácia é a de duração de 2s, já para a frequência de 28Hz a época de 1s se destaca.

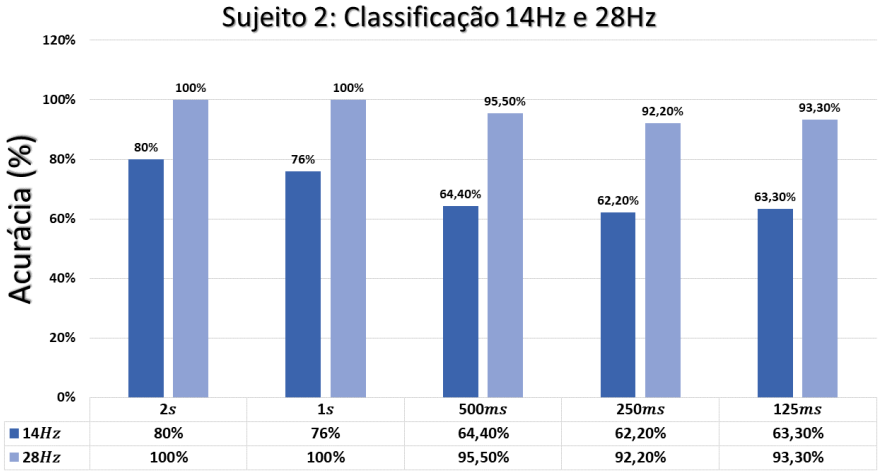


Figura 19: Desempenho do Sujeito 2 para o classificador LDA combinado em 14Hz e 28Hz, para todas as épocas. Fonte: Autoria própria.

Em todas as épocas analisadas, mostrado na Figura 19, a frequência de 28Hz apresenta acurácia mais elevada em comparação com a frequência de 14Hz. No intervalo mais curtos, época de 125ms, o classificador atinge 93,3% para a frequência de 28Hz. Além disso, para a mesma frequência, é apresentado um desempenho excepcional de 100% de acurácia nas épocas de 2s e 1s.

4.3 SUJEITO 3

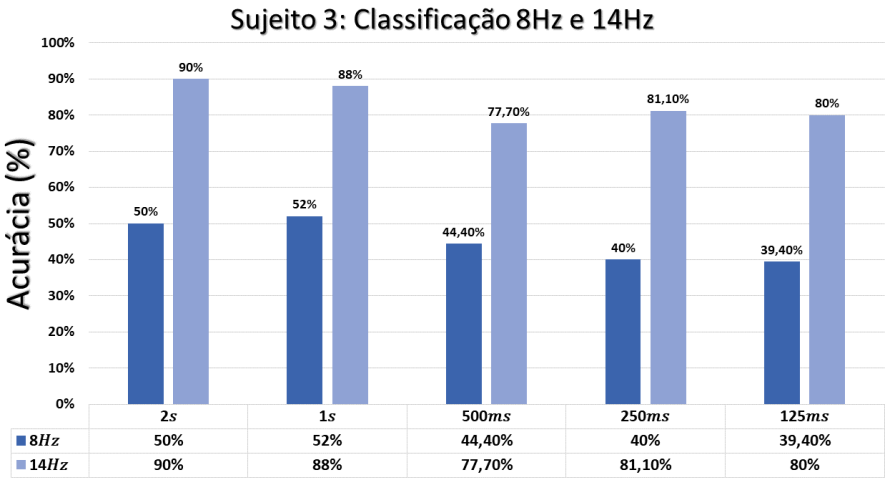


Figura 20: Desempenho do Sujeito 3 para o classificador LDA combinado em 8Hz e 14Hz, para todas as épocas. Fonte: Autoria própria.

O classificador para o sujeito 3, na figura 20, exibe uma acurácia mais elevada para a frequência de 14Hz em comparação com a frequência de 8Hz. Destacando a maior época, duração de 2s, que atingiu 90% de acurácia, o melhor desempenho em relação às outras épocas que variam de 77% a 88%, para a frequência de 14Hz.

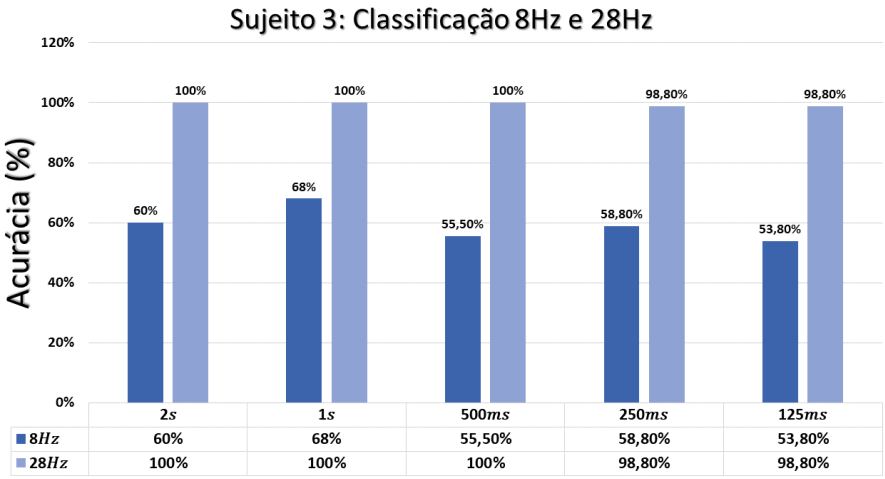


Figura 21: Desempenho do Sujeito 3 para o classificador LDA combinado em 8Hz e 28Hz, para todas as épocas. Fonte: Autoria própria.

A Figura 21 é mostrado um relatório de análise de dados para o classificador combinado nas frequências de 8Hz e de 28Hz, para o sujeito 3. Nota-se que o classificador apresenta um desempenho excepcional para ambas as épocas e frequência de 28Hz. Nas épocas de 250ms e 125ms, na mesma frequência, ele obtém acurácia idêntica 98,8%. Para as demais épocas, o classificador alcança 100% de assertividade.

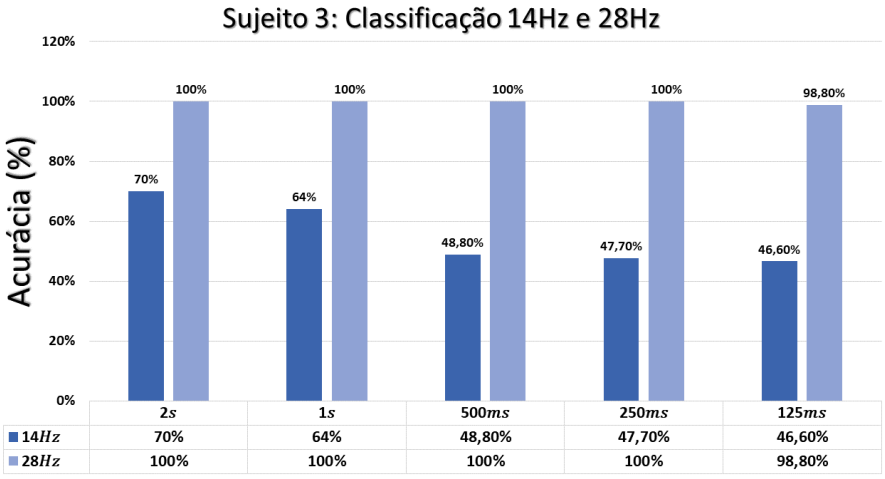


Figura 22: Desempenho do Sujeito 3 para o classificador LDA combinado em 14Hz e 28Hz, para todas as épocas. Fonte: Autoria própria.

Em todas as épocas analisadas, mostrado na Figura 22, a frequência de 28Hz exibe melhor desempenho em comparação com a frequência de 14Hz. Surpreendentemente, o classificador alcança uma assertividade de 98,8% para a época de 125ms e 100% para todas as outras épocas, indicando uma habilidade consistente do sujeito em manter o foco e fornecer respostas precisas.

4.4 SUJEITO 4

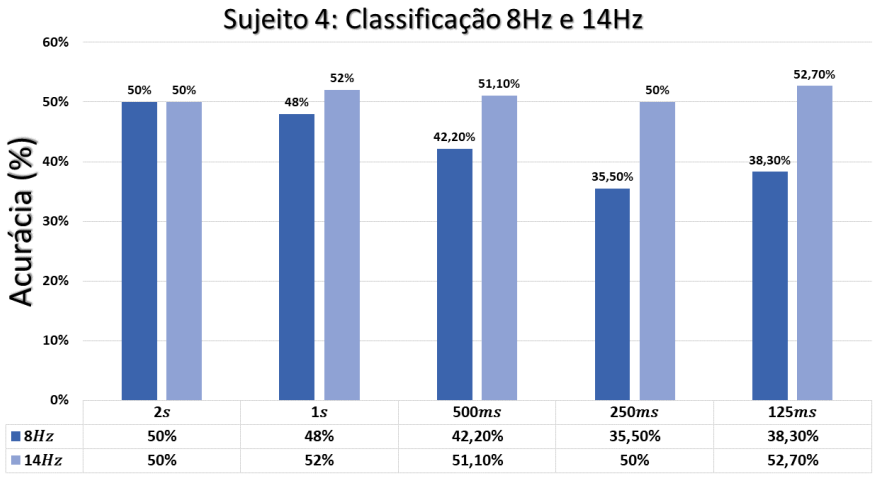


Figura 23: Desempenho do Sujeito 4 para o classificador LDA combinado em 8Hz e 14Hz, para todas as épocas. Fonte: Autoria própria.

Na Figura 23, o relatório de análise de dados é exibido para o classificador LDA combinado nas frequências de 8Hz e de 14Hz, para o sujeito 4. De maneira geral, o classificador mostra desempenho superior na frequência de 14Hz, exceto a época de 2s que tem acurácia de 50% para os dois estímulos. Em épocas de menor duração, o desempenho do classificador varia de 50% a 53%.

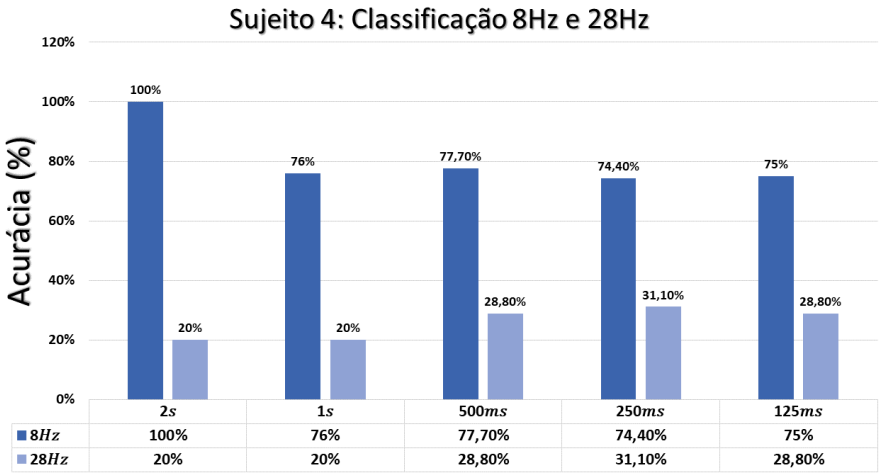


Figura 24: Desempenho do Sujeito 4 para o classificador LDA combinado em 8Hz e 28Hz, para todas as épocas. Fonte: Autoria própria.

O classificador para o sujeito 4, na figura 24, apresenta consistentemente acurácia mais elevada para a frequência de 8Hz em comparação com a frequência de 28Hz, destacando a maior época, com duração de 2s, que atinge um desempenho excepcionalmente alto 100% e 95 de acurácia. As demais épocas mantiveram um desempenho maior e igual a 74% de acertos.

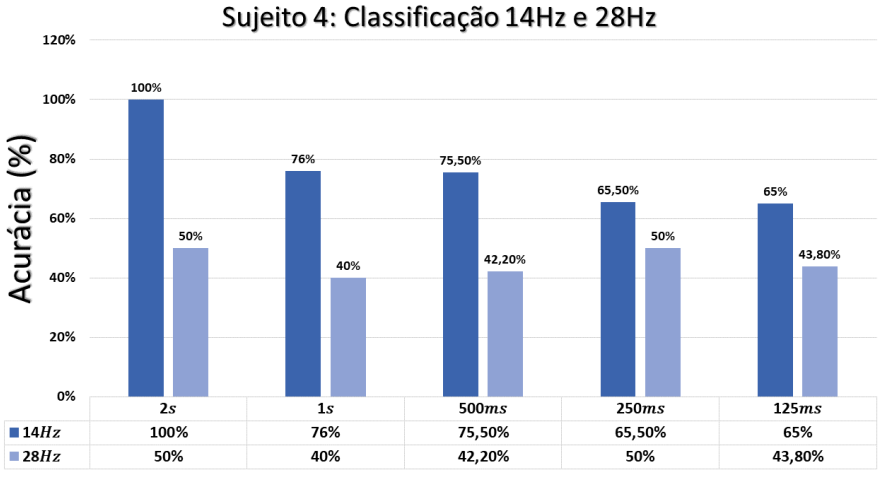


Figura 25: Desempenho do Sujeito 4 para o classificador LDA combinado em 14Hz e 28Hz, para todas as épocas. Fonte: Autoria própria.

O classificador para o sujeito 4, na figura 25, mostra um desempenho superior para a frequência de 14Hz em comparação com a frequência de 28Hz. Destacando a maior época, duração de 2s, que atingiu incrível 100% de acurácia, o melhor desempenho em relação às outras épocas que variam de 65% a 76%, para a frequência de 14Hz.

5 CONCLUSÃO

Os avanços tecnológicos, em paralelo a investigação das atividades cerebrais, possibilitaram o advento da Interface Cérebro-Máquina (ICM). O trabalho apresenta um estudo aprofundado sobre ICM baseada no Potencial Evocado Visual de Estado Estável (SSVEP). Diante da observação de demoras em sistemas de tempo real ao fornecer feedback ao usuário, a análise é direcionada para as diferentes durações de épocas, explorando tanto intervalos curtos de tempo quanto aqueles frequentemente utilizados na literatura.

Foi utilizado um conjunto de dados de um repositório público como sinais de estudo. Após o pré-processamento, que incorporou um filtro passa-faixa com banda passante de 2Hz, é necessário dividir esse sinal em segmentos menores para a aplicação de métodos e técnicas adicionais. O foco principal do estudo se baseou nessa etapa, onde foi aplicado a extração de épocas em cinco diferentes durações: 2s, 1s, 500ms, 250ms, 125ms.

A etapa de extração de característica foi produzida baseada no cálculo da densidade espectral de potência (PSD) através do método de Periodograma, onde é possível observar os picos de potência em torno das frequências da estimulação visual. Com os dados da extração de característica foram criadas as matrizes de atributos e implementado o classificador LDA que realizava classificação binária com o objetivo de identificar o estímulo no qual o indivíduo estava focado, separando os sinais analisados em classes distintas.

A partir dos resultados encontrados neste trabalho foi possível detectar que a utilização de épocas com menor duração, como as épocas de 125ms ou 250ms podem proporcionar maior quantidade de comandos gerados pelo sistema ICM-SSVEP por unidade de tempo. No entanto, segundo a análise comparativa, a taxa de erro de classificação também é aumentada, indicando que se deve realizar um ajuste para selecionar a duração adequada da época a ser adotada para a aplicação de interesse.

Portanto, o sucesso de um sistema ICM-SSVEP não se resume apenas à coleta de dados, mas também à compreensão profunda associadas à escolha da duração da época, ao processamento de sinal eficiente e à aplicação de métodos de classificação apropriados. Uma abordagem cuidadosa e integrada desses elementos é essencial para criar um sistema ICM eficaz, capaz de traduzir de maneira confiável as intenções do usuário com base nos sinais cerebrais capturados.

6 SUGESTÕES PARA TRABALHOS FUTUROS

Com base no estudo abordado, para trabalhos futuros, sugere-se a exploração de algumas direções que podem aprimorar ainda mais a eficiência de sistemas ICM-SSVEP:

- Análise de Componentes Canônicos (CCA): A adição de mais canais, permitindo uma identificação mais precisa das áreas do cérebro envolvidas nas respostas aos estímulos visuais;
- Classificação Multiclasse: Quanto mais estímulos, mais comandos para um sistema;
- Conjunto de dados: Testar o script em diferentes conjuntos de dados;
- Aplicações práticas em tempo real: Expandir as análises para cenários de tempo real, considerando não apenas a acurácia da classificação, mas também o tempo de resposta do sistema.

REFERÊNCIAS BIBLIOGRÁFICAS

Souza, J. P. G., Fermoseli, A. F. O., Krizan, J. and Costa, G. M. (2015) "**Interface Cérebro - Máquina (ICM): Da transdução do estímulo externo em impulso nervoso a tradução em comandos digitais**" Caderno De Graduação - Ciências Biológicas e da Saúde - UNIT/AL, v. 3, p. 139-152.

Vilas Boas, V. M. (2021) "**AutoBCI: interface cérebro-máquina com configuração hiperparamétrica automatizada**". Orientador: Cleison Daniel Silva; Coorientador: Otávio Noura Teixeira. 2021. 249 f. Dissertação (Mestrado em Computação Aplicada) - Núcleo de Desenvolvimento Amazônico em Engenharia, Universidade Federal do Pará, Tucuruí, 2021. Disponível em: http://repositorio.ufpa.br/jspui/handle/2011/1321.

G. Garcia-Molina and D. Zhu. "**Optimal spatial filtering for the steady state visual evoked potential: BCI application**". In: 5th International IEEE/EMBS Conference on Neural Engineering (2011). doi: 10.1109/ner.2011.5910512.

H. Bakardjian, T. Tanaka, and A. Cichocki. "**Optimization of SSVEP brain responses with application to eight-command Brain–Computer Interface**". In: Neuroscience Letters 469.1 (2010), pp. 34–38. doi: 10.1016/j.neulet.2009.11. 039.

Sarah N. et al. CARVALHO. "**Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs.**" In: Biomedical Signal Processing and Control 21 (2015), pp. 34–42.

Henrique Luiz Voni et al GIULIANI. "**Influência da Janela de Estimação no Desempenho de Classificação em Sistemas BCI-SSVEP.**" In: SIMPOSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS 39 (2021).

Pengfei et al. MA. "**A classification algorithm of an SSVEP brain-Computer interface based on CCA fusion wavelet coefficients.**" In: Journal of Neuroscience Methods 371 (2022), p. 109502.

Santos, R. O. (2002) "**Estrutura e funções do córtex cerebral**".

Martin, J. H. (2013) "**Neuroanatomia: Texto e Atlas**" 4. ed. Porto Alegre: McGraw Hill Education.

Izquierdo, I. (2018) "**Memória**" 3. ed. Porto Alegre: Artmed.

Silverthorn, D. U. (2017) "**Fisiologia Humana: uma abordagem integrada**" 7. ed. [S.l.]: Porto Alegre: Artmed.

Huang, J. (2021) "**Visão geral da função cerebral**" Manuais MSD Edição Para Profissionais; Manuais MSD.

Bueno, L. (2017) "**Interface Cérebro-Computador Baseada em EEG Utilizando Redes Neurais Auto-Organizadas**" Tese de Doutorado. Universidade Federal do Espírito Santo, Brazil.

Barros, K. R. (2005) "**Metodologia para Classificação de Sinais EMG para Controle de**

Prótese com Baixo Esforço Computacional" Uberlândia: FEELT-UFU.

Yoo, J and Yoo, H. J. (2011) "**Fabric circuit board-based dry electrode and its characteristics for long-term physiological signal recording**" Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Boston, MA, USA, 2011, pp. 2497-2500, doi: 10.1109/IEMBS.2011.6090692.

Prutchi, D and Norris, M. (2005) "**Design and Development of Medical Electronic Instrumentation: A Practical Perspective of the Design, Construction, and Test of Medical Devices**", New Jersey: John Wiley & Sons.

TAVARES, Maurício Campelo; ENG, M.; BIOMÉDICA, Eng. **Eeg e potenciais evocados – uma introdução**. Contronic Sistemas Automáticos Ltda, p. 1-13, 2011.

Marinho, T. F. (2017) "**Recomendação da SBNC para Localização de Eletrodos e Montagens de EEG**" Sociedade Brasileira De Neurofisiologia Clínica. Disponível em: https://sbnc.org.br/wpcontent/uploads/2015/05/1512584738_Norma_montagens_EEG_.pdf.

Faceli, K., Lorena, A. C., Gama, J. and Carvalho, A. C. P. L. F. de. (2011) "**Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**" Rio de Janeiro: LTC.

Mitchell, T. (1997) "**Machine Learning**". McGraw-Hill, 1. Ed.

Zambalde, E. P. (2018) "**SSVEP-based BCI with visual stimuli from LCD screen Applied for wheelchair control: offline and online investigations**" Dissertação (Mestrado em Engenharia Biomédica) - Universidade Federal de Uberlândia, Uberlândia, 2018. http://dx.doi.org/10.14393/ufu.di.2018.1166.

Namazi, H., Ala, T. S. and Bakardjian, H. (2018) "**Decoding of steady-state visual evoked potentials by fractal analysis of the electroencephalographic (EEG) signal**". Fractals, 26(06), 1850092. https://doi.org/10.1142/s0218348x18500925.

Garcia, J. F. C. (2014). "**Interface Cérebro Computador Baseada em SSVEP e ERD para o Comando de um Veículo Autônomo**". 10.13140/RG.2.1.3997.9046.

B. J. de. J. Júnior. "**Análise de técnicas de filtragem em sistemas BCI-SSVEP**". In: (2017). url: https://www.monografias.ufop.br/handle/35400000/669.

Mohammad Samin Nur et al. CHOWDHURY. "**Deep neural network for visual stimulus-based reaction time estimation using the periodogram of single-trial eeg**". In: Sensors 20.21 (2020), p. 6090.

J. V. F. Calvinho. "**ICM Space Game: Uma ferramenta computacional alternativa para coleta de sinais de EEG**". In: (2021). Orientador: Cleison Daniel Silva; Coorientador: Bruno Merlin.

SENA, Marina Luiza dos Reis. "**Desenvolvimento de um sistema BCI-SSVEP e testes preliminares no controle de um protótipo de cadeira de rodas**". 2018.

ANEXO A – LINK DE ACESSO AO REPOSITÓRIO DO GITHUB

Repositório: https://github.com/ikathllen/SSVEP-Based-BCI-Epoch-Extraction-Analysis

ANEXO B – ARTIGO PUBLICADO

Interface Cérebro-Máquina baseada em SSVEP: Análise de Extração de Épocas

Fablena K. N. Dias[1], Sávio M. Sousa[2], Cleison D. Silva[2]

[1]Faculdade de Engenharia de Computação – Universidade Federal do Pará (UFPA)
CEP 68455-901 – Tucuruí – PA – Brasil

[2]Faculdade de Engenharia Elétrica – Universidade Federal do Pará (UFPA)
CEP 68455-901 – Tucuruí – PA – Brasil

{fablena.dias, savio.sousa}@tucurui.ufpa.br, cleison@ufpa.br

Resumo. *O trabalho apresenta os resultados da análise comparativa da extração de épocas com tamanhos diferentes de sinais de eletroencefalograma (EEG) de sistema Interface Cérebro-Máquina na presença de três estímulos. O objetivo geral é analisar o desempenho de classificação de um sistema ICM-SSVEP ao processar sinais de EEG com diferentes durações de épocas, o sistema é ajustado para classificação binária usando Análise do Discriminante Linear para cada duração e combinação de frequências (*$8Hz \times 14Hz$*, *$8Hz \times 28Hz$* e *$14Hz \times 28Hz$*), apresentando as acurácias detalhadas para cada análise.*

1. Introdução

As Interfaces Cérebro-Máquina (ICM) são sistemas artificiais que proporcionam uma comunicação direta entre o cérebro e uma máquina, permitindo que pessoas com desordens motoras ou sensoriais possam controlar dispositivos externos ao corpo humano [1]. As etapas de uma ICM são divididas em: Aquisição de sinais, processamento, classificação e aplicação.

O *Steady State Visual Evoked Potential* (SSVEP) é uma resposta gerada pela atividade neural em reação a um estímulo visual de frequência constante [2]. Esse fenômeno ocorre na região do lobo occipital, que é responsável pela percepção visual. Quando o usuário focaliza o olhar em uma frequência de estímulo permanente, é possível observar um aumento da atividade cerebral na mesma frequência e harmônicos, na região do córtex visual [2]. Um dos métodos utilizados para capturar os sinais cerebrais é o Eletroencefalograma (EEG) que consiste em uma técnica de neuroimagem, não invasiva, onde os sinais elétricos são coletados por eletrodos em contato com couro cabeludo [3].

Na literatura sobre a extração de épocas, algumas pesquisas utilizam épocas de estímulos com duração fixa de 2 ou 3 segundos [4], [5]. Outras buscam relacionar a acurácia da classificação dos sinais com a variação da duração das épocas, variando de 1 a 3 segundos [6], [7]. Por possuir mais informações, é comum optar por épocas com maior duração, no entanto épocas com duração menores que 2 segundos possuem vantagens em relação a agilidade de resposta ao sistema. Nesse sentido, o objetivo deste trabalho é realizar um estudo comparativo para analisar o desempenho de classificação de um sistema ICM-SSVEP ao processar sinais de EEG com duração de épocas de tempo iguais e inferiores a $2s$.

2. Materiais e Métodos

2.1. Aquisição de sinal

Nessa etapa é utilizado um conjunto público contendo sinais de EEG aquisitados durante a presença de três estímulos visuais com frequências: 8 Hz, $14Hz$ e $28Hz$ [4]. O repositório[4] contém EEG de quatro sujeitos, com cinco ensaios por indivíduo para cada frequência de SSVEP. Para o trabalho, o sinal de EEG do eletrodo Oz é selecionado, pois ele está posicionado sobre o lobo occipital, relacionado ao processamento visual. Ao analisar a variação da energia, desta região, é possível discernir entre olhos abertos/fechados, concentrado/relaxado e estímulo luminoso de frequência conhecida [8].

[4] http://www.bakardjian.com/work/ssvep data Bakardjian.html

2.2. Processamento dos sinais de EEG

Essa fase garante a qualidade dos resultados, uma vez que, ao coletar o sinal de EEG é comum a presença de ruídos. Os estímulos visuais, SSVEP, tendem a modular a atividade elétrica cerebral na mesma frequência do estímulo, desta forma, a detecção de estímulos na frequência F_0 pode ser realizada filtrando os sinais de EEG numa banda de frequência centrada em torno de F_0. Para realçar e preservar as informações espectrais entorno do estímulo é comum utilizar filtros passa-banda. Os filtros necessitam de parâmetros que definem a banda de frequências de interesse, como o intervalo $\Delta f = [F_l, F_u]$, onde F_l e F_u representam as frequências de corte inferior e superior em $Hertz$, respectivamente [3]. Filtros passa-banda *butterworth* de 5ª ordem são utilizados para selecionar as frequências compendiadas por Δf.

Após a filtragem do sinal de EEG e a redução dos elementos ruidosos, proporcionando uma representação mais clara e precisa do sinal, a aplicação de técnicas de extração de características de sinais de EEG permitem obter informações mais confiáveis e relevantes para a etapa de classificação. Para isso, é necessário dividir os dados em épocas de tempo para análise. Segundo a descrição do *dataset* [4], o período de estimulação se define em 15 segundos para cada ensaio. A Figura 1 mostra os sinais de EEG que são segmentados em 5 épocas para cada frequência: $125ms$, $250ms$, $500ms$, $1s$ e $2s$. O *dataset* contém cinco ensaios, isso implica dizer que cada época será multiplicada pela quantidade de ensaios para obter mais informações.

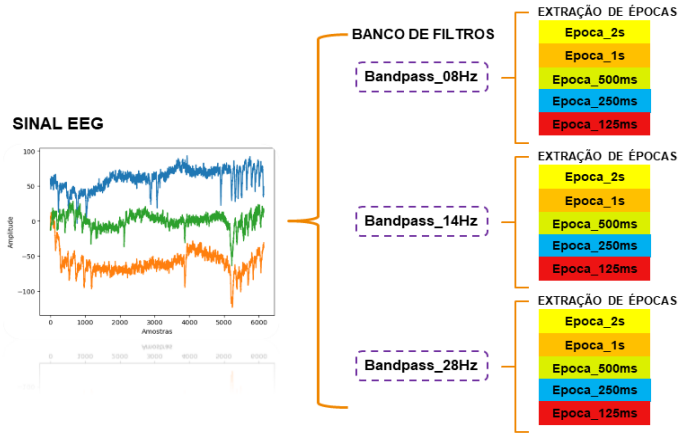


Figura 1: O sinal bruto passa por um banco de filtro e é dividido em épocas de tempo, representadas em diferentes bandas de frequência.

A partir da extração de épocas, aplica-se o periodograma que estima a densidade espectral de um sinal. Isso revela as relações entre a amplitude e a frequência do sinal, sendo uma técnica amplamente utilizada em diversas análises baseadas em EEG [9]. Para calcular o periodograma do sinal de EEG discreto filtrado $x[n]$, faz-se uso da equação:

$$\hat{P}(k) = \frac{1}{N}\left|\sum_{n=0}^{N-1} x[n]e^{-j\frac{2\pi}{N}nk}\right|^2, \forall k = 0, 1, \ldots, N-1 \quad (1)$$

$\hat{P}$ representa o periodograma, k é o ordinal no domínio da frequência, n é o ordinal no domínio do tempo discreto, o comprimento da sequência a ser transformada é descrito por N [9].

2.3. Classificação

Para realizar a classificação dos dados foram separados em 70% para treinamento e 30% para teste. São realizadas três combinações binárias entre as frequências para a criação das matrizes de características, que são aplicadas no classificador: $8Hz$ e $14Hz$; $8Hz$ e $28Hz$; e $14Hz$ e $28Hz$. É crucial enfatizar que cada combinação é aplicada para a mesma época.

Por possuir estrutura simples, desempenho competitivo e treinamento eficiente, os classificadores lineares são um dos algoritmos mais populares usados para projetar sistemas de ICM [3], sendo capazes de separar duas classes de exemplos e de determinar a classe de um sinal de entrada, representado por:

$$Y = w^T X, \tag{2}$$

onde Y é a saída do classificador, o símbolo T indica a transposição de w que é o vetor de pesos do classificador determinado durante o treinamento do modelo é X e a matriz de características extraídas do sinal filtrado de entrada [10], sendo $X = \sum_k [\hat{P}_1(k), \hat{P}_2(k), \hat{P}_3(k)]^T$.

3. Resultados

O relatório de classificação é um importante recurso para análise de dados, uma métrica que oferece informações mais detalhadas do desempenho de classificação e da matriz de confusão [3]. Neste estudo, são geradas matrizes de confusão a fim de obter detalhes da acurácia para cada sujeito disponíveis no *dataset*, para cada janelas de tempo e combinação de frequências.

Tabela 1: Acurácia de todas as épocas, todos os voluntários e todas as combinações.

Voluntários	Épocas	$8Hz \times 14Hz$		$8Hz \times 28Hz$		$14Hz \times 28Hz$	
Sujeito 1	$2s$	**90%**	90%	70%	**100%**	40%	**90%**
	$1s$	**96%**	72%	80%	**92%**	40%	**92%**
	$500ms$	**95.5%**	57.7%	71.1%	**86.6%**	31.1%	**95.5%**
	$250ms$	**90%**	51.1%	60%	**82.2%**	32.2%	**94.4%**
	$125ms$	**90.5%**	51.1%	61.6%	**85%**	31.6%	**95%**
Sujeito 2	$2s$	**100%**	80%	**80%**	70%	80%	**100%**
	$1s$	**96%**	72%	68%	**76%**	76%	**100%**
	$500ms$	**97.7%**	71.1%	62.2%	**62.2%**	64.4%	**95.5%**
	$250ms$	**96.6%**	70%	56.6%	**56.6%**	62.2%	**92.2%**
	$125ms$	**96.6%**	65%	55.5%	**61.1%**	63.3%	**93.3%**
Sujeito 3	$2s$	50%	**90%**	60%	**100%**	70%	**100%**
	$1s$	52%	**88%**	68%	**100%**	64%	**100%**
	$500ms$	44.4%	**77.7%**	55.5%	**100%**	48.8%	**100%**
	$250ms$	40%	**81.1%**	58.8%	**98.8%**	47.7%	**100%**
	$125ms$	39.4%	**80%**	53.8%	**98.8%**	46.6%	**98.8%**
Sujeito 4	$2s$	50%	**50%**	**100%**	20%	**100%**	50%
	$1s$	48%	**52%**	**76%**	20%	**76%**	40%
	$500ms$	42.2%	**51.1%**	**77.7%**	28.8%	**75.5%**	42.2%
	$250ms$	35.5%	**50%**	**74.4%**	31.1%	**65.5%**	50%
	$125ms$	38.3%	**52.7%**	**75%**	28.8%	**65%**	43.8%

No desempenho do LDA combinado para $8Hz$ e de $14Hz$, os sujeitos 1 e 2 mostram acurácia maior de 90% para $8Hz$ em épocas menores e iguais a $2s$, porém, para $14Hz$, eles tiveram 51,1% e 72% em épocas menores que $1s$ e 80-90% em $2s$; sujeitos 3 e 4 tiveram baixa acurácia. Na combinação $8Hz$ e $28Hz$, sujeitos 1 e 3 foram notáveis em todas as épocas para a frequência de $28Hz$, sendo que o sujeito 3 alcançou acurácia maior que 98.8%. Para $14Hz$ e $28Hz$, os sujeitos 1, 2 e 3 possuem desempenho variando entre 90% e 100%, sendo que o sujeito 3 apenas não obtém 100% de desempenho para a época de $125ms$.

4. Considerações finais

O trabalho realiza a análise comparativa de cinco épocas de sinais de EEG com duração diferente para cada um dos sujeitos e estímulos disponibilizados no conjunto de dados. Destaca-se que quanto maior da duração da época maior tende a ser a acurácia de classificação do sistema ICM-SSVEP. A utilização de épocas com menor duração, como as épocas de $125ms$ ou $250ms$ podem proporcionar maior quantidade de comandos gerados pelo sistema ICM-SSVEP por unidade tempo. No entanto, segundo a análise comparativa, a taxa de erro de classificação também é aumentada. Indicando que se deve realizar um ajuste para selecionar a duração adequada da época a ser adotada para a aplicação de interesse.

References

[1] J. P. G. Souza et al. “Interface Cerébro-Máquina (ICM): Da transdução do estímulo externo em impulso nervoso a tradução em comandos digitais”. In: Caderno De Graduação - Ciências Biológicas e da Saúde - UNIT/AL 3 (2015), pp. 139–152.

[2] G. Garcia-Molina and D. Zhu. “Optimal spatial filtering for the steady state visual evoked potential: BCI application”. In: 5th International IEEE/EMBS Conference on Neural Engineering (2011). doi: 10.1109/ner.2011.5910512.

[3] V. M. Vilas Boas. “AutoBCI: interface cerébro-máquina com configuração hiper-paramétrica automatizada”. In: (2021). Orientador: Cleison Daniel Silva; Coorientador: Otavio Noura Teixeira. url: http://repositorio.ufpa.br/jspui/handle/ 2011/13211.

[4] H. Bakardjian, T. Tanaka, and A. Cichocki. “Optimization of SSVEP brain responses with application to eight-command Brain–Computer Interface”. In: Neuroscience Letters 469.1 (2010), pp. 34–38. doi: 10.1016/j.neulet.2009.11. 039.

[5] Sarah N. et al. CARVALHO. “Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs.” In: Biomedical Signal Processing and Control 21 (2015), pp. 34–42.

[6] Henrique Luiz Voni et al GIULIANI. “Influência da Janela de Estimação no Desempenho de Classificação em Sistemas BCI-SSVEP.” In: SIMPOSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS 39 (2021).

[7] Pengfei et al. MA. “A classification algorithm of an SSVEP brain-Computer interface based on CCA fusion wavelet coefficients.” In: Journal of Neuroscience Methods 371 (2022), p. 109502.

[8] L. Bueno. “A Interface Cerébro-Computador Baseada em EEG Utilizando Redes Neurais Auto-Organizadas”. In: (2017).

[9] Mohammad Samin Nur et al. CHOWDHURY. “Deep neural network for visual stimulus-based reaction time estimation using the periodogram of single-trial eeg”. In: Sensors 20.21 (2020), p. 6090.

[10] J. J. et al. BELMIR JR. “Análise do Potencial Evocado Visualmente em Sinais Cerebrais para Implementação de BCIs.” In: ˜ Brazilian Technology Symposium (2016).