

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
ENGENHARIA COMPUTACIONAL

Hiero Henrique Barcelos Costa

Análise de Janelamento em Imaginação Motora para Interface
Cérebro-Máquina

Juiz de Fora
2025

Hiero Henrique Barcelos Costa

**Análise de Janelamento em Imaginação Motora para Interface
Cérebro-Máquina**

Trabalho de Conclusão de Curso apresentada
à Faculdade de Engenharia da Universidade
Federal de Juiz de Fora como requisito parcial
à obtenção do título de Bacharel em Engenharia Computacional.

Orientador: Prof. Me Gabriel Henrique de Souza

Coorientador: Prof. Dr Heder Soares Bernardino

Juiz de Fora

2025

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Barcelos Costa, Hiero Henrique.

Análise de Janelamento em Imaginação Motora para Interface Cérebro-Máquina / Hiero Henrique Barcelos Costa. – 2025.

67 f. : il.

Orientador: Gabriel Henrique de Souza

Coorientador: Heder Soares Bernardino

Trabalho de Conclusão de Curso – Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Engenharia Computacional, 2025.

1. Interface Cérebro-Máquina. 2. Imaginação Motora. 3. Eletroencefalograma. 4. Janelamento. I. Souza, Gabriel H, orient. II. Bernardino, Heder Soares, coorient. III. Título.

Hiero Henrique Barcelos Costa

**Análise de Janelamento em Imaginação Motora para Interface
Cérebro-Máquina**

Trabalho de Conclusão de Curso apresentada
à Faculdade de Engenharia da Universidade
Federal de Juiz de Fora como requisito parcial
à obtenção do título de Bacharel em Engenharia Computacional.

Aprovado em 15 de Agosto de 2025

BANCA EXAMINADORA

Prof. Me. Gabriel Henrique de Souza - Orientador
Universidade Federal de Juiz de Fora

Prof. Dr. Heder Soares Bernardino - Coorientador
Universidade Federal de Juiz de Fora

Prof. Dr. Luciana Conceição Dias Campos
Universidade Federal de Juiz de Fora

Prof. Dr. Alex Borges Vieira
Universidade Federal de Juiz de Fora

Dedico este trabalho à minha família, que com amor, apoio e inspiração tornou possível cada conquista nesta jornada. Especialmente aos meus pais e avós, que me deram uma base sólida para seguir adiante.

AGRADECIMENTOS

Agradeço profundamente aos meus avós, que foram a base sólida que me permitiu chegar até aqui; ao meu pai, por me ensinar o valor do compromisso com aquilo que realmente importa; à minha mãe, que sempre me incentivou em todas as escolhas e me acolheu nos momentos mais difíceis; e à minha irmã, que me mostrou na prática a importância da dedicação para conquistar o que se deseja na vida.

Sou grato também aos meus amigos, que me acompanharam nessa trajetória.

Agradeço aos meus professores, que com sabedoria e paciência conduziram nessa caminhada, transmitindo ensinamentos que foram fundamentais para o meu crescimento acadêmico e pessoal.

Finalmente, meu agradecimento especial ao meu orientador e amigo, que me introduziu ao campo das neurociências, abrindo portas e caminhos que transformaram minha trajetória. Portanto, proporcionando a criação desse trabalho.

“O gênero humano é uma espécie de todo organizado, e é na humanidade que o plano da natureza para o desenvolvimento racional da espécie deve ser realizado. Este plano, embora não seja consciente, governa a direção do progresso, e cada geração deve aproveitar as conquistas das anteriores para avançar.”

(Immanuel Kant, *Ideia para uma História Universal com um Propósito Cosmopolita* (1784), p.2)

RESUMO

Diversos métodos vêm sendo desenvolvidos para a coleta da atividade neuronal, sendo o eletroencefalograma (EEG) um dos mais utilizados por sua natureza não invasiva e acessível. Com o avanço das Interfaces Cérebro-Máquina (BCI), tornou-se possível aplicar esses sinais cerebrais em diversas áreas, permitindo a interação direta entre o cérebro e dispositivos externos. Um dos paradigmas mais estudados em BCI é a imaginação motora (MI), na qual o sujeito imagina movimentos sem executá-los fisicamente. Esses sinais são captados e processados para que possam ser interpretados por sistemas computacionais. Na literatura, é comum o uso de janelas temporais fixas iniciando cerca de 2,5 segundos após o início da tentativa para realizar análises e classificações. O objetivo deste trabalho é avaliar os principais métodos presentes na literatura para diferentes estratégias de janelamento investigando não apenas a eficácia, mas também a eficiência e a estabilidade dos modelos ao longo do tempo. Para isso, foram testados os algoritmos *Common Spatial Patterns* com *LogPower* e classificador *Naive Bayesian Parzen Window*, *Filter Bank Common Spatial Patterns* e a rede convolucional EEGNet, aplicando-os em diferentes configurações de janelas. Os testes foram realizados em conjuntos de dados amplamente utilizados na área, provenientes das competições internacionais de BCI. Os resultados indicaram uma justificativa neurofisiológica clara para o uso recorrente de janelas em torno de 2,5 segundos. Esse intervalo coincide com uma maior sincronização das frequências beta, associadas à imaginação motora, o que potencializa a discriminabilidade dos sinais. Além disso, o estudo demonstrou que o uso de janelas maiores tende a melhorar os resultados, ao fornecer mais informações temporais relevantes para os classificadores. Outro ponto importante revelado foi que a combinação de múltiplas janelas, abrangendo diferentes intervalos de tempo, não apenas melhora o desempenho pontual dos classificadores, como também contribui para uma maior estabilidade e qualidade dos resultados ao longo do tempo. Isso sugere que a abordagem tradicional de utilizar apenas uma janela fixa pode ser limitada e que a exploração de estratégias mais dinâmicas e informativas é promissora para avanços na área.

Palavras-chave: Interface Cérebro-Máquina; Imaginação Motora; Eletroencefalograma; Janelamento.

ABSTRACT

Various methods have been developed to record neural activity, with electroencephalography (EEG) being one of the most widely used due to its non-invasive and accessible nature. With the advancement of Brain-Computer Interfaces (BCIs), it has become possible to apply these brain signals in various domains, enabling direct interaction between the brain and external devices. One of the most studied paradigms in BCI is motor imagery (MI), in which the subject imagines movements without physically executing them. These signals are captured and processed so they can be interpreted by computational systems. In the literature, it is common to use fixed time windows starting around 2.5 seconds after the beginning of a trial to perform analyses and classifications. The aim of this work is to evaluate the main methods present in the literature for different temporal windowing strategies, investigating not only efficacy but also the efficiency and stability of methods over time. To this end, the following algorithms were tested: Common Spatial Patterns with LogPower and Naive Bayesian Parzen Window classifier, Filter Bank Common Spatial Patterns, and the EEGNet convolutional neural network, applied under different window configurations. The tests were conducted on widely used datasets from international BCI competitions. The results indicated a clear neurophysiological justification for the recurring use of windows around 2.5 seconds. This interval coincides with greater synchronization of beta frequencies, which are associated with motor imagery, thus enhancing signal discriminability. Furthermore, the study showed that using larger windows tends to improve results by providing more relevant temporal information for the classifiers. Another important finding was that combining multiple windows covering different time intervals not only improves the point performance of classifiers but also contributes to greater stability and quality of results over time. This suggests that the traditional approach of using a single fixed window may be limited and that exploring more dynamic and informative strategies holds promise for advancing BCI research.

Keywords: Brain-Computer Interface; Motor Imagination; Electroencephalogram; Windowing.

LISTA DE ILUSTRAÇÕES

Figura 1 – Representação esquemática de um neurônio.	17
Figura 2 – Áreas de Brodmann.	18
Figura 3 – ERP sendo decomposto nas diversas bandas	19
Figura 4 – Sistemas 10-20 (círculos pretos) ou 10-10 (círculos pretos + círculos brancos).	23
Figura 5 – Ciclo esquemático de uma BCI	25
Figura 6 – Configuração das atividades dentro de um <i>trial</i> para os conjuntos de dados.	27
Figura 7 – Arquitetura do <i>Filter Bank Common Spatial Patterns</i> (FBCSP)	31
Figura 8 – Arquitetura da EEGNet.	33
Figura 9 – Kappa para os diferentes janelamentos no conjunto de dados BCICIV2a	48
Figura 10 – Kappa para os diferentes janelamentos no conjunto de dados BCICIV2b	50
Figura 11 – Kappa para os diferentes janelamentos no conjunto de dados CBCIC	52
Figura 12 – Performance Profile para o método CSP em diferentes janelamentos	55
Figura 13 – Performance Profile para o método FBCSP em diferentes janelamentos	57
Figura 14 – Performance Profile para o método EEGNet em diferentes janelamentos	59

LISTA DE TABELAS

Tabela 1 – Conjunto de Dados avaliados.	26
Tabela 2 – Eletrodos usados em cada conjunto de dados.	26
Tabela 3 – Métodos utilizados em BCI com suas respectivas etapas e funções . . .	29
Tabela 4 – Arquitetura da EEGNet com detalhes de cada camada	34
Tabela 5 – Principais métricas utilizadas na avaliação de sistemas BCI	36
Tabela 6 – WD-score para diferentes tamanhos de janelas e diferentes conjuntos de dados.	41
Tabela 7 – Kappa em 2,5 segundos para diferentes tamanhos de janelas e diferentes conjunto de dados.	42
Tabela 8 – Integração e Oscilação para diferentes tamanhos de janelas e diferentes conjuntos de dados.	43
Tabela 9 – WD-score para diferentes posições de janelas e diferentes conjuntos de dados.	44
Tabela 10 – Kappa em 2,5 segundos para diferentes posições de janelas e diferentes conjuntos de dados.	45
Tabela 11 – Integração e Oscilação para diferentes posições de janelas e diferentes conjuntos de dados.	46

LISTA DE ABREVIATURAS E SIGLAS

Acc	Acurácia
AEP	Potencial Evocado Auditivo
AVC	Acidente Vascular Cerebral
BCI	Interface Cérebro-Máquina
CNS	Sistema Nervoso Central
CSP	Padrões Espaciais Comuns
ECoG	Eletrocorticografia
EEG	Eletroencefalograma
ERD	Dessincronização Relacionada a Evento
ERP	Potenciais Relacionados a Eventos
ErrP	Potencial Relacionado ao Erro
ERS	Sincronização Relacionada a Evento
$E(\circ)$	Valor Esperado (Esperança Matemática)
FBCSP	Banco de Filtros com Padrões Espaciais Comuns
fMRI	Ressonância Magnética Funcional
fNIR	Espectroscopia Funcional no Infravermelho Próximo
FN	Falso Negativo
FP	Falso Positivo
IS	Fala Imaginada
MEG	Magnetoencefalografia
MI	Imaginação Motora
NBPW	Janela de Parzen Ingênua Bayesiana
PET	Tomografia por Emissão de Pósitrons
PP	Perfil de Desempenho
RMSE	Erro Quadrático Médio
SCP	Potencial Cortical Lento
SP	Potência Espectral
SSVEP	Potencial Visual Evocado em Estado Estável
TDAH	Transtorno de Déficit de Atenção com Hiperatividade
TN	Verdadeiro Negativo
TP	Verdadeiro Positivo
VEP	Potencial Evocado Visual
VEPt	Potencial Evocado Vibrotátil
VTP	Potencial Vibrotátil
WD-score	Índice de Janela com Atraso

LISTA DE SÍMBOLOS

$Z_{S,T}$	Matriz do sinal transformado, com dimensões S (número de eletrodos) por T (tamanho do sinal)
$W_{S,S}$	Matriz de transformação, com dimensões S por S
$W_{S,S}^T$	Transposta da matriz de transformação W
$E_{S,T}$	Matriz do sinal original, com dimensões S (número de eletrodos) por T (tamanho do sinal)
$R_{S,S}^a$	Matriz de correlação de elementos para a classe a , com dimensões S por S
$R_{S,S}^b$	Matriz de correlação de elementos para a classe b , com dimensões S por S
λ	Autovalor (utilizado na decomposição de autovalores)
I	Matriz identidade
N^c	Número de amostras de treinamento da classe c
$E_{n,S,T}^c$	A n -ésima amostra de treinamento da classe c dentro da matriz de dados original, com dimensões S por T
f_i	Vetor de características calculado a partir da i -ésima matriz Z
$diag(\circ)$	Operador que retorna a diagonal de uma matriz
$tr(\circ)$	Operador que retorna o traço de uma matriz (soma dos elementos da diagonal)
m	Número de filtros selecionados
Lp	Potência logarítmica do sinal
$Z_{i,B}$	A i -ésima amostra temporal do sinal filtrado pelo CSP, correspondente a uma determinada banda de frequência B
B	Banda de frequência
$G_n(\omega, \omega_0)$	Função de filtro de Chebyshev Tipo II
ω	Frequência angular de análise do sinal
ω_0	Frequência de corte do filtro
ε	Parâmetro associado à ondulação na banda de rejeição do filtro de Chebyshev
$T_n(x)$	Polinômio de Chebyshev de ordem n
$X_{T,B,E,S}$	Conjunto de dados de entrada inicial, onde T é o número de amostras, B o número de bandas, E o número de eletrodos e S o tamanho do sinal
$X_{T,B \times F,E,S}$	Conjunto de dados de entrada transformado após a aplicação do Filter Bank, onde F é o número de filtros dentro do Filter Bank
d	Número total de características disponíveis
F	Conjunto de características
$S = \emptyset$	Conjunto vazio inicial de características selecionadas
Ω	Classe de saída (variável alvo)

$I(f_i; \Omega)$	Informação mútua entre a característica f_i e a classe de saída Ω
k	Parâmetro definido pelo usuário para o número de características a serem selecionadas
E	Número de eletrodos (na arquitetura EEGNet)
T	Tamanho do sinal (na arquitetura EEGNet)
N	Número de classes no output (na arquitetura EEGNet)
F_1	Hiperparâmetro para o número de filtros (camada convolucional temporal na EEGNet)
F_2	Hiperparâmetro para o número de filtros (camada convolucional separável na EEGNet)
D	Hiperparâmetro para a profundidade da convolução (camada convolucional espacial na EEGNet)
p	Probabilidade de dropout
κ	Coefficiente Kappa (métrica de avaliação de concordância)
p_o	Proporção de acertos reais observados pelo sistema
p_e	Proporção de acertos esperados por acaso
n	Número total de amostras (no contexto do RMSE)
y_i	Valor real da i -ésima amostra
$\hat{y}_i$	Valor predito pelo modelo para a i -ésima amostra
$\kappa(t)$	Valor da métrica Kappa ao longo do tempo t
t	Tempo
U	Utilidade média da BCI no longo prazo
$E(\cdot)$	Operador de Valor Esperado (esperança matemática), indicando uma média ao longo de várias tentativas ou simulações
$b(t)$	Benefício que a BCI traz em cada instante de tempo t
T	Tempo total considerado (no contexto da métrica de Utilidade)
t_0	Limite inferior do intervalo de tempo considerado para o cálculo de Integração e Oscilação
t_1	Limite superior do intervalo de tempo considerado para o cálculo de Integração e Oscilação
$\rho_s(\tau)$	Performance profile do método s
n_p	Número total de problemas no conjunto $\mathcal{P}$
$\mathcal{P}$	Conjunto de todos os problemas avaliados
$r_{p,s}$	Razão de desempenho do método s no problema p
τ	Fator de tolerância (no Performance Profile)
$\mathcal{S}$	Conjunto de todos os métodos considerados
$t_{p,s}$	Tempo (ou custo) que o método s leva para resolver o problema p

SUMÁRIO

1	INTRODUÇÃO	14
2	O CÉREBRO	16
3	INTERFACES CÉREBRO-MÁQUINA	21
3.1	PARADIGMAS DE BCI	23
3.2	ETAPAS DE UM PIPELINE DE BCI	24
4	BASES DE DADOS	26
5	MÉTODOS DE ANÁLISE	28
5.1	COMMON SPATIAL PATTERNS	29
5.2	BANCO DE FILTROS COMMON SPATIAL PATTERNS	31
5.2.1	Banco de Filtros	31
5.2.2	Mutual Information based Best Individual Feature	32
5.3	REDE NEURAL CONVOLUCIONAL PARA CLASSIFICAÇÃO DE EEG (EEGNET)	33
6	MÉTRICAS DE AVALIAÇÃO	35
7	ANÁLISE PROPOSTA	38
8	RESULTADOS	40
8.1	TABELAS DE DESEMPENHO	40
8.2	ANÁLISE DO KAPPA NO TEMPO	46
8.3	GRÁFICOS DOS PERFIS DE DESEMPENHO	53
8.4	DISCUSSÃO DOS RESULTADOS	60
9	CONCLUSÃO	63
	REFERÊNCIAS	65

1 INTRODUÇÃO

O crescente interesse pela compreensão do funcionamento cerebral tem impulsionado o desenvolvimento de tecnologias capazes de registrar e interpretar a atividade elétrica do cérebro humano. Essa atividade é gerada por oscilações rítmicas sincronizadas de populações neuronais, as quais produzem variações no potencial elétrico extracelular. Tais variações podem ser captadas por diferentes métodos neurofisiológicos, entre os quais a eletroencefalografia (EEG) se destaca por ser um método não invasivo, com alta resolução temporal e amplamente acessível.

A EEG realiza a medição de variações de voltagem, por meio de eletrodos posicionados sobre o couro cabeludo. Esses registros permitem a análise de ritmos cerebrais que se organizam em bandas de frequência, associadas a distintos estados cognitivos e comportamentais. Esses ritmos são fundamentais na construção de sinais utilizados por Interfaces Cérebro-Máquina (BCI).

As BCIs são sistemas que interpretam os sinais oriundos do sistema nervoso central (SNC) e os convertem em comandos artificiais, viabilizando uma comunicação direta entre o cérebro e dispositivos externos. Uma das primeiras implementações práticas desse conceito foi realizada por J. Vidal [Vidal 1977], utilizando potenciais relacionados a eventos (ERP). Desde então, a tecnologia evoluiu consideravelmente, permitindo, por exemplo, que indivíduos com severas limitações motoras, como aqueles afetados pela síndrome do encarceramento, possam operar dispositivos de maneira autônoma em ambientes domiciliares [Kübler 2019].

Entre os diversos paradigmas utilizados em BCIs, a Imaginação Motora (MI) se destaca, sendo o mais amplamente estudado [Padfield et al. 2019]. Esse paradigma baseia-se na detecção da atividade cerebral associada à imaginação de movimentos corporais, sem a necessidade de realização física. A imaginação de movimentos ativa regiões corticais semelhantes às envolvidas no movimento real, o que torna essa abordagem particularmente promissora para aplicações em reabilitação motora e controle de próteses [Saibene et al. 2023]. Em contextos onde a MI é aplicada ao controle direto de dispositivos, como próteses robóticas, torna-se essencial que a resposta do sistema seja rápida, garantindo uma interação natural e contínua com o ambiente. Por outro lado, em aplicações clínicas, onde se tem o uso de terapias BCI-assistidas, pode-se priorizar uma acurácia elevada em detrimento da latência, dado a se preferir uma resposta de qualidade à uma resposta rápida [Zhang et al. 2019].

Nesse contexto, o estudo do janelamento em sistemas BCI baseados em Imaginação Motora ganha relevância, já que se trata priorização de dados presentes num intervalo de tempo específico para o treinamento das Interfaces, uma vez que o tamanho e o posicionamento das janelas de análise afetam diretamente a qualidade dos dados extraídos

e, por conseguinte, a performance do sistema. Desta forma, investigar como o janelamento impacta a estabilidade e a confiabilidade dos sistemas MI-BCI é fundamental para o desenvolvimento de soluções mais eficazes e adaptáveis ao longo do tempo. Além disso, a análise da estabilidade temporal dos dados pode revelar janelas de desempenho ideais, que por sua vez podem possivelmente estar relacionadas a fatores neurofisiológicos específicos.


Este trabalho está organizado em nove capítulos. No Capítulo 2, são abordados os fundamentos da atividade elétrica cerebral e a técnica de eletroencefalografia. O Capítulo 3 introduz as Interfaces Cérebro-Máquina, com ênfase no paradigma de Imaginação Motora. Em seguida, o Capítulo 4 apresenta os conjuntos de dados utilizados, enquanto os Capítulos 5 e 6 detalham os métodos de avaliação e as métricas adotadas, respectivamente. A proposta metodológica é discutida no Capítulo 7, e os resultados obtidos, com suas respectivas análises comparativas e discussões críticas, são apresentados no Capítulo 8. Por fim, o Capítulo 9 encerra o trabalho com as conclusões, limitações do estudo e sugestões para investigações futuras.

2 O CÉREBRO

O cérebro humano é um órgão complexo e responsável por todas as funções cognitivas, motoras, sensoriais e emocionais dos seres humanos. No centro dessas funções estão os neurônios. Os neurônios são uma das células que compõem nosso sistema nervoso. É através dessas células que as informações são transportadas de um lado para o outro dentro do nosso corpo. Para fazer essa passagem, o neurônio possui 2 mecanismos principais: o potencial de ação e a sinapse.

Para entender como esses mecanismos funcionam, é necessário conhecer as três divisões principais de um neurônio, como demonstra a Figura 1. A primeira parte são os dendritos, que recebem os estímulos externos e os repassam para o corpo do neurônio. O corpo celular (soma), por sua vez, integra as informações recebidas e, caso o limiar de ativação seja alcançado, gera um sinal elétrico, também chamado de potencial de ação. O axônio então conduz esse sinal até suas extremidades, onde ocorre a comunicação com outras células por meio das sinapses [Bear, Connors e Paradiso 2017].

Figura 1 – Representação esquemática de um neurônio.



Fonte: Figura retirada de [Bear, Connors e Paradiso 2017].

Quando aglomeramos múltiplos neurônios em um ecossistema funcional em nossa cabeça, temos como resultado, o encéfalo humano. O encéfalo pode ser subdividido em quatro áreas principais:


- O Cérebro (ou telencéfalo) é a maior porção do encéfalo, composto pelos dois hemisférios cerebrais e responsável por funções superiores como raciocínio, percepção sensorial, controle motor voluntário e linguagem.
- O Diencefalo, situado abaixo do cérebro, inclui estruturas como o tálamo e o

hipotálamo, que atuam na regulação sensorial, hormonal e autonômica.

- O Tronco encefálico conecta o cérebro à medula espinhal e controla funções automáticas essenciais, como batimentos cardíacos, respiração e reflexos.
- O Cerebelo, localizado na parte posterior e inferior do encéfalo, é responsável pela coordenação motora, equilíbrio e aprendizado de movimentos.

Para melhor demonstrar como as diferentes áreas do córtex cerebral se organizam funcionalmente, a categorização proposta por Korbinian Brodmann. Essas regiões, conhecidas como áreas de Brodmann [Jacobs 2011], são amplamente utilizadas como referência anatômica e funcional na neurociência. A Figura 2 ilustra esse mapeamento [Başar e Düzgün 2016].

Figura 2 – Áreas de Brodmann.



Fonte: Figura retirada de [Başar e Düzgün 2016].

A atividade de cada uma das regiões apresentadas no mapa de Brodmann está associada a funções específicas. Um exemplo é a área 4, que corresponde ao córtex motor primário, responsável pelo controle voluntário da musculatura esquelética. Outra área, por exemplo, é a 17, relacionada ao córtex visual primário. Assim, a compreensão dessas divisões permite relacionar padrões de ativação cerebral às funções sensoriais, motoras e cognitivas.


Essa atividade neuronal dentro do encéfalo gera oscilações rítmicas de natureza elétrica (voltaica) que são resultados da atividade sincronizada de populações neuronais, especialmente nos dendritos dos neurônios piramidais corticais. Essa atividade gera variações de potencial elétrico extracelular, que podem ser medidas por métodos específicos de aquisição de sinais neurofisiológicos. Alguns métodos são a eletroencefalografia, a magnetoencefalografia e a eletrocorticografia.

Entre esses métodos, destaca-se a eletroencefalografia (EEG), uma técnica não invasiva que permite registrar a atividade elétrica cerebral a partir de eletrodos posicionados

no couro cabeludo. O EEG capta variações de voltagem na faixa de microvolts (μV), produzidas principalmente por potenciais pós-sinápticos. Quando esses potenciais se sincronizam em larga escala, formam padrões oscilatórios conhecidos como ritmos cerebrais, classificados em bandas de frequência: delta (0.5–4 Hz), teta (4–8 Hz), alfa (8–13 Hz), beta (13–30 Hz) e gama (acima de 30 Hz) [Amzica e Silva 2012].

Esses ritmos refletem a dinâmica funcional do encéfalo em diferentes estados cognitivos e comportamentais. Os potenciais relacionados a eventos (event-related potentials, ERP) evocados compostos resultam da superposição de oscilações nessas faixas de frequência — consideradas as “frequências naturais do cérebro” — como delta: 0.5–3.5 Hz, teta: 3.5–7 Hz, alfa: 8–13 Hz, beta: 15–30 Hz e gama: 30–70 Hz, conforme ilustrado na Figura 3 [Başar e Düzgün 2016].

Figura 3 – ERP sendo decomposto nas diversas bandas



Fonte: Figura retirada de artigo [Başar e Düzgün 2016].

Tradicionalmente, os sistemas de EEG operavam com frequências de amostragem em torno de 100 Hz. No entanto, já é comum encontrar sistemas que coletam dados a 500 Hz ou mais. Contudo, é importante destacar que, ao se ampliar a faixa de coleta, aumenta-se também a suscetibilidade a ruídos, exigindo cuidados adicionais no pré-processamento e na filtragem dos dados [Başar e Düzgün 2016].

Já na década de 1970 começaram a surgir sistemas computacionais baseados na coleta dessa atividade neural, como a EEG-BCI de J. Vidal [Vidal 1977]. A partir daí, diversos outros sistemas foram criados sob a definição de Interfaces Cérebro-Máquina (Brain-Computer Interface, BCI), cujo principal objetivo é o controle de algum dispositivo, mecânico ou computacional, através da atividade neuronal. Isso gerou novas alternativas para pessoas com deficiências motoras severas, possibilitando o envio de comandos

diretamente a partir da atividade cerebral, sem a necessidade de envolvimento muscular [Sosa et al. 2011].

Com o passar do tempo, as aplicações das BCIs se expandiram consideravelmente. Hoje, essas interfaces são estudadas e aplicadas em áreas como:

- Neuroreabilitação, auxiliando pacientes com lesões medulares ou sequelas de AVC a recuperar movimentos, ou reestabelecer conexões sensório-motoras [Daly e Huggins 2015];
- Controle de próteses robóticas e cadeiras de rodas, permitindo o comando direto a partir de padrões mentais [Katyal et al. 2014];
- Entretenimento e realidade virtual, onde usuários interagem com jogos ou ambientes virtuais usando apenas a atividade cerebral [Marshall et al. 2013];
- Neurofeedback e treinamento cognitivo, com foco em melhorar atenção, memória ou controlar distúrbios como TDAH e ansiedade [Jeunet et al. 2019].

3 INTERFACES CÉREBRO-MÁQUINA

Interfaces Cérebro-Máquina (BCI) se tratam de sistemas computacionais cuja função é proporcionar o manejo de dispositivos mecânicos ou computacionais mediante dados coletados sobre a atividade cerebral de um indivíduo. Uma definição mais formal é “*Um sistema que mede a atividade do sistema nervoso central (SNC) e a converte em um sinal artificial que substitui, restaura, aprimora, suplementa, informa ou melhora a saída natural do SNC e, assim, modifica as interações em andamento entre o SNC e seu ambiente interno ou externo.*” [Wolpaw e Wolpaw 2012]. Desta forma, temos que uma BCI cria uma interação em tempo real entre seu usuário e o mundo.

Uma das primeiras BCI criadas foi a EEG-BCI de J. Vidal [Vidal 1977], onde o objetivo era mover um símbolo em um labirinto usando Potenciais Relacionados a Eventos (ERP). O usuário via flashes de luzes de xenônio em quatro posições, cada uma indicando uma direção (cima, baixo, esquerda, direita). Cada flash gerava um sinal diferente no cérebro, que era usado para saber qual direção o usuário queria seguir.

Com o tempo, as BCIs evoluíram, passando de sistemas simples de comunicação para aplicações complexas controladas diretamente pela atividade cerebral. Nas últimas décadas, pesquisas focaram em pessoas com paralisia severa (síndrome do encarceramento), e desde a década de 2010, já é possível encontrar exemplos de pacientes utilizando BCI de forma autônoma em casa [Kübler 2019].

Um dos fatores que contribuiu para a popularização das BCIs foram as competições na área, pois elas disponibilizaram ao público conjuntos de dados já organizados, permitindo que pesquisadores e entusiastas testassem e comparassem algoritmos em condições padronizadas. Dado esse fato, junto ao avanço acelerado da ciência da computação, com o surgimento de algoritmos de processamento de dados mais rápidos e computadores mais potentes, o desenvolvimento das interfaces cérebro-computador também se acelerou significativamente [Caiado e Ukolov 2025].

A BCI *Competition*, por exemplo, resultou no surgimento de novas abordagens baseadas em aprendizado de máquina e aprendizado profundo [Blankertz et al. 2004, Blankertz et al. 2006, Brunner et al. 2012]. Além disso, o caráter competitivo e aberto dessas iniciativas atraiu a atenção de uma comunidade multidisciplinar e ajudou a criar métricas que direcionaram o progresso da área.

Compor um conjunto de dados para BCI assim como os das competições pode ser feito de diversas formas. Normalmente os métodos utilizados são divididos entre invasivos e não invasivos. Alguns deles são:


- EEG (eletroencefalografia): registra a atividade elétrica do cérebro por meio de eletrodos colocados no couro cabeludo;

- ECoG (eletrocorticografia): mede sinais elétricos diretamente da superfície do cérebro, por meio de procedimentos invasivos;
- Registros intracorticais: captam a atividade de neurônios individuais utilizando eletrodos inseridos no tecido cerebral;
- MEG (magnetoencefalografia): detecta os campos magnéticos gerados pela atividade neural;
- fMRI (ressonância magnética funcional): mapeia o fluxo sanguíneo cerebral associado à atividade cerebral;
- fNIR (imagem por espectroscopia no infravermelho próximo): mede alterações na oxigenação do sangue no cérebro de forma não invasiva;
- PET (tomografia por emissão de pósitrons): utiliza substâncias radioativas para visualizar o metabolismo cerebral.

Apesar da diversidade de métodos, tecnologias como MEG, fMRI e PET ainda não são adequadas para o uso diário em sistemas BCI, devido ao alto custo, à complexidade dos equipamentos e à baixa capacidade de processamento em tempo real [Wolpaw e McFarland 2013]. Por outro lado, métodos baseados em sinais elétricos, como o EEG, apresentam maior viabilidade para aplicações práticas e acessíveis em curto e médio prazo. O que resultou no fato de a maioria das BCIs de sistemas não invasivos serem baseadas em dados de EEG [Kawala-Sterniuk et al. 2021].

Aprofundando na utilização dos EEGs, temos que para a coleta dos dados é necessário dispor os eletrodos em torno da cabeça do indivíduo em questão. A colocação dos eletrodos foi padronizada por um sistema internacional chamado sistema 10–20 ou 10-10 para uma disposição mais densa, assim como mostra a Figura 4 [Tatum et al. 2008]. As seguintes designações são utilizadas: Fp (frontopolar), F (frontal), T (temporal), O (occipital), C (central), P (parietal). A letra “z” indica a linha média, enquanto números pares e ímpares representam respectivamente os hemisférios direito e esquerdo [Tatum et al. 2008].

Figura 4 – Sistemas 10-20 (círculos pretos) ou 10-10 (círculos pretos + círculos brancos).



Fonte: Figura retirada de artigo [Tatum et al. 2008].

3.1 PARADIGMAS DE BCI

A coleta dos dados para BCI varia de acordo com o paradigma adotado. Nessa seção abordaremos os principais paradigmas de BCI, dando um foco maior ao paradigma de Imaginação Motora (MI) na subseção ??, classificados por sua natureza e modo de controle, são [Caiado e Ukolov 2025]:

- Fala imaginada (IS): consiste na imaginação de uma palavra ou frase específica, gerando padrões neuronais distintos. É uma BCI independente, endógena, podendo ser síncrona ou assíncrona.
- Imaginação motora (MI): envolve a imaginação de movimentos de partes do corpo, resultando em padrões cerebrais detectáveis. Também é uma BCI independente, endógena, e pode ser síncrona ou assíncrona.
- Potenciais evocados visuais (VEP ou SSVEP / P300), auditivos (AEP) e vibrotáteis (VTP ou VEPT): utilizam estímulos sensoriais externos (como luzes, sons ou vibrações) que provocam respostas específicas no cérebro. São BCIs exógenas e síncronas, podendo ser dependentes ou independentes.
- Potencial de erro (ErrP): ocorre quando o sistema interpreta incorretamente a intenção do usuário, gerando um sinal que permite a correção automática. É uma BCI independente, exógena e assíncrona.

- Potenciais corticais lentos (SCP): referem-se a alterações lentas no potencial da região pré-frontal do cérebro, geralmente com feedback sensorial. Classifica-se como BCI independente, endógena e assíncrona.
- Mudanças espectrais (SP / ERD / ERS): mudanças nos sinais cerebrais causadas por estados cognitivos ou emocionais do usuário, sem controle voluntário. Podem ser endógenas ou exógenas, e funcionar de forma síncrona ou assíncrona.

Dentre os paradigmas apresentados, o MI é um dos mais pesquisados dado seu amplo espectro de aplicações em áreas como neuroreabilitação, neuropróteses e jogos [Padfield et al. 2019]. Essa afirmação é reforçada por uma revisão sistemática da literatura feita com dados de 2009 até 2019 que apontou o paradigma MI como o mais popular [Värbu, Muhammad e Muhammad 2022].

O paradigma MI é um dos mais amplamente estudados no contexto de BCI. Esse paradigma baseia-se na captação de sinais neurais gerados quando o indivíduo imagina o movimento de um membro específico, sem realizar qualquer ação física. Estudos demonstram que a atividade cerebral durante a imaginação de movimentos aciona áreas semelhantes às envolvidas na execução real desses movimentos [Saibene et al. 2023].


Durante a coleta dos dados, o indivíduo é inicialmente informado de que uma sequência de tarefas será apresentada. Após um breve intervalo, o tipo de movimento a ser imaginado é exibido da maneira mais simples possível para evitar outros estímulos neuronais. O participante, então, realiza a imaginação do movimento solicitado. Entre cada tentativa, uma pequena pausa é feita antes do início da próxima sequência.

Uma vez que os dados são coletados, eles podem ser processados por uma BCI para diversas finalidades. As aplicações variam desde controle de dispositivos até usos clínicos. Entre essas aplicações, destaca-se o uso da imaginação motora na reabilitação de pacientes pós-acidente vascular cerebral (AVC), onde o treinamento com MI pode auxiliar na recuperação das funções motoras [Daly e Huggins 2015].

3.2 ETAPAS DE UM PIPELINE DE BCI

Nesta seção, destacamos as principais etapas envolvidas no funcionamento de um sistema de BCI, conforme ilustrado na Figura 5. O ciclo apresentado descreve desde a aquisição dos sinais cerebrais até a execução de comandos em um dispositivo externo. A estruturação desse ciclo se baseia em trabalhos como o de [Pal et al. 2024].

Figura 5 – Ciclo esquemático de uma BCI



Fonte: Figura de autoria própria.

O processo inicia-se com a aquisição do sinal eletroencefalográfico (EEG), captado por meio de sensores posicionados no couro cabeludo. Esse sinal bruto é então submetido a um pré-processamento para reduzir ruídos e interferências externas, como a diferença de potencial das tomadas do cômodo. Em seguida, são aplicadas técnicas de filtragem temporal e espacial, responsáveis por isolar faixas de frequência e regiões cerebrais relevantes à tarefa.

Após essa etapa, realiza-se a extração de características, na qual se busca representar matematicamente os padrões neurais de interesse e selecionar aqueles de maior interesse. Esses dados são então encaminhados a um classificador, que interpreta as características extraídas e as converte em comandos. Esses comandos são transmitidos a uma aplicação ou dispositivo externo, permitindo uma interação efetiva com o ambiente. O *feedback* gerado é então recebido pelo usuário, fechando o ciclo e possibilitando o ajuste voluntário do padrão neural nas próximas interações.

O modelo de BCI apresentado na Figura 5 contém as etapas principais para o funcionamento da mesma. Entretanto, nem toda BCI irá constituir de todas essas etapas, sendo de interesse do programador definir quais etapas serão utilizadas e quais métodos utilizar em cada etapa. Isso possibilita a criação algoritmos customizados para cada problema.

4 BASES DE DADOS

Nesse trabalho serão utilizados apenas conjuntos de dados públicos de BCI para o paradigma MI. Esses conjuntos de dados são de competições internacionais de BCI, que estão estabelecidos na literatura por conta da padronização na coleta, do processamento e disponibilização. Os conjuntos de dados são o BCICIV2a [Brunner et al. 2012], o BCICIV2b [Brunner et al. 2012] e o CBCIC [Chowdhury e Andreu-Perez 2021]. A Tabela 1 demonstra os dados presentes dentro deles. As colunas indicam: o nome do conjunto, seu acrônimo, o número de participantes, a quantidade de eletrodos utilizados para coleta dos sinais de EEG, o número de classes motoras (como mão esquerda e direita) e o número de tentativas (trials) por sujeito e classe.

Tabela 1 – Conjunto de Dados avaliados.

Nome	Acrônimo	Sujeitos	Eletrodos	classes	trials
<i>BCI Competition IV 2a</i>	2a	9	22	4	144
<i>BCI Competition IV 2b</i>	2b	9	3	2	360
<i>Clinical BCI Challenge</i>	cbcic	10	12	2	60

Apesar das variações nos objetivos experimentais, um aspecto relevante é que todos apresentam um número de sujeitos participantes relativamente próximo, o que facilita comparações entre estudos. Além disso, todos incluem duas classes principais de tarefas motoras imaginadas: movimentos da mão esquerda e da mão direita.

Os eletrodos utilizados na coleta dos dados estão presentes na Tabela 2. Todos os conjuntos de dados apresentam os eletrodos posicionados conforme o sistema internacional 10-20 ou suas variações. Todos os conjuntos de dados dão destaque aos eletrodos C3, Cz e C4. Isso ocorre, pois esses eletrodos estão em regiões próximas às áreas de Brodmann sensório-motoras [Guttmann-Flury, Sheng e Zhu 2022], que são importantes para o paradigma MI.

Tabela 2 – Eletrodos usados em cada conjunto de dados.


Conjunto de dados	Eletrodos
BCICIV2a	Fz, FC3, FC1, FCz, FC2, FC4, C5, C3 , C1, Cz , C2, C4 , C6, CP3, CP1, CPz, CP2, CP4, P1, Pz, P2, POz
BCICIV2b	C3 , Cz , C4
CBCIC	F3, FC3, C3 , CP3, P3, FCz, CPz, F4, FC4, C4 , CP4, P4

Para coletar a atividade neuronal de cada *trial*, existe um passo a passo a ser seguido para cada um dos conjuntos de dados. A Figura 6 esquematiza esse passo a passo que normalmente é composto de três a quatro etapas:

- Fase de Preparação (Preparação): Uma mensagem na tela avisa que a tarefa vai começar, permitindo que o participante se concentre.

- Apresentação da Instrução (Dica): Um símbolo ou indicação visual (como uma seta) é exibido na tela, informando qual movimento imaginário deve ser realizado (ex: mão esquerda ou direita).
- Execução da Imaginação Motora (Tarefa): O participante imagina o movimento solicitado durante alguns segundos, enquanto os sinais cerebrais são registrados.
- Período de Descanso (Pausa): Uma breve pausa é incluída antes do início da próxima tentativa, permitindo que o cérebro retorne a um estado neutro.

Figura 6 – Configuração das atividades dentro de um *trial* para os conjuntos de dados.



Fonte: Figura de autoria própria

No processo de construção desses conjuntos de dados, tem-se que utilizar separações entre dados de treino, utilizados pelos competidores na criação da sua abordagem, e dados de teste, utilizados para validar o melhor método pela competição. Entretanto, tem-se que o BCICIV2b tem um processo mais complexo relacionado à sua coleta, onde as duas primeiras seções seriam realizadas como BCICIV2a e CBCIC, enquanto as três últimas envolveriam um mecanismo de feedback. Isso resulta num particionamento de 240 *trials* sem feedback e 480 *trials* com feedback, o que afeta diretamente os métodos de BCI dependendo da análise feita.

5 MÉTODOS DE ANÁLISE

Existem diversos tipos de métodos utilizados para a análise de sinais de EEG em BCI. Esses métodos podem ser classificados de maneira geral em três grandes categorias que são baseadas nas etapas de uma BCI. Essas categorias são métodos de pré-processamento; métodos de extração e seleção de características; e métodos de classificação. A primeira categoria é responsável por remover os ruídos, como os originários da movimentação dos olhos e batimentos cardíacos. A segunda categoria é responsável por extrair características desse sinal e selecionar as melhores. Por fim, a terceira é responsável por categorizar as características da etapa anterior em relação ao vetor de características do sinal cerebral.

Pegando como referência o trabalho de [Niha e Banu 2016], temos a Tabela 3, que resume os principais métodos utilizados em sistemas de BCI para análise de sinais de EEG. A tabela apresenta três colunas principais: Nome do Método, indicando o nome e a sigla; Etapa, para indicar a qual categoria aquele método pertence; e Função, que descreve o objetivo do uso daquele método no sistema de forma breve.

Neste trabalho, o foco será dado a três métodos principais, amplamente reconhecidos e utilizados em competições internacionais de BCI. Os métodos escolhidos representam diferentes abordagens para o problema: desde técnicas lineares clássicas até modelos mais modernos baseados em redes neurais profundas. São eles CSP (Common Spatial Patterns)[Park e Chung 2018], o FBCSP (Filter Bank Common Spatial Patterns) [Ang et al. 2008] e a rede convolucional EEGNet [Shamas et al. 2015]. Serão apresentados nas seções 5.1, 5.2 e 5.3 os métodos implementados nesse trabalho e como eles funcionam.

Tabela 3 – Métodos utilizados em BCI com suas respectivas etapas e funções

Nome do Método	Etapa	Função
Filtro Adaptativo (Adaptive Filter)	Pré-processamento	Remove ruídos do sinal mantendo as informações relevantes.
Laplaciano de Superfície (Surface Laplacian)	Pré-processamento	Estima a densidade de corrente e reduz interferências locais.
Padrões Espaciais Comuns (CSP)	Pré-processamento	Destaca padrões espaciais discriminativos entre classes.
Análise de Componentes Principais (PCA)	Pré-processamento / Extração de características	Reduz dimensionalidade e extrai informações mais relevantes.
Análise de Componentes Independentes (ICA)	Extração de características	Separa componentes independentes como artefatos oculares/musculares.
Transformada Wavelet (WT)	Extração de características	Analisa sinais no domínio tempo-frequência em múltiplas escalas.
Decomposição em Pacotes de Wavelet (WPD)	Extração de características	Análise mais detalhada que WT, com maior custo computacional.
Transformada Rápida de Fourier (FFT)	Extração de características	Extrai componentes de frequência de sinais estacionários.
Análise Discriminante Linear (LDA)	Classificação	Classificador linear simples e eficiente, de baixo custo.
Máquina de Vetores de Suporte (SVM)	Classificação	Classificador robusto, com boa capacidade de generalização.
Classificador de Bayes Ingênuo (NBC)	Classificação	Baseado em probabilidade; requer pouco dado para treinar.
Rede Neural Artificial (ANN)	Classificação	Classificador não linear com múltiplas camadas e boa capacidade de aprendizado.
k-Vizinhos Mais Próximos (k-NN)	Classificação	Classifica com base na proximidade entre amostras de treinamento.

5.1 COMMON SPATIAL PATTERNS

O método Padrões Espaciais Comuns (CSP) é um método de filtragem espacial que também auxilia na extração de características. Ele é um método estatístico que busca encontrar padrões espaciais discriminativos entre apenas duas classes de dados a e b . Sua aplicação é dada por:

$$Z_{S,T} = W_{S,S}^T \times E_{S,T} \quad (5.1)$$

onde Z é uma matriz do tamanho do sinal (T) pelo número de eletrodos (S) responsável por demonstrar o sinal transformado após a multiplicação da matriz de transformação W pela matriz E original. A matriz W é definida através do seguinte cálculo de decomposição de autovalores:

$$R_{S,S}^a W_{S,S} = (R_{S,S}^a + R_{S,S}^b) W_{S,S} \lambda \quad (5.2)$$

A maximização desse problema é restrita para garantir que a soma das matrizes diagonais dos autovalores seja igual à identidade, ou seja, $\lambda^a + \lambda^b = I$. Nessa equação temos também que R é a matriz de correlação de elementos para uma determinada classe a ou b . Para encontrar R para uma classe qualquer c é necessário realizar a seguinte equação:

$$R_{S,S}^c = \frac{1}{N^c} \sum_n^{N^c} (E_{n,S,T}^c) (E_{n,S,T}^c)^T \quad (5.3)$$

Nesta equação temos N^c como sendo o número de amostras de treinamento da classe c em questão. Enquanto isso, $E_{n,S,T}^c$ representa a n -ésima amostra de treinamento da classe c dentro da matriz de dados original. Com isso, é possível encontrar o valor de Z . Uma vez feito isso, é possível extrair as características dessa matriz Z ao realizar:

$$f_i = \log \left(\frac{\text{diag}(Z_i Z_i^T)}{\text{tr}(Z_i Z_i^T)} \right) \quad (5.4)$$

Por fim, temos o vetor de características f_i calculado utilizando a i -ésima matriz Z sobre o efeito do cálculo da diagonal $\text{diag}(\circ)$ e traço $\text{tr}(\circ)$. Isso produz um total de filtros coletados igual ao número de eletrodos. Esse vetor final $f = [f_1, f_2, \dots, f_m]$ com m filtros selecionados tem a seguinte característica: os primeiros $m/2$ componentes são calculados com base na variância de uma classe a e os últimos $m/2$ componentes com base na variância de uma classe b . Esse final pode ser reduzido dependendo do número m escolhido.

Depois do CSP outros métodos podem ser aplicados. O mais utilizado é a *Logarithmic Power Representation* (Log Power)[Aspiras e Asari 2011], por conta de relacionar bem com os autovetores encontrados no CSP. A Log Power cuja função é comprimir o valor de potência encontrado em cada uma das bandas de frequência dos dados do EEG. Dessa forma, para alcançar a potência logarítmica do sinal Lp realizamos:

$$Lp = \log \left(\sum_i^T \frac{(Z_{i,B})^2}{T} \right) \quad (5.5)$$


Nesta equação temos que $Z_{i,B}$ é a i -ésima amostra temporal do sinal filtrado pelo CSP, correspondente a uma determinada banda de frequência B , $Z_{i,B}$ é a i -ésima amostra

temporal do sinal filtrado pelo CSP, correspondente a uma determinada banda de frequência B e T é o tamanho do sinal. Terminadas as etapas de extração de características, o método *Naive-Bayes Parzen Window*(NBPW) classifica os sinais gerados para determinar a classe.

5.2 BANCO DE FILTROS COMMON SPATIAL PATTERNS

O *Filter Bank Common Spatial Patterns* (FBCSP) é uma extensão do CSP que incorpora a análise em múltiplas bandas de frequência (um *filter bank*) e por isso o nome desse método. Ele é composto por quatro etapas sequenciais. A Figura 7 demonstra esse passo a passo. Primeiro o sinal de EEG passa por filtros passa-faixa múltiplos usando filtros de Chebyshev Tipo II de fase zero. Depois ocorre a filtragem espacial usando o algoritmo CSP. Feito isso, um método de seleção de características é utilizado nos dados produzidos pelo CSP. Por fim é aplicado algum método de classificação das características CSP selecionadas.

Figura 7 – Arquitetura do *Filter Bank Common Spatial Patterns* (FBCSP)



Fonte: Figura de autoria própria

As duas últimas etapas do FBCSP, seleção de características e classificação, podem ser realizadas por diversos métodos diferentes, como mostra na imagem. O FBCSP implementado utiliza para a seleção de características o *Mutual Information based Best Individual Feature* (MIBIF) e para o processo de classificação o *Linear Discriminant Analysis* (LDA).

5.2.1 Banco de Filtros

O Filter Bank (FB) consiste em aplicar múltiplos filtros passa-banda em um sinal de entrada com o objetivo de se obter várias representações do mesmo sinal. Para realizar

essas filtragens, utiliza-se o filtro de Chebyshev Tipo II. Esses filtros, por sua vez, funcionam da seguinte forma [Prakash et al. 2021]:

$$G_n(\omega, \omega_0) = 1/\sqrt{\left(1 + 1/\left(\varepsilon^2 T_n^2 \frac{\omega_0}{\omega}\right)\right)} \quad (5.6)$$

Nessa equação, ω representa a frequência angular de análise do sinal, enquanto ω_0 corresponde à frequência de corte do filtro. O parâmetro ε está associado à ondulação presente na banda de rejeição, controlando a taxa de atenuação nessa região. O termo $T_n(x)$ corresponde ao polinômio de Chebyshev de ordem n . Este polinômio é responsável pela forma característica da resposta em frequência dos filtros de Chebyshev, influenciando diretamente a inclinação da curva na região de transição entre a banda passante e a banda de rejeição.

Desta forma, uma vez aplicados os Chebyshev Tipo II para as bandas em questão, geram-se novos conjuntos de dados de sinais realçando uma faixa de frequências específicas. O resultado é, portanto, a transformação de um conjunto de dados de entrada inicial $X_{T,B,E,S}$ em $X_{T,B \times F,E,S}$ onde T é o número de amostras, B o número de bandas, E o número de eletrodos, S o tamanho do sinal e F o número de filtros dentro do FB.

5.2.2 Mutual Information based Best Individual Feature

O algoritmo *Mutual Information based Best Individual Feature* (MIBIF) é uma técnica de seleção de características baseada na abordagem de filtro, cujo objetivo é escolher as melhores características de um conjunto de dados considerando a informação mútua entre cada característica e a classe de saída [Ang et al. 2008]. A informação mútua é uma métrica que quantifica a dependência estatística entre variáveis, permitindo identificar quais características fornecem mais informação sobre a variável de saída.

O funcionamento do algoritmo inicia-se com a definição de um conjunto de características $F = \{f_1, f_2, \dots, f_d\}$, em que d representa o número total de características disponíveis. Além disso, é inicializado um conjunto vazio $S = \emptyset$, que ao final conterá as características selecionadas. Em seguida, é calculada a informação mútua de cada característica $f_i \in F$ em relação à classe de saída Ω , dada por $I(f_i; \Omega)$ para todo $i = 1, \dots, d$.

Após o cálculo da informação mútua, o algoritmo inicia o processo iterativo de seleção das melhores características. Em cada iteração, a característica f_i que maximiza a informação mútua $I(f_i; \Omega)$ é selecionada e adicionada ao conjunto S , sendo removida de F . Esse procedimento é repetido até que o conjunto S possua exatamente k características, em que k é um parâmetro definido pelo programador.

Assim, o algoritmo MIBIF seleciona as k características mais informativas em relação à classe de saída, considerando unicamente a dependência entre cada característica e a variável alvo.

5.3 REDE NEURAL CONVOLUCIONAL PARA CLASSIFICAÇÃO DE EEG (EEG-NET)


A *EEGNet* é uma arquitetura de rede neural convolucional (CNN) que se espelha na arquitetura do FBCSP, pois combina camadas convolucionais espaciais, camadas convolucionais temporais, camadas convolucionais separáveis e a *Softmax*. Essas estruturas simulam as quatro etapas do funcionamento do FBCSP de filtragem temporal, filtragem espacial, seleção de características e classificação.

A Figura 8 mostra a arquitetura da EEGNet. As camadas azuis indicam convoluções temporais, enquanto os blocos laranja indicam convoluções espaciais. As camadas seguintes em amarelo representam convoluções separáveis que realizam uma compressão das características extraídas. Após cada uma dessas camadas ocorre uma camada de normalização.

Os círculos marcados com “A-P-D” representam, respectivamente, camadas de ativação marcadas pelo uso da função ELU, pooling para a redução de dimensionalidade espacial e/ou temporal, e *dropout* para a regularização e evitar uma superespecialização do modelo. A fusão das saídas em “M” significa um *merge* dos dados, ou seja, ocorre a concatenação deles, remetendo à etapa de seleção de características do FBCSP.

Na parte final da rede temos uma etapa roxa que representa uma convolução profunda seguida por normalização, *pooling*, e *dropout*, agora aplicada às características combinadas. A última camada representa a etapa de classificação, marcada pela presença da *Softmax*, finalizando a simulação das quatro etapas principais do FBCSP: filtragem temporal, espacial, extração/seleção de características e classificação.

Figura 8 – Arquitetura da EEGNet.



Fonte: Figura retirada de artigo [Souza et al. 2023]

A Tabela 4 demonstra com mais clareza a transformação dos dados pelas camadas da EEGNet. A primeira coluna identifica os blocos visuais da Figura 8, com base em cores ou símbolos. A segunda coluna nomeia o tipo de camada usada. A terceira indica o número de filtros nas camadas convolucionais. A quarta mostra o tamanho do kernel (janela da

convolução). A quinta apresenta a quantidade de parâmetros treináveis, e a última coluna exibe o formato da saída após cada transformação nos dados. Vale ressaltar que a letra “E” nas colunas representa o número de eletrodos, “T” o tamanho do sinal, “N” o número de classes no output. Além disso, os hiperparâmetros F_1, F_2 e D são implementados seguindo as configurações originais da EEGNet-8,2[Lawhern et al. 2018]. Dessa forma, temos que $F_1 = 8, F_2 = 16, D = 2$ e que a probabilidade de *dropout* é de $p = 0,5$.

Tabela 4 – Arquitetura da EEGNet com detalhes de cada camada

Bloco	Camada	Filtro	Tamanho	Parâmetros	Output
	Input	-	-	-	(E, T)
	Reshape	-	-	-	(1, E, T)
Azul	Conv2D	F_1	(1, 64)	$64 \cdot F_1$	(F_1, E, T)
Branco	BatchNorm	-	-	$2 \cdot F_1$	(F_1, E, T)
Laranja	DepthwiseConv2D	$D \cdot F_1$	(E, 1)	$E \cdot D \cdot F_1$	$(D \cdot F_1, 1, T)$
Branco	BatchNorm	-	-	$2 \cdot D \cdot F_1$	$(D \cdot F_1, 1, T)$
A	Activation	-	-	-	$(D \cdot F_1, 1, T)$
P	AveragePool2D	-	(1, 4)	-	$(D \cdot F_1, 1, T/4)$
D	Dropout	-	-	-	$(D \cdot F_1, 1, T/4)$
Amarelo	SeparableConv2D	F_2	(1, 16)	$16 \cdot D \cdot F_1 + F_2 \cdot (D \cdot F_1)$	$(F_2, 1, T/4)$
Branco	BatchNorm	-	-	$2 \cdot F_2$	$(F_2, 1, T/4)$
A	Activation	-	-	-	$(F_2, 1, T/4)$
P	AveragePool2D	-	(1, 8)	-	$(F_2, 1, T/32)$
D	Dropout	-	-	-	$(F_2, 1, T/32)$
M	Flatten	-	-	-	$(F_2 \cdot T/32)$
Roxo	Dense	-	-	$N \cdot (F_2 \cdot T/32)$	N
Classificador	Softmax	-	-	-	N

6 MÉTRICAS DE AVALIAÇÃO

Existem diversas métricas para a avaliação de uma BCI. A primeira e mais utilizada foi acurácia. A maioria dos estudos feitos em BCI a utilizam como métrica [Souza 2025]. Entretanto, somente utilizar a acurácia como métrica não foi o suficiente para modular as BCI para MI [Ascensão et al. 2019]. Por isso, outras métricas foram propostas para avaliar o desempenho das BCIs, como mostra a Tabela . Algumas das métricas utilizadas incluem:

- Acurácia: primeira métrica adotada e ainda a mais comum em estudos com BCI;
- *Kappa* médio e erro quadrático médio (RMSE): utilizadas na *BCI Competition III* [Blankertz et al. 2004];
- *Kappa* máximo: utilizado na BCI Competition IV [Brunner et al. 2012];
- WD-score (*Window-Delay Score*): surgiu em resposta a aplicações em tempo real onde o modelo é utilizado em diversas janelas diferentes [Souza et al. 2023];
- Utilidade (*Utility Metric*): propõe uma perspectiva mais centrada no usuário como forma de avaliação [Seno, Matteucci e Mainardi 2010];
- Integração e Oscilação: para uma análise do comportamento médio do modelo. [Souza 2025].

Existem diversas outras métricas que podem ser utilizadas, ainda assim, o objetivo de cada métrica busca fornecer uma medida quantificável que permite avaliar um aspecto específico da performance das BCIs dado um objetivo final. A Tabela 5 apresenta essas métricas organizadas em três colunas: a primeira indica o nome da métrica, a segunda descreve a forma como ela é calculada ou definida matematicamente, e a terceira aponta sua aplicação prática no contexto da avaliação de sistemas BCI.

Tabela 5 – Principais métricas utilizadas na avaliação de sistemas BCI

Métrica	Cálculo	Aplicação
Acurácia	$\text{Acc} = \frac{TP + TN}{TP + FN + TN + FP}$	Avalia o quão bem o sistema de BCI consegue classificar a atividade mental do sujeito analisado para determinado comando
Kappa	$\kappa = \frac{p_o - p_e}{1 - p_e}$	Avalia o desempenho de um classificador, pois mede a concordância entre dois classificadores, corrigindo a concordância que poderia ocorrer por acaso
Erro quadrático médio (RMSE)	$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	Quantificar a diferença média entre valores preditos e valores reais de uma BCI
WD-score (<i>Window-Delay Score</i>)	$WDs = \arg \max_t (\kappa(t))$	Avalia o desempenho levando em conta janelas temporais e atrasos de resposta
Utilidade (<i>Utility Metric</i>)	$U = E \left[\lim_{T \rightarrow \infty} \frac{\int_0^T b(t) dt}{T} \right]$	Diz quão útil é a BCI para um sujeito em questão, considerando o que ela consegue entregar de correto em média por segundo, no longo prazo.
Integração	$\text{Int} = \int_{t_0}^{t_1} \kappa(t) dt$	Propõem representar o comportamento médio da BCI ao longo do tempo, ou seja mede a qualidade da concordância durante um intervalo de tempo
Oscilação	$\text{Osc} = \int_{t_0}^{t_1} \left \frac{d\kappa(t)}{dt} \right dt$	Avalia a consistência das respostas ao longo do tempo, ou seja, mede o total da variação entre as concordancias num intervalo de tempo

Na equação da acurácia, aparecem quatro siglas que representam os tipos de acertos e erros do classificador. A sigla TP significa “verdadeiro positivo” e se refere aos casos em que o sistema acertou ao dizer que a classe era positiva. Já TN é o “verdadeiro negativo”, quando o sistema acertou ao dizer que era classe negativa. Por outro lado, FP representa os “falsos positivos”, ou seja, erros em que o sistema classificou como positivo algo que era negativo. E FN são os “falsos negativos”, quando o sistema classificou como negativo algo que, na verdade, era positivo.

Na equação do Kappa, a letra p_o representa a proporção de acertos reais do sistema, ou seja, o quanto ele acertou de fato. Já p_e indica o quanto se esperaria que o sistema acertasse *por acaso*, considerando as distribuições das classes. Desta forma, temos o valor de Kappa variando de -1 à 1, onde 1 significa alta concordância, 0 concordância ao acaso e -1 uma concordância pior que o acaso.

No erro quadrático médio (RMSE), y_i indica o valor real de uma determinada amostra, enquanto $\hat{y}_i$ representa o valor previsto pelo modelo para essa mesma amostra. O índice i serve apenas para indicar que estamos lidando com várias amostras, uma por uma. Já o n indica a quantidade total de amostras.

Na métrica WD-score, usamos a letra $\kappa(t)$ para representar o valor da métrica

Kappa no instante de tempo t .

Na métrica de utilidade, a letra U representa a utilidade média da BCI no longo prazo. A função $b(t)$ indica o benefício que a BCI traz em cada instante de tempo t , por exemplo, classificações corretas ou ações úteis. O tempo total considerado é T , e o símbolo $E[\cdot]$ representa o valor esperado, que significa uma média ao longo de várias tentativas ou simulações.

Na equação de integração, a letra $\kappa(t)$ novamente representa o valor da métrica Kappa ao longo do tempo, e o intervalo $[t_0, t_1]$ indica o período de tempo considerado para o cálculo.

Por fim, na equação de oscilação, temos novamente a Kappa variando com o tempo, mas agora olhamos para a sua *derivada*, representada por $\frac{d\kappa(t)}{dt}$, que mostra o quanto a Kappa está mudando a cada instante.

Além das métricas apresentadas, também é possível avaliar o desempenho de sistemas BCI por meio da construção de um perfil de desempenho (*performance profile*) [Audet et al. 2021]. O *Performance Profile* (PP) é uma função de distribuição acumulada que avalia o desempenho relativo de diferentes algoritmos sobre um conjunto de problemas [Dolan e Moré 2002]. Ele mostra a robustez e a eficiência relativa dos métodos testados em diferentes tarefas. A função é definida da seguinte forma:

$$\rho_s(\tau) = \frac{1}{n_p} \cdot |p \in \mathcal{P} : r_{p,s} \leq \tau| \quad (6.1)$$

Nessa equação, $\rho_s(\tau)$ representa a proporção de problemas resolvidos pelo método $s \in \mathcal{S}$ com desempenho relativo menor ou igual a τ , onde τ é o fator de tolerância que representa o quão próximo do melhor desempenho um método pode estar para ser considerado competitivo. O termo n_p representa o número total de problemas no conjunto $\mathcal{P}$ onde $\mathcal{P}$ é o conjunto de todos os problemas avaliados. Por fim, $r_{p,s}$ é razão de desempenho do método s no problema p . O termo $r_{p,s}$ é encontrado da seguinte maneira:

$$r_{p,s} = \frac{t_{p,s}}{\min t_{p,s'} : s' \in \mathcal{S}} \quad (6.2)$$

onde $t_{p,s}$ é tempo (ou outra medida de custo, como erro ou distância) que o método s leva para resolver o problema p e o termo $\mathcal{S}$ representa conjunto de todos os métodos considerados.

O gráfico gerado pela relação $\rho_s(\tau)$ (eixo y) por τ (eixo x) é o que é conhecido por Performance Profile. Quanto mais rapidamente a curva sobe, melhor o método. Já a altura final da curva indica a fração de problemas que ele conseguiu resolver.

7 ANÁLISE PROPOSTA

A maioria dos estudos em BCI ainda se limita ao uso tradicional de métricas pontuais, focadas especialmente no desempenho da interface, como é o caso da acurácia média obtida em um ponto fixo dos *trials*. Essa abordagem, embora amplamente utilizada na literatura [Souza 2025], tende a favorecer determinados métodos em detrimento de outros, comprometendo a generalização dos resultados [Maurício et al. 2024]. Métricas como WD-score surgiram com o objetivo de suprir essa análise temporal dos resultados. Além disso, na literatura é visto que diferentes tamanhos e posicionamento de janelamento dos dados interferem diretamente na qualidade dos resultados obtidos [Miladinović et al. 2024].

O janelamento, portanto, se apresenta como um aspecto fundamental nas análises BCI. Na literatura é visto que janelas temporais maiores tendem a produzir melhores resultados em termos de acurácia, embora isso ocorra às custas da responsividade do sistema [Miladinović et al. 2024]. Além disso, o posicionamento dessas janelas ao longo do tempo tem demonstrado influência direta sobre o desempenho, destacando a necessidade de se considerar não somente o tamanho, mas também a localização temporal da janela [Maurício et al. 2024].

Dado que grande parte das abordagens ainda se baseia em pontos fixos de análise, torna-se importante evidenciar a necessidade do desenvolvimento de BCIs que não apenas otimizem o desempenho pontual, mas que também apresentem estabilidade ao longo do tempo. Identificar em que momento ocorrem as melhores respostas é estratégico, pois permite o uso de posições de janela específicas para maximizar os resultados. Além disso, técnicas que visem reduzir os resultados do WD-score permitiriam cada vez mais a criação de BCIs mais eficazes [Souza et al. 2023].

Diante disso, o objetivo central deste trabalho de conclusão de curso é investigar a influência de diferentes tamanhos e posicionamentos de janelas temporais, buscando compreender como essas configurações afetam o desempenho dos métodos. Adicionalmente, será explorado o impacto do posicionamento de várias janelas temporais diferentes ao mesmo tempo, analisando se esse recurso pode contribuir para a estabilidade do sinal ao longo do tempo. Além disso, será realizada uma análise para observar as respostas no ponto de 2,5 segundos após o início dos *trials*, considerando a relevância desse ponto no contexto das tarefas motoras analisadas [Malan e Sharma 2021, Souza et al. 2023, Maurício et al. 2024].

Desta forma as métricas selecionadas para esta análise são a Integração, Oscilação, WD-score e o PP. Elas foram escolhidas por permitirem uma avaliação não apenas da acurácia pontual, mas também da estabilidade, variabilidade e do desempenho relativo dos comportamentos dos métodos ao longo do tempo, assim como proposto no Capítulo 7.

A experimentação foi realizada em cima dos dados dos 3 conjuntos de dados

apresentados no Capítulo 4, o BCICIV2a, o BCICIV2b e o CBCIC. Para a realização dos experimentos, serão utilizados 3 métodos principais abordados no Capítulo 5: o CSP, que utiliza extração de características por LogPower e classificação por NBPW; o FBCSP, que utiliza o MIBIF e LDA; e a EEGNet. Os experimentos foram conduzidos utilizando validação cruzada com 5 dobras. As análises com diferentes janelamentos foram divididas em três categorias:

- Janelamento com tamanho variável: utilização de janelas com durações de 0,5 a 1,0 segundos, 0,5 a 1,5 segundos, 0,5 a 2,0 segundos e 0,5 a 2,5 segundos para o treinamento dos métodos, possibilitando avaliar o impacto do aumento da duração da janela na eficácia da análise;
- Janelamento com posicionamento variável: uso de janelas deslocadas no tempo, como 0,0 a 2,0 segundos, 0,5 a 2,5 segundos, 1,0 a 3,0 segundos, 1,5 a 3,5 segundos e 2,0 a 4,0 segundos para o treinamento dos métodos, permitindo investigar os efeitos da posição temporal da janela sobre a eficiência;
- Aumento de dados com janelamento deslizante: aplicação de múltiplas janelas fixas de 2,0 segundos, deslocadas progressivamente (por exemplo: 0,0 a 2,0 segundos, 0,1 a 2,1 segundos, ..., até 2,0 a 4,0 segundos) para o treinamento dos métodos, a fim de analisar como isso influencia a estabilidade dos resultados.

8 RESULTADOS

Esse capítulo foi reservado para apresentar todos os resultados obtidos, juntamente da análise deles. Os resultados foram coletados e separados em três seções diferentes de apresentação e uma de discussão dos resultados. A Seção 8.1 apresenta os resultados das métricas para cada janelamento dispostos em formato de tabela. A Seção 8.2 consta com gráficos que apresentam a variação do Kappa no tempo da janela. A Seção 8.3 consta com gráficos que apresentam os PPs dos diferentes janelamentos. Por fim, a Seção 8.4 é a seção onde serão discutidos os resultados apresentados.

8.1 TABELAS DE DESEMPENHO

As Tabelas 6 a 11 apresentam os resultados obtidos para os diferentes experimentos conduzidos com três métodos de classificação (CSP, FBCSP e EEGNet), avaliados sobre distintos conjuntos de dados (BCICIV2a, BCICIV2b e CBCIC). As métricas foram calculadas em diferentes configurações de janelas temporais, tanto em termos de tamanho quanto de posição ao longo dos *trials*.

Cada célula das tabelas apresenta os resultados das métricas avaliadas, variando conforme o tipo de métrica. Nas Tabelas 6, 7, 9 e 10, cada célula exibe um par no formato (t, métrica), onde t representa o tempo de maior eficácia em segundos, e o segundo parâmetro corresponde ao valor da métrica considerada (WD-score ou Kappa). Já nas Tabelas 8 e 11, os pares representam (Integração, Oscilação).

As Tabelas 6, 7 e 8 referem-se às variações no tamanho da janela de análise, mantendo-se fixo o seu início em 0,5 segundos. Já as Tabelas 9, 10 e 11 apresentam diferentes posições da janela, mantendo o tamanho constante em 2,0 segundos ou utilizando múltiplas janelas de tamanho 2,0 segundos em posições diferentes ao mesmo tempo (linha DA).

Os melhores desempenhos dentro de cada grupo estão destacados em negrito, permitindo uma comparação mais clara entre os métodos avaliados. Foram selecionados os melhores resultados de método por conjunto de dados, logo cada tabela terá nove melhores desempenhos apresentados, caso não existam resultados iguais.

Ao analisar os dados da Tabela 6, observa-se que a janela (0,5; 2,5) foi a que mais frequentemente proporcionou os melhores resultados entre os métodos e conjuntos de dados. Essa janela se destacou ao gerar os melhores desempenhos para CSP, FBCSP e EEGNet no conjunto de dados CBCIC, além de apresentar os melhores valores para CSP e FBCSP nos conjuntos de dados BCICIV2a e BCICIV2b.

Em termos de variação, o conjunto de dados CBCIC apresentou a maior oscilação entre os resultados da métrica, com uma média de variação entre o melhor e o pior

desempenho de 0,2106, sendo a maior contribuição dessa instabilidade proveniente do FBCSP, com uma diferença de 0,2284.

O pior desempenho geral foi observada no conjunto de dados BCICIV2b, que registrou os menores valores de métrica, especialmente com a EEGNet, que se destacou negativamente. Considerando o conjunto de janelas analisado, o FBCSP foi o algoritmo com melhor desempenho, enquanto a EEGNet apresentou o pior.

Quanto à consistência temporal das métricas, nota-se um padrão de concentração dos melhores resultados em torno da faixa de 2,5 a 3,0 segundos, embora o conjunto de dados CBCIC apresente maior variação temporal absoluta, com valores entre 0,7 e 3,7 segundos após a dica. Ainda assim, é evidente a tendência dos conjuntos de dados em favorecer janelas de tempo mais longas para obtenção de melhores resultados.

Por fim, analisando o desempenho geral, o CSP apresentou o desempenho mais estável dos três métodos, não importando o tamanho do janelamento nem o conjunto de dados escolhido. O FBCSP apresentou os melhores resultados para os conjuntos de dados BCICIV2a e BCICIV2b, enquanto a EEGNet apresentou o melhor resultado para o conjunto de dados CBCIC.

Tabela 6 – WD-score para diferentes tamanhos de janelas e diferentes conjuntos de dados.

Fonte	Janela	CSP	FBCSP	EEGNet
BCICIV2a	(0,5; 1,0)	(2,6000; 0,4360)	(2,7000; 0,2693)	(2,6000; 0,1204)
BCICIV2a	(0,5; 1,5)	(2,5000; 0,5278)	(2,5000; 0,3835)	(2,5000; 0,2091)
BCICIV2a	(0,5; 2,0)	(2,6000; 0,5417)	(2,6000; 0,5039)	(2,5000; 0,3056)
BCICIV2a	(0,5; 2,5)	(2,4000; 0,5509)	(2,5000; 0,5540)	(2,5000; 0,2600)
BCICIV2b	(0,5; 1,0)	(4,0000; 0,3104)	(4,1000; 0,2245)	(3,4000; 0,1831)
BCICIV2b	(0,5; 1,5)	(3,7000; 0,3574)	(3,7000; 0,3245)	(3,5000; 0,1862)
BCICIV2b	(0,5; 2,0)	(4,0000; 0,3798)	(3,7000; 0,3837)	(3,5000; 0,1782)
BCICIV2b	(0,5; 2,5)	(3,7000; 0,3853)	(3,6000; 0,4298)	(3,4000; 0,1844)
CBCIC	(0,5; 1,0)	(2,3000; 0,2583)	(3,9000; 0,2183)	(3,9000; 0,4533)
CBCIC	(0,5; 1,5)	(4,7000; 0,3367)	(1,7000; 0,2600)	(3,6000; 0,5983)
CBCIC	(0,5; 2,0)	(4,6000; 0,4050)	(3,7000; 0,3933)	(3,4000; 0,6333)
CBCIC	(0,5; 2,5)	(3,8000; 0,4350)	(4,0000; 0,4467)	(4,0000; 0,6800)

Analisando a Tabela 7, observa-se, assim como na Tabela 6, que a janela (0,5; 2,5) apresentou os melhores resultados para a maioria dos métodos nos três conjuntos de dados. Em relação à variação dos valores de Kappa, o conjunto de dados CBCIC foi o que apresentou maior amplitude entre os piores e melhores desempenhos, especialmente para o método EEGNet. Nesse caso, os valores variaram de 0,4100, na menor janela, até 0,6717, na maior, representando um ganho superior a 0,26, um salto expressivo na qualidade do modelo com o aumento do tempo de janela. No conjunto de dados BCICIV2a, os ganhos também foram significativos, com destaque novamente para a EEGNet, que evoluiu de 0,1111 para 0,3056. Já o conjunto de dados BCICIV2b apresentou menor variação geral, embora também tenha mostrado crescimento nos valores de Kappa com o aumento da

janela, especialmente para os métodos CSP e FBCSP. Esse comportamento reforça a tendência observada na Tabela 6.

Além disso, é relevante destacar que oito dos dados da Tabela 7 também estão presentes na Tabela 6. Dentre esses oito, seis correspondem ao conjunto de dados BCICIV2a, enquanto a EEGNet é o método com o maior número de coincidências, totalizando cinco. Esses dados sugerem uma forte tendência do conjunto de dados BCICIV2a e do método EEGNet a alcançarem seus melhores desempenhos em janelas de 2,5 segundos após a dica.

Tabela 7 – Kappa em 2,5 segundos para diferentes tamanhos de janelas e diferentes conjunto de dados.

Fonte	Janela	CSP	FBCSP	EEGNet
BCICIV2a	(0,5; 1,0)	(2,5000; 0,4306)	(2,5000; 0,2677)	(2,5000; 0,1111)
BCICIV2a	(0,5; 1,5)	(2,5000; 0,5278)	(2,5000; 0,3835)	(2,5000; 0,2091)
BCICIV2a	(0,5; 2,0)	(2,5000; 0,5401)	(2,5000; 0,5015)	(2,5000; 0,3056)
BCICIV2a	(0,5; 2,5)	(2,5000; 0,5378)	(2,5000; 0,5540)	(2,5000; 0,2600)
BCICIV2b	(0,5; 1,0)	(3,5000; 0,2488)	(3,5000; 0,1755)	(3,5000; 0,1807)
BCICIV2b	(0,5; 1,5)	(3,5000; 0,3356)	(3,5000; 0,3071)	(3,5000; 0,1862)
BCICIV2b	(0,5; 2,0)	(3,5000; 0,3684)	(3,5000; 0,3610)	(3,5000; 0,1782)
BCICIV2b	(0,5; 2,5)	(3,5000; 0,3837)	(3,5000; 0,4181)	(3,5000; 0,1718)
CBCIC	(0,5; 1,0)	(3,5000; 0,2133)	(3,5000; 0,1367)	(3,5000; 0,4100)
CBCIC	(0,5; 1,5)	(3,5000; 0,2783)	(3,5000; 0,2533)	(3,5000; 0,5883)
CBCIC	(0,5; 2,0)	(3,5000; 0,2967)	(3,5000; 0,3567)	(3,5000; 0,6300)
CBCIC	(0,5; 2,5)	(3,5000; 0,3950)	(3,5000; 0,4250)	(3,5000; 0,6717)

Além das observações iniciais, é possível aprofundar a análise da Tabela 8 destacando outros padrões importantes. Primeiramente, nota-se uma tendência geral de crescimento nos valores da métrica de integração (primeiro valor de cada par) à medida que a janela aumenta, o que indica uma acumulação mais consistente de evidências temporais com janelas maiores. Essa tendência é evidente especialmente para os métodos CSP e FBCSP em todos os conjuntos de dados, sugerindo que esses métodos se beneficiam da presença de mais informações temporais para consolidar suas decisões.

No que diz respeito à oscilação (segundo valor de cada par), há uma diminuição progressiva nos valores conforme o tamanho da janela aumenta, o que implica uma maior estabilidade nas classificações. Isso é particularmente notável no conjunto de dados BCICIV2a, onde a oscilação cai de forma mais acentuada tanto para o CSP quanto para o FBCSP. Já no conjunto de dados CBCIC, embora o padrão de oscilação decrescente também se mantenha, os valores absolutos são mais altos, indicando que, apesar da melhora com janelas maiores, o nível de flutuação ainda é mais elevado em comparação com os demais conjuntos de dados.

Quanto aos métodos, é perceptível que o método EEGNet possui a menor qualidade de concordância entre todos os métodos apresentados. Já o CSP possui a maior qualidade de concordância e estabilidade de resultados entre os métodos apresentados quando

analisamos a janela de maior tamanho. Por fim, é possível verificar uma correlação entre as Tabelas 6,7 e 8 que mostra tendência de resultados melhores, com uma maior qualidade e estabilidades para janelas maiores, ou seja, com tamanho de 2 segundos.

Tabela 8 – Integração e Oscilação para diferentes tamanhos de janelas e diferentes conjuntos de dados.

Fonte	Janela	CSP	FBCSP	EEGNet
BCICIV2a	(0,5; 1,0)	(0,7453; 0,8542)	(0,4568; 0,9877)	(0,0921; 0,5606)
BCICIV2a	(0,5; 1,5)	(1,0415; 0,8221)	(0,6893; 0,8831)	(0,1981; 0,5432)
BCICIV2a	(0,5; 2,0)	(1,1887; 0,7905)	(1,0318; 0,8569)	(0,3396; 0,6948)
BCICIV2a	(0,5; 2,5)	(1,3220; 0,7411)	(1,2211; 0,8326)	(0,3601; 0,5355)
BCICIV2b	(0,5; 1,0)	(0,4732; 0,6287)	(0,3465; 0,6385)	(0,0591; 0,5561)
BCICIV2b	(0,5; 1,5)	(0,6487; 0,5371)	(0,5500; 0,5486)	(0,0981; 0,5853)
BCICIV2b	(0,5; 2,0)	(0,8048; 0,4963)	(0,7358; 0,5719)	(0,1028; 0,4644)
BCICIV2b	(0,5; 2,5)	(0,9403; 0,5051)	(0,9330; 0,5897)	(0,1558; 0,4071)
CBCIC	(0,5; 1,0)	(1,0303; 1,1083)	(0,7949; 1,2967)	(1,9034; 0,9992)
CBCIC	(0,5; 1,5)	(1,4640; 1,2400)	(1,0433; 1,3017)	(2,6705; 0,7375)
CBCIC	(0,5; 2,0)	(1,6021; 1,0675)	(1,5476; 0,8425)	(2,8343; 0,7892)
CBCIC	(0,5; 2,5)	(1,7568; 0,7825)	(1,7794; 0,8633)	(3,1282; 0,6367)

A partir dos dados da Tabela 9, observa-se que a janela DA é, de forma geral, a que mais frequentemente aparece associada aos melhores resultados entre os diferentes métodos e conjuntos de dados. Especificamente, ela apresenta os melhores desempenhos para o método FBCSP em todos os três conjuntos de dados analisados, além de também proporcionar o melhor resultado para o CSP no conjunto de dados BCICIV2b.

Quanto à variação dos resultados, nota-se que ela depende significativamente tanto do conjunto de dados quanto do método utilizado. O conjunto de dados BCICIV2a apresenta a maior oscilação nas métricas, especialmente quando combinado com o método EEGNet, onde a diferença entre o melhor e o pior desempenho ultrapassa 0,35 na escala da métrica. O conjunto de dados BCICIV2b também mostra uma variação considerável para o EEGNet, embora em menor grau do que o BCICIV2a. Por outro lado, o conjunto de dados CBCIC apresenta resultados mais consistentes, principalmente para o EEGNet, com variações mais discretas em comparação aos demais.

No que diz respeito aos piores desempenhos absolutos, o conjunto de dados BCICIV2b se destaca registrando os valores mais baixos de performance entre os métodos avaliados. Entre esses métodos, o EEGNet demonstrou o pior desempenho geral, evidenciado tanto pelos menores valores absolutos observados, como 0,0509 no conjunto de dados BCICIV2b, quanto pela alta variabilidade dos resultados ao longo das diferentes janelas e conjuntos de dados.

Em relação ao tempo de detecção dos melhores desempenhos, embora não haja uma constância absoluta, observa-se uma leve tendência à concentração de bons resultados em uma faixa entre 2,5 e 3,6 segundos após a dica.

Por fim, ao comparar os métodos, verifica-se um padrão de preferência em relação às janelas temporais: o CSP tende a apresentar melhor desempenho com janelas centrais; o EEGNet, com janelas iniciais; e o FBCSP, com a estratégia de combinação de múltiplas janelas simultâneas, como ocorre na janela DA.

Tabela 9 – WD-score para diferentes posições de janelas e diferentes conjuntos de dados.

Fonte	Janela	CSP	FBCSP	EEGNet
BCICIV2a	(0,0; 2,0)	(2,2000; 0,5262)	(2,1000; 0,4630)	(2,0000; 0,4506)
BCICIV2a	(0,5; 2,5)	(2,4000; 0,5509)	(2,5000; 0,5540)	(2,5000; 0,2600)
BCICIV2a	(1,0; 3,0)	(2,5000; 0,5478)	(2,5000; 0,5401)	(2,9000; 0,2215)
BCICIV2a	(1,5; 3,5)	(2,9000; 0,5015)	(2,6000; 0,4823)	(3,0000; 0,1073)
BCICIV2a	(2,0; 4,0)	(3,0000; 0,4954)	(2,9000; 0,4236)	(3,4000; 0,0965)
BCICIV2a	DA	(2,5000; 0,5363)	(2,4000; 0,5694)	(2,6000; 0,1420)
BCICIV2b	(0,0; 2,0)	(3,6000; 0,3844)	(3,7000; 0,4067)	(3,0000; 0,3150)
BCICIV2b	(0,5; 2,5)	(3,7000; 0,3853)	(3,6000; 0,4298)	(3,4000; 0,1844)
BCICIV2b	(1,0; 3,0)	(3,5000; 0,3887)	(3,8000; 0,4104)	(4,1000; 0,0847)
BCICIV2b	(1,5; 3,5)	(3,7000; 0,3810)	(3,9000; 0,4040)	(4,0000; 0,0985)
BCICIV2b	(2,0; 4,0)	(4,0000; 0,3672)	(3,7000; 0,4006)	(4,7000; 0,0509)
BCICIV2b	DA	(4,1000; 0,3887)	(3,6000; 0,4316)	(3,4000; 0,1448)
CBCIC	(0,0; 2,0)	(3,6000; 0,3833)	(3,9000; 0,4067)	(3,2000; 0,6483)
CBCIC	(0,5; 2,5)	(3,8000; 0,4350)	(4,0000; 0,4467)	(4,0000; 0,6800)
CBCIC	(1,0; 3,0)	(4,5000; 0,4717)	(4,6000; 0,4667)	(4,1000; 0,6550)
CBCIC	(1,5; 3,5)	(4,6000; 0,4900)	(4,2000; 0,4783)	(4,5000; 0,6333)
CBCIC	(2,0; 4,0)	(4,5000; 0,4767)	(4,6000; 0,4750)	(4,6000; 0,6467)
CBCIC	DA	(4,5000; 0,4717)	(4,3000; 0,4883)	(4,1000; 0,6650)

Analisando os dados da Tabela 10, é possível perceber uma tendência clara entre os métodos utilizados, a qual se mantém ao longo dos diferentes conjuntos de dados. O CSP apresentou seus melhores resultados na janela (1,0; 3,0), enquanto a EEGNet obteve seus melhores desempenhos na janela de (0,5; 2,5). Já o FBCSP alcançou os melhores resultados com a janela DA.

Em relação à performance dos métodos, observa-se que a EEGNet se destacou somente no conjunto de dados CBCIC, enquanto nos demais apresentou os piores resultados para todas as janelas, chegando a um comportamento quase aleatório na janela (2,0; 4,0) no conjunto de dados BCICIV2b.

Um padrão que se repete entre a Tabela 9 e a Tabela 10 é a alta sensibilidade da EEGNet em relação ao posicionamento da janela, com preferência por janelas iniciadas o mais próximo possível da dica. Por fim, nota-se também que o conjunto de dados BCICIV2b apresenta, consistentemente, os piores desempenhos entre os três avaliados em ambas as tabelas.

Tabela 10 – Kappa em 2,5 segundos para diferentes posições de janelas e diferentes conjuntos de dados.

Fonte	Janela	CSP	FBCSP	EEGNet
BCICIV2a	(0,0; 2,0)	(2,5000; 0,5008)	(2,5000; 0,4313)	(2,5000; 0,1505)
BCICIV2a	(0,5; 2,5)	(2,5000; 0,5378)	(2,5000; 0,5540)	(2,5000; 0,2600)
BCICIV2a	(1,0; 3,0)	(2,5000; 0,5478)	(2,5000; 0,5401)	(2,5000; 0,1590)
BCICIV2a	(1,5; 3,5)	(2,5000; 0,4846)	(2,5000; 0,4784)	(2,5000; 0,0486)
BCICIV2a	(2,0; 4,0)	(2,5000; 0,4630)	(2,5000; 0,4182)	(2,5000; 0,0463)
BCICIV2a	DA	(2,5000; 0,5363)	(2,5000; 0,5679)	(2,5000; 0,1319)
BCICIV2b	(0,0; 2,0)	(3,5000; 0,3807)	(3,5000; 0,4040)	(3,5000; 0,0586)
BCICIV2b	(0,5; 2,5)	(3,5000; 0,3837)	(3,5000; 0,4181)	(3,5000; 0,1718)
BCICIV2b	(1,0; 3,0)	(3,5000; 0,3887)	(3,5000; 0,4064)	(3,5000; 0,0525)
BCICIV2b	(1,5; 3,5)	(3,5000; 0,3767)	(3,5000; 0,4025)	(3,5000; 0,0365)
BCICIV2b	(2,0; 4,0)	(3,5000; 0,3644)	(3,5000; 0,3979)	(3,5000; 0,0009)
BCICIV2b	DA	(3,5000; 0,3767)	(3,5000; 0,4252)	(3,5000; 0,1417)
CBCIC	(0,0; 2,0)	(3,5000; 0,3783)	(3,5000; 0,3683)	(3,5000; 0,6433)
CBCIC	(0,5; 2,5)	(3,5000; 0,3950)	(3,5000; 0,4250)	(3,5000; 0,6717)
CBCIC	(1,0; 3,0)	(3,5000; 0,4433)	(3,5000; 0,3650)	(3,5000; 0,6183)
CBCIC	(1,5; 3,5)	(3,5000; 0,3850)	(3,5000; 0,3483)	(3,5000; 0,6050)
CBCIC	(2,0; 4,0)	(3,5000; 0,3750)	(3,5000; 0,2850)	(3,5000; 0,6000)
CBCIC	DA	(3,5000; 0,4433)	(3,5000; 0,4417)	(3,5000; 0,6500)

A Tabela 11 evidencia que, de forma consistente entre os métodos e conjuntos de dados, a janela denominada como “DA” resultou em valores superiores de desempenho ao combinar qualidade e estabilidade. Observa-se ainda uma tendência clara de que, à medida que a janela de análise é deslocada para o final do intervalo do *trial*, há uma queda progressiva na qualidade dos resultados, refletida por métricas mais baixas. No entanto, essa perda vem acompanhada de uma maior estabilidade, com menos variação entre os desempenhos.

O método EEGNet apresentou seu melhor desempenho geral no conjunto de dados CBCIC, tanto em termos de integração quanto oscilação, o que reforça sua capacidade de capturar padrões temporais mais complexos presentes nesse conjunto de dados. Por outro lado, o CSP se destacou por manter uma constância maior na qualidade dos resultados ao longo das diferentes posições de janela, sendo também o método que apresentou menor sensibilidade às mudanças de posição, demonstrando maior estabilidade.

Esse comportamento geral está em consonância com o que foi observado nas Tabelas 9 e 10, além da própria Tabela 11, reforçando a ideia de que os métodos tendem a preferir janelas localizadas mais próximas da dica. Entretanto, essas janelas iniciais, embora frequentemente associadas a melhores desempenhos, revelam também uma maior variabilidade, o que pode comprometer a robustez dos modelos. Por fim, é importante destacar que o método FBCSP foi o que mais frequentemente teve a janela DA associada aos seus melhores resultados.

Tabela 11 – Integração e Oscilação para diferentes posições de janelas e diferentes conjuntos de dados.

Fonte	Janela	CSP	FBCSP	EEGNet
BCICIV2a	(0,0; 2,0)	(1,3760; 0,6651)	(1,1240; 0,7701)	(0,3331; 1,1011)
BCICIV2a	(0,5; 2,5)	(1,3220; 0,7411)	(1,2211; 0,8326)	(0,3601; 0,5355)
BCICIV2a	(1,0; 3,0)	(1,3184; 0,7018)	(1,1903; 0,7589)	(0,2924; 0,5004)
BCICIV2a	(1,5; 3,5)	(1,2331; 0,6022)	(1,0622; 0,7238)	(0,1449; 0,3171)
BCICIV2a	(2,0; 4,0)	(1,1880; 0,6771)	(0,9606; 0,6844)	(0,1608; 0,3272)
BCICIV2a	DA	(1,3378; 0,6910)	(1,3178; 0,7917)	(0,2364; 0,3129)
BCICIV2b	(0,0; 2,0)	(0,9104; 0,5153)	(0,8767; 0,6002)	(0,2122; 0,7629)
BCICIV2b	(0,5; 2,5)	(0,9403; 0,5051)	(0,9330; 0,5897)	(0,1558; 0,4071)
BCICIV2b	(1,0; 3,0)	(0,9448; 0,5095)	(0,9003; 0,5778)	(0,1237; 0,1793)
BCICIV2b	(1,5; 3,5)	(0,9092; 0,5021)	(0,9004; 0,5695)	(0,1333; 0,2035)
BCICIV2b	(2,0; 4,0)	(0,9003; 0,4741)	(0,8872; 0,5537)	(0,0752; 0,1653)
BCICIV2b	DA	(0,9475; 0,5387)	(0,9451; 0,5925)	(0,2777; 0,2457)
CBCIC	(0,0; 2,0)	(1,6760; 0,8967)	(1,6428; 0,8683)	(2,9935; 0,6733)
CBCIC	(0,5; 2,5)	(1,7568; 0,7825)	(1,7794; 0,8633)	(3,1282; 0,6367)
CBCIC	(1,0; 3,0)	(1,8250; 0,7808)	(1,7974; 0,8883)	(3,0150; 0,6550)
CBCIC	(1,5; 3,5)	(1,8022; 0,6900)	(1,8131; 0,8542)	(2,9579; 0,5867)
CBCIC	(2,0; 4,0)	(1,7688; 0,8450)	(1,7565; 0,8700)	(2,9437; 0,5842)
CBCIC	DA	(1,9095; 0,8267)	(2,0787; 0,6925)	(3,1464, 0,4933)

8.2 ANÁLISE DO KAPPA NO TEMPO

Foram produzidos nove gráficos com o objetivo de analisar a evolução do coeficiente Kappa ao longo do tempo para os diferentes janelamentos testados. Cada gráfico corresponde a uma combinação entre método (CSP, FBCSP e EEGNet) e conjunto de dados (BCICIV2a, BCICIV2b e CBCIC), totalizando um gráfico por par método e conjunto de dados. Dessa forma são geradas as Figuras de 9-a até 11-c, resultando em nove gráficos. Os resultados apresentados refletem o desempenho médio ao longo do tempo para todas as janelas avaliadas, possibilitando uma análise mais ampla da estabilidade e da eficácia dos métodos ao longo do *trial*.

Para facilitar a interpretação e a comparação entre os métodos, os gráficos foram organizados em três figuras, resultando em uma para cada conjunto de dados. A Figura 9 apresenta os resultados obtidos com o conjunto BCICIV2a, enquanto as Figuras 10 e 11 exibem os resultados para os conjuntos BCICIV2b e CBCIC, respectivamente. Cada figura agrega os três gráficos correspondentes aos diferentes métodos, permitindo a comparação direta entre eles em termos de variação temporal da métrica Kappa. Essa visualização complementa os dados das tabelas apresentados na Seção 8.1, oferecendo uma perspectiva visual mais clara sobre a dinâmica do desempenho dos métodos ao longo do tempo.

Observando a Figura 9-a, o gráfico referente ao CSP, observa-se uma tendência crescente nos valores de Kappa até aproximadamente 2,5 segundos, indicando um aumento progressivo da capacidade discriminativa dos sinais à medida que mais informações são


acumuladas. As curvas se estabilizam ou decaem levemente após esse ponto. As janelas que terminam em 2,5 ou 3,0 segundos apresentam os melhores desempenhos, com destaque para a janela (0,5; 2,5), que consistentemente mantém valores altos de Kappa. A janela DA, que representa a integração de múltiplas janelas, apresenta resultados comparáveis aos da janela (0,5; 2,5) na faixa de tempo de 2,0 a 2,5 segundos, embora se torne ligeiramente inferior depois dessa faixa.

Na Figura 9-b, o gráfico referente ao FBCSP, há um padrão similar, com crescimento dos valores de Kappa até cerca de 2,5 segundos, seguido por uma leve queda ou estabilização. A janela (0,5; 2,5) novamente se destaca com valores máximos em torno de 0,55. No entanto, a janela DA apresenta desempenho superior após 2,0 segundos.


Na Figura 9-c, o gráfico referente à EEGNet, os padrões são mais variados e com maior oscilação, o que pode indicar maior sensibilidade do modelo às diferentes janelas. O melhor desempenho desse método foi encontrado na janela de (0,0; 2,0) no tempo 2,0 segundos. As demais janelas apresentam variações mais abruptas e valores inferiores, e a janela DA não supera os melhores janelamentos isolados; porém, apresentou resultado mais estável.

De forma geral, observa-se que todas as abordagens nesse conjunto de dados se beneficiam de janelas que terminam ao redor de 2,5 segundos após a dica. A janela DA tende a ser vantajosa para o FBCSP, mas menos impactante para CSP e EEGNet. Além disso, é possível perceber a melhora dos resultados proveniente do aumento do tamanho da janela e do posicionamento das janelas em (0,5; 2,5) e (1,0; 3,0).


Figura 9 – Kappa para os diferentes janelamentos no conjunto de dados BCICIV2a



(a) CSP



(b) FBCSP



(c) EEGNET

Fonte: Figura de autoria própria.

Analisando agora a Figura 10-a, o gráfico do método CSP, observa-se que todas as curvas seguem uma tendência de crescimento por volta de 2,5 segundos depois da dica,


com uma leve queda depois. As janelas (0,5; 2,5), (0,5; 2,0), (1,0; 3,0) e DA apresentam os melhores desempenhos, atingindo valores próximos de 0,4 de Kappa, indicando boa estabilidade entre diferentes configurações de janelas. A janela (0,5; 1,0) apresentou desempenho muito inferior, refletindo a insuficiência de informações temporais curtas.

Na Figura 10-b, o gráfico referente ao FBCSP, há novamente um crescimento consistente por volta de 2,5 segundos depois da dica, seguido de uma ligeira queda. Os melhores resultados, em torno de 0,42 de Kappa, são obtidos com as janelas DA e (1,0; 3,0). As janelas de tamanho inferiores a 2,0 segundos apresentaram os piores resultados para o método.


Já na Figura 10-c, o (c), referente à EEGNet, os valores de Kappa são visivelmente mais baixos, com picos em torno de 0,15 a 0,20. A curva da janela (0,0; 2,0) se destaca com um pico superior a 0,3 no instante 2,0 segundos depois da dica, embora com forte oscilação. A EEGNet foi a única que apresentou melhores resultados com a variação do tamanho de janela relativo a suas posições. A janela DA, apesar de mais estável entre todas as outras, não produziu os melhores resultados, obtendo valores inferiores a 0,15.

Em síntese, os resultados reforçam que os métodos CSP e FBCSP alcançam melhores desempenhos com janelas que abrangem até cerca de 2,5 à 3,0 segundos após o *trial*, sendo que o FBCSP continua se beneficiando da janela DA. O EEGNet mantém desempenho inferior e mais instável, ainda mantendo a tendência de melhores resultados cerca de 2,5 à 3,0 segundos após o *trial*, salvo a janela (0,0; 2,0) que se destacou em 2,0 segundos.


Figura 10 – Kappa para os diferentes janelamentos no conjunto de dados BCICIV2b



(a) CSP



(b) FBCSP



(c) EEGNET

Fonte: Figura de autoria própria.

Por fim, analisando agora a Figura 11-a, o gráfico referente ao método CSP, nota-se que as janelas (1,0; 3,0), (1,5; 3,5), (2,0; 4,0) e DA se destacam, alcançando valores de


Kappa superiores a 0,45. É perceptível, também, a melhora dos resultados à medida que se aumenta o tamanho da janela, com a janela mais curta, (0,5; 1,0), apresentando os piores resultados. De modo geral, o CSP demonstra ter os melhores resultados na faixa de 3,0 a 4,0 segundos depois da dica.

No caso da Figura 11-a, o gráfico do método FBCSP apresentou um comportamento é semelhante, com as janelas (1,0; 3,0), (1,5; 3,5), (2,0; 4,0) e a janela “DA” novamente figurando entre as melhores, alcançando valores de Kappa superiores a 0,45. A janela “DA” apresenta o melhor desempenho em relação às outras, além de uma estabilidade alta, indicando que o FBCSP se beneficia da combinação de múltiplas janelas ao processar diferentes segmentos do sinal. O tamanho da janela tornou-se um fator importante para a melhoria dos resultados, com janelas mais longas apresentando resultados superiores a janelas mais curtas. Além disso, o FBCSP também demonstra ter os melhores resultados na faixa de 3,0 a 4,0 segundos depois da dica.


Já na Figura 11-a, o gráfico referente a EEGNet, o padrão é mais claro: a janela “DA” se sobressai significativamente, atingindo valores de Kappa superiores a 0,65, os mais altos entre todos os métodos analisados. As janelas (1,0; 3,0) e (1,5; 3,5) também apresentam bom desempenho, demonstrando uma preferência pelo posicionamento de janela mais centralizado. Em contraste, fica clara a melhora à medida que se aumenta o tamanho da janela. Também é perceptível o fato de a EEGNet para esse conjunto de dados apresentar resultados altamente estáveis, ficando difícil definir com clareza uma faixa do *trial* com os melhores resultados.

De forma geral, foi possível perceber que o desempenho dos métodos é fortemente dependente da escolha do janelamento, sendo as janelas mais longas e intermediárias, (1,0; 3,0) e (1,5; 3,5), as mais eficazes. A janela “DA” se destaca especialmente no EEGNet e FBCSP, que se sobressaem em muito em relação aos demais, tanto em estabilidade quanto em relação a qualidade da solução ao longo do tempo. Além disso, os 3 gráficos apresentaram uma grande consistência quanto à qualidade de seus resultados, com a EEGNet se destacando também com a maior estabilidade.


Figura 11 – Kappa para os diferentes janelamentos no conjunto de dados CBCIC



(a) CSP



(b) FBCSP



(c) EEGNET

Fonte: Figura de autoria própria.

8.3 GRÁFICOS DOS PERFIS DE DESEMPENHO

Assim como na Seção 8.2, foram produzidos nove gráficos com o objetivo de analisar o PP do uso de cada janelamento. Cada gráfico corresponde a uma combinação entre método (CSP, FBCSP e EEGNet) e conjunto de dados (BCICIV2a, BCICIV2b e CBCIC), totalizando um gráfico por par método e conjunto de dados.

Para facilitar a interpretação e a comparação entre os métodos, os gráficos foram organizados em três figuras, resultando em uma para cada método. A Figura 12 apresenta os resultados obtidos pelo método CSP, enquanto as Figuras 13 e 14 exibem os resultados para os métodos FBCSP e EEGNet, respectivamente. Cada figura agrega os três gráficos correspondentes aos diferentes conjuntos de dados. O objetivo desses gráficos é comparar o desempenho relativo de cada janela ao longo dos sujeitos, utilizando a métrica baseada na razão de desempenho τ . O eixo vertical indica a fração de sujeitos para os quais uma determinada janela apresenta desempenho até τ vezes pior que o melhor resultado obtido (quanto mais próxima de 1,0, melhor a cobertura). Já o eixo horizontal representa os valores de τ .

Começando a analisar pela Figura 12, no primeiro gráfico, correspondente ao conjunto de dados BCICIV2a, observa-se que as janelas de (0,5; 1,5), (0,5; 2,0) e (1,0; 3,0) apresentam desempenho superior. Suas curvas sobem rapidamente e alcançam o valor máximo da fração de sujeitos resolvidos com valores de τ baixos, evidenciando que essas janelas obtêm desempenho próximo ao ótimo para a maioria dos sujeitos. As piores janelas são a (0,5; 1,0), (2,0; 4,0) e a DA. Por fim, tem-se que o pior desempenho se encontra menor que 3,5 vezes do melhor, enquanto todos os outros se concentram em menos de 2,5 vezes.


No segundo gráfico, referente ao conjunto de dados BCICIV2b, as janelas de (0,5; 2,0), (1,0; 3,0) e (1,5; 3,5) desempenham melhor que as demais, com curvas que crescem de maneira acelerada e alcançam a totalidade dos sujeitos com valores de τ ainda menores do que no caso anterior, sugerindo um desempenho mais homogêneo entre os sujeitos. A janela (0,5; 1,0), apresenta o pior desempenho, com curva mais lenta e cobertura parcial dos sujeitos, mesmo com valores altos de τ , evidenciando menor eficácia desse posicionamento no processo de extração de características.

No terceiro gráfico, correspondente ao conjunto CBCIC, confirma-se novamente a superioridade das janelas (0,5; 2,0) e (1,0; 3,0). A janela (2,0; 4,0), em contrapartida, dos casos anteriores, apresenta bom desempenho nesse conjunto. Ainda assim, a janela de (0,5; 1,0) retorna a apresentar um desempenho inferior às outras.


Em resumo, as janelas (0,5; 2,0) e (1,0; 3,0) são as que mais frequentemente apresentam os melhores desempenhos para o método CSP, independentemente do conjunto de dados. Já janelas com início mais tardio, como a de (2,0; 4,0), e tamanhos menores, como

(0,5; 1,0), são sistematicamente menos eficazes, sendo superadas pelas demais em todos os cenários. Esses resultados indicam que há uma faixa temporal ideal para a extração de padrões espaciais discriminativos via CSP. Além disso, o conjunto de dados BCICIV2a apresentou o pior desempenho para os sujeitos, alcançando valores de τ próximos a 3,5.


Figura 12 – Performance Profile para o método CSP em diferentes janelamentos



(a) Conjunto de dados BCICIV2a



(b) Conjunto de dados BCICIV2b



(c) Conjunto de dados CBCIC

Fonte: Figura de autoria própria.

Partindo agora para a Figura 13, no primeiro gráfico, referente ao conjunto BCICIV2a, destaca-se a janela (0,5; 2,5), cuja curva é uma das que mais rapidamente atinge


o topo do gráfico. As janelas $(0,0; 2,0)$ e $(1,0; 3,0)$ também apresentam curvas com bom crescimento e alta cobertura de sujeitos. Por outro lado, a janela $(0,5; 1,0)$ mostra desempenho significativamente inferior, com crescimento lento e baixa fração de sujeitos resolvidos para valores baixos de τ , sendo superada por todas as outras alternativas.

No segundo gráfico, que representa o conjunto BCICIV2b, a janela DA se destaca, sendo a primeira a alcançar a cobertura total dos sujeitos. As janelas $(0,0; 2,0)$, $(0,5; 2,5)$ e $(1,5; 3,5)$ também mantêm desempenho elevado e constante. Mais uma vez, a janela $(0,5; 1,0)$ apresenta os piores resultados, com baixa cobertura mesmo para valores mais altos de τ .


O terceiro gráfico, referente ao conjunto CBCIC. A janela DA, novamente, é a que apresenta a melhor performance, atingindo rapidamente o valor máximo da fração de sujeitos resolvidos. As janelas $(0,0; 2,0)$ e $(0,5; 2,5)$ também se destacam positivamente. Enquanto isso, a janela $(0,5; 1,0)$ mais uma vez tem desempenho notadamente inferior, com sua curva crescendo lentamente e ficando atrás das demais. Nesse gráfico aparece uma correlação clara do tamanho de janela quanto à performance para todos os sujeitos, demonstrando que quanto menor for a janela, pior será a performance.

De forma geral, os gráficos demonstram que as janelas $(0,0; 2,0)$ e $(0,5; 2,5)$ são as mais constantemente eficientes para o método FBCSP. A janela DA, que combina múltiplos posicionamentos, é uma das melhores opções em todos os conjuntos. Em contrapartida, janelas menores como a $(0,5; 1,0)$ se mostram menos eficazes, mostrando baixo desempenho e menor generalização.


Figura 13 – Performance Profile para o método FBCSP em diferentes janelamentos



(a) Conjunto de dados BCICIV2a



(b) Conjunto de dados BCICIV2b



(c) Conjunto de dados CBCIC

Fonte: Figura de autoria própria.

Por fim, analisando agora a Figura 14 No primeiro gráfico, correspondente ao conjunto BCICIV2a, observa-se que a janela (0,0; 2,0) apresenta o melhor desempenho,


atingindo rapidamente a fração máxima de sujeitos resolvidos com os menores valores de τ , o que indica resultados próximos ao ótimo. As janelas (0,5; 2,0) e (0,5; 2,5) também demonstram boa performance, enquanto a janela (1,5; 3,5) é nitidamente inferior, necessitando de maiores valores de τ para alcançar a cobertura total.

No segundo gráfico, que mostra os resultados do conjunto BCICIV2b, a janela (0,0; 2,0) novamente se destaca como a melhor alternativa, seguida por (0,5; 1,0) e (1,0; 3,0). Janelas com início mais tardio, como (1,5; 3,5) e (2,0; 4,0), demonstram desempenho inferior, com menor fração de sujeitos resolvidos para baixos valores de τ .


No terceiro gráfico, referente ao conjunto CBCIC, observa-se que a janela (0,5; 2,5) obteve a melhor performance, atingindo rapidamente a cobertura total. As janelas (0,5; 2,0) e (1,5; 3,5) também se destacam, enquanto a janela (0,5; 1,0) apresenta os piores resultados.

Em síntese, os gráficos demonstram que o método EEGNet apresenta melhor desempenho com as janelas (0,5; 2,0), (0,5; 2,5) e (1,0; 3,0). Já as janelas (1,5; 3,5) e (2,0; 4,0) são consistentemente menos eficazes, pois resultaram em Kappa 0 para algum de seus sujeitos.


Figura 14 – Performance Profile para o método EEGNet em diferentes janelamentos



(a) Conjunto de dados BCICIV2a



(b) Conjunto de dados BCICIV2b



(c) Conjunto de dados CBCIC

Fonte: Figura de autoria própria.

8.4 DISCUSSÃO DOS RESULTADOS

Como proposto no Capítulo 7, o objetivo desta análise é responder a três questões centrais: (i) qual o impacto da aplicação simultânea de múltiplas janelas temporais; (ii) como se comportam os dados em torno do ponto de 2,5 segundos, buscando verificar a tendência observada na literatura de utilizar informações pontuais nesse intervalo; e (iii) de que forma diferentes tamanhos e posições de janelas influenciam o desempenho das interfaces cérebro-computador.

Para isso, os dados foram organizados e discutidos com base na separação por janelas temporais, posições dentro do *trial* e no uso combinado de diferentes posicionamentos temporais. Inicialmente, foram avaliados os efeitos das variações no tamanho e na posição das janelas, tanto de forma isolada quanto combinada, para observar as tendências gerais de desempenho. Em seguida, foi realizada uma análise detalhada sobre o comportamento dos métodos, especificamente no instante de 2,5 segundos, visando compreender a razão da sua recorrente utilização em estudos da área. Por fim, foram considerados os efeitos da aplicação simultânea de múltiplas janelas de diferentes posições, como é o caso da janela denominada DA, que agrega diversos segmentos do *trial* em uma única entrada.

Com relação à influência do posicionamento das janelas, os resultados mostram que há uma preferência consistente por intervalos que incluem ou terminam próximos ao ponto de 2,5 segundos após a dica. Especificamente, as janelas de (0,5; 2,5) e (1,0; 3,0) apresentam desempenhos superiores em praticamente todos os métodos e conjuntos de dados analisados. Esse comportamento pode ser atribuído à sincronização da atividade neural que ocorre nesse período, resultando em sinais mais organizados e com maior presença de padrões frequenciais relevantes, especialmente na faixa beta, associada à imaginação motora. A análise pontual no instante de 2,5 segundos também parece estar relacionada a essa hipótese. Esse ponto está contido na faixa temporal de 2,0 a 4,0 segundos, onde se observa o alinhamento de oscilações corticais que favorecem o surgimento de padrões de sincronização de ondas beta [Malan e Sharma 2021]. Além disso, foi possível verificar que diversos picos de desempenho se concentram nesse instante, justificando a escolha recorrente por janelas que o incluem, como demonstrado por estudos anteriores [Malan e Sharma 2021, Souza et al. 2023, Maurício et al. 2024].

Já em relação ao tamanho das janelas, há uma tendência clara de que intervalos maiores, especialmente aqueles com pelo menos 2,0 segundos de duração, resultam em maior acurácia. Isso se deve ao maior volume de informação contido em janelas longas, o que aumenta as chances de capturar os padrões neurais relacionados à tarefa, desde que a janela não extrapole o período útil do *trial*. Tal tendência é corroborada pela literatura recente, que associa o aumento do intervalo de janelamento a melhores resultados em tarefas de imaginação motora [Miladinović et al. 2024].

Adicionalmente, a abordagem DA, baseada na aplicação simultânea de múltiplas

janelas diferentes ao mesmo tempo, mostrou-se especialmente promissora. Ao combinar diferentes recortes temporais do mesmo *trial*, essa técnica parece destacar as características principais presentes no conjunto de dados, contribuindo tanto para uma melhor qualidade de resultados ao longo do tempo quanto para uma maior estabilidade dos mesmos. Isso reforça a ideia de que uma abordagem mais ampla, que contemple diferentes momentos do sinal, pode ser mais eficaz do que uma extração pontual ou localizada.

Dessa forma, é possível responder diretamente às três perguntas norteadoras desta investigação:

- (i) A aplicação simultânea de múltiplas janelas temporais, como na abordagem DA, proporcionou os melhores desempenhos gerais e também a maior estabilidade ao longo do tempo.
- (ii) Esse desempenho está intimamente relacionado ao fato de que, entre 2,0 e 4,0 segundos após dica, ocorre a sincronização da atividade neuronal, favorecendo o surgimento de padrões de frequência, em especial as ondas beta, que são mais facilmente detectáveis. O ponto de 2,5 segundos, situado exatamente no início dessa faixa, mostra-se especialmente informativo, tanto por estar inserido nesse contexto fisiológico quanto pelo fato de que boa parte dos picos de desempenho dos métodos ocorre nesse instante.
- (iii) Por fim, observou-se que janelas maiores foram consistentemente preferidas, o que está de acordo com a literatura que associa maiores intervalos de extração a melhor acurácia. Em relação ao posicionamento, destacaram-se as janelas (0,5; 2,5) e (1,0; 3,0), sendo a primeira encerrada no provável pico de atividade neuronal e a segunda contendo a maior parte dos seus dados dentro da faixa de sincronização. Ambas, portanto, maximizam a chance de capturar as informações mais discriminativas para a tarefa de classificação.

Para finalizar, em relação aos conjuntos de dados analisados, o que apresentou os piores resultados foi o BCICIV2b, demonstrando a menor qualidade média de desempenho ao longo do tempo. Além disso, foi o que obteve os piores valores pontuais quando comparado aos demais. A EEGNet, em particular, teve desempenho significativamente inferior dentro desse conjunto de dados, possivelmente devido ao fato de se tratar de um conjunto que reúne dados com e sem feedback misturados, além de ter sido coletado utilizando somente três eletrodos. Soma-se a isso a influência de artefatos oculares, que introduzem ruídos adicionais ao sinal.

Por outro lado, o conjunto de dados CBCIC apresentou os melhores resultados médios ao longo do tempo, incluindo o maior valor pontual observado. No entanto, também foi o que mostrou maior oscilação nos desempenhos ao longo do tempo. Ainda assim, foi o conjunto no qual os métodos obtiveram melhor performance por indivíduo.

Já o conjunto de dados BCICIV2a destacou-se por apresentar os melhores resultados pontuais, com valores máximos de Kappa situando-se no intervalo de aproximadamente 2,5 à 3,5 segundos.

9 CONCLUSÃO

A compreensão do funcionamento do cérebro humano tem sido um dos grandes desafios da atualidade. Esse órgão, responsável por diversas funções, hoje se encontra em voga, pois se tornou possível coletar a atividade neural e utilizá-la para diversas aplicações. Nesse contexto surgiram as Interfaces Cérebro-Máquina, que têm como propósito utilizar algum método de coleta de informações cerebrais, como o eletroencefalograma, e utilizar essas informações coletadas para diversas aplicações, indo desde os ramos de entretenimento até os campos da saúde, como auxílio na reabilitação para casos de pós-AVC.

Visto isso, as Interfaces Cérebro-Máquina vêm crescendo e se desenvolvendo cada dia mais, passando de simples experimentos em laboratórios para espaços mais públicos e acessíveis. Contribuindo para essa popularização estão as competições internacionais de BCI. Elas auxiliaram no desenvolvimento e estabelecimento de métricas nas quais foi possível otimizar o desenvolvimento de novas interfaces. Além disso, essa iniciativa atraiu a atenção de uma comunidade multidisciplinar que impulsionou ainda mais o desenvolvimento da área.

Dentro dos paradigmas que mais cresceu para Interfaces Cérebro-Máquina foi a imaginação motora, cujas aplicações giram em torno da capacidade de coletar os sinais de um sujeito e permitir que o mesmo interaja com máquinas ou dispositivos no seu meio através de sua atividade mental. Durante a atividade mental, ocorrem mudanças nos padrões de atividade elétrica do cérebro. Essa atividade registrada por um eletroencefalograma pode ser uma geração de potenciais evocados que estão ligados aos efeitos de sincronização e dessincronização de frequências dadas uma atividade específica cerebral.

Na literatura, atualmente, para o paradigma de imaginação motora se utilizam análises pontuais em torno de 2,5 segundos depois da dica para o treinamento de BCI. Esse trabalho veio com a proposta de analisar qual a influência de diferentes janelamentos nos resultados para as Interfaces. Juntamente da possibilidade de se utilizar múltiplas janelas diferentes ao mesmo tempo.

Utilizando os métodos mais comuns da literatura e conjuntos de dados já estabelecidos na literatura, foi possível testar essas questões. Assim, foi encontrada uma correlação clara da atividade neuronal de sincronização e dessincronização, especialmente de ondas betas, com as janelas centradas em volta dos tempos de 2,5 a 3,5 segundos. Isso, por sua vez, explica a tendência dos estudos da literatura utilizarem análises pontuais para 2,5 segundos. Entretanto, foi possível perceber também que janelas maiores de análise encontraram resultados melhores. Além disso, o uso de múltiplas janelas diferentes ao mesmo tempo proporcionou uma maior qualidade e estabilidade dos resultados, estando também correlacionado com uma melhora geral dos mesmos, como é visto para o algoritmo

FBCSP.

Ainda assim, esse atraso para a coleta de características que aumentam a qualidade dos modelos demonstra-se um desafio para as interfaces que buscam ser mais responsivas. Portanto, seria necessário o desenvolvimento de novos métodos que consigam coletar características que possam existir dentro desse intervalo reduzido com uma maior qualidade e estabilidade. Outra abordagem seria definir ou encontrar novas características, sejam elas fisiológicas ou elétricas, que sirvam de base para desenvolvimento de novas métricas e algoritmos.

Para trabalhos futuros, recomenda-se, especialmente no contexto de interfaces mais eficientes, a realização de um estudo mais sistemático focado em janelas temporais reduzidas, compreendidas entre 0,0 e 0,5 segundos. Esse estudo deve empregar ou desenvolver métricas que avaliem não somente o desempenho de classificação, mas também a latência e a estabilidade da resposta, visando otimizar o tempo de resposta do sistema sem comprometer a acurácia.

Por outro lado, para aplicações onde a latência não é um fator crítico, torna-se pertinente aprofundar investigações envolvendo técnicas de aumento de dados combinadas com estratégias que utilizam múltiplas janelas temporais simultaneamente. O objetivo seria avaliar o impacto do enriquecimento de dados na qualidade, estabilidade e generalização dos modelos, especialmente nos intervalos entre 2,5 e 3,5 segundos após o início da dica. Esse tipo de abordagem pode revelar o potencial máximo de desempenho, permitindo identificar o limite superior do ganho possível com a combinação de múltiplas fontes temporais.

REFERÊNCIAS

- AMZICA, F.; SILVA, F. Cellular substrates of brain rhythms. *Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications and Related Fields*, p. 33–64, 10 2012.
- ANG, K. K. et al. Filter bank common spatial pattern (fbcsp) in brain-computer interface. In: *2008 IEEE International Joint Conference on Neural Networks (IJCNN)*. Hong Kong, China: IEEE, 2008. p. 2390–2397.
- ASCENÇÃO, P. V. et al. Evaluation of performance metrics for users of brain computer interfaces during motor imagery. In: *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*. Bari, Italy: IEEE, 2019. p. 217–222.
- ASPIRAS, T. H.; ASARI, V. K. Log power representation of eeg spectral bands for the recognition of emotional states of mind. In: *2011 8th International Conference on Information, Communications & Signal Processing (ICICS)*. Singapore: IEEE, 2011. p. 1–5.
- AUDET, C. et al. Performance indicators in multiobjective optimization. *European Journal of Operational Research*, v. 292, n. 2, p. 397–422, 2021.
- BAŞAR, E.; DÜZGÜN, A. The clair model: Extension of brodmann areas based on brain oscillations and connectivity. *International Journal of Psychophysiology*, v. 103, p. 185–198, 2016. Research on Brain Oscillations and Connectivity in A New Take-Off State.
- BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. *Neurociências: desvendando o sistema nervoso*. 4. ed. Porto Alegre: Artmed, 2017.
- BLANKERTZ, B. et al. The bci competition 2003: progress and perspectives in detection and discrimination of eeg single trials. *IEEE Transactions on Biomedical Engineering*, v. 51, p. 1044–1051, jun 2004.
- BLANKERTZ, B. et al. The bci competition iii: Validating alternative approaches to actual bci problems. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 14, p. 153–159, jun 2006.
- BRUNNER, C. et al. Review of the bci competition iv. *Frontiers in Neuroscience*, 2012. Dados de motor imagery multi-classe e desafios inter-sessão.
- CAIADO, F.; UKOLOV, A. The history, current state and future possibilities of the non-invasive brain computer interfaces. *Medicine in Novel Technology and Devices*, v. 25, p. 100353, 2025.
- CHOWDHURY, A.; ANDREU-PEREZ, J. Clinical brain-computer interface challenge 2020 (cbcic at wcci2020): Overview, methods and results. *IEEE Transactions on Medical Robotics and Bionics*, 2021.
- DALY, J. J.; HUGGINS, J. E. Brain-computer interface: Current and emerging rehabilitation applications. *Archives of Physical Medicine and Rehabilitation*, v. 96, n. 3, Supplement, p. S1–S7, 2015.

DOLAN, E. D.; MORÉ, J. J. *Benchmarking Optimization Software with Performance Profiles*. 2002.

GUTTMANN-FLURY, E.; SHENG, X.; ZHU, X. Channel selection from source localization: A review of four eeg-based brain-computer interfaces paradigms. *Behavior Research Methods*, 2022.

JACOBS, K. M. Brodmann's areas of the cortex. In: KREUTZER, J. S.; DELUCA, J.; CAPLAN, B. (Ed.). *Encyclopedia of Clinical Neuropsychology*. New York, NY: Springer, 2011. p. 459–459.

JEUNET, C. et al. Using eeg-based brain computer interface and neurofeedback targeting sensorimotor rhythms to improve motor skills: Theoretical background, applications and prospects. *Neurophysiologie Clinique*, v. 49, n. 2, p. 125–136, 2019.

KATYAL, K. D. et al. A collaborative bci approach to autonomous control of a prosthetic limb system. In: *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. San Diego, CA, USA: IEEE, 2014.

KAWALA-STERNIUK, A. et al. Summary of over fifty years with brain-computer interfaces—a review. *Brain Sciences*, v. 11, 2021.

KÜBLER, A. The history of bci: From a vision for the future to real support for personhood in people with locked-in syndrome. *Neuroethics*, Springer Science and Business Media LLC, v. 13, p. 163–180, May 2019.

LAWHERN, V. J. et al. Eegnet: a compact convolutional neural network for eeg-based brain-computer interfaces. *Journal of Neural Engineering*, v. 15, n. 5, p. 056013, 2018.

MALAN, N. S.; SHARMA, S. Time window and frequency band optimization using regularized neighbourhood component analysis for multi-view motor imagery eeg classification. *Biomedical Signal Processing and Control*, v. 67, p. 102550, 2021.

MARSHALL, D. et al. Games, gameplay, and bci: The state of the art. *IEEE Transactions on Computational Intelligence and AI in Games*, v. 5, n. 2, p. 82–99, 2013.

MAURÍCIO, J. et al. Analysis of window-delay score for data augmentation methods in brain-computer interfaces. In: *Anais do XXI Encontro Nacional de Inteligência Artificial e Computacional*. Porto Alegre, RS, Brasil: SBC, 2024. p. 192–203.

MILADINOVIĆ, A. et al. Optimizing real-time mi-bci performance in post-stroke patients: Impact of time window duration on classification accuracy and responsiveness. *Sensors*, v. 24, n. 18, p. 6125, 2024.

NIHA, K.; BANU, W. A. Brain signal processing: Technologies, analysis and application. In: *2016 IEEE International Conference on Computational Intelligence and Computing Research (ICCIC)*. Chennai, India: IEEE, 2016. p. 1–6.

PADFIELD, N. et al. Eeg-based brain-computer interfaces using motor-imagery: Techniques and challenges. *Sensors*, v. 19, n. 6, 2019.

PAL, S. et al. Enhancing brain signal acquisition in brain-computer interfaces (bcis). In: *2024 2nd International Conference on Disruptive Technologies (ICDT)*. Dehradun, India: IEEE, 2024.

- PARK, Y.; CHUNG, W. Bci classification using locally generated csp features. In: *2018 6th International Conference on Brain-Computer Interface (BCI)*. Gangwon, Korea (South): IEEE, 2018. p. 1–4.
- PRAKASH, M. B. et al. Noise reduction of ecg using chebyshev filter and classification using machine learning algorithms. In: *2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*. Greater Noida, India: IEEE, 2021. p. 434–441.
- SAIBENE, A. et al. Eeg-based bcis on motor imagery paradigm using wearable technologies: A systematic review. *Sensors*, v. 23, n. 5, 2023.
- SENO, B. D.; MATTEUCCI, M.; MAINARDI, L. T. The utility metric: A novel method to assess the overall performance of discrete brain–computer interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 18, n. 1, p. 20–28, 2010.
- SHAMAS, M. et al. Eegnet: A novel tool for processing and mapping eeg functional networks. In: *2015 7th International IEEE/EMBS Conference on Neural Engineering (NER)*. Montpellier, France: IEEE, 2015. p. 1064–1067.
- SOSA, O. A. P. et al. Bci: A historical analysis and technology comparison. In: *2011 Pan American Health Care Exchanges*. Rio de Janeiro, Brasil: IEEE, 2011. p. 205–209.
- SOUZA, G. H. D. et al. Window-delay analysis on eegnet. In: *2023 10th International Conference on Soft Computing & Machine Intelligence (ISCMi)*. Delhi, India: IEEE, 2023. p. 166–170.
- SOUZA, G. H. de. *Custo por atraso de janela: Uma nova visão sobre o desempenho de Interfaces Cérebro-Máquina*. Tese (Tese (Doutorado)) — Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Modelagem Computacional, 2025. Orientador: Heder Soares Bernardino. Coorientador: Alex Borges Vieira.
- TATUM, W. O. et al. *Handbook of EEG Interpretation*. United States of America: Demos Medical Publishing, 2008.
- VIDAL, J. J. Real-time detection of brain events in eeg. *Proceedings of the IEEE*, v. 65, p. 633–641, 1977.
- VÄRBU, K.; MUHAMMAD, N.; MUHAMMAD, Y. Past, present, and future of eeg-based bci applications. *Sensors*, v. 22, n. 9, 2022.
- WOLPAW, J. R.; MCFARLAND, D. J. Brain–computer interfaces. In: BARNES, M. P.; GOOD, D. C. (Ed.). *Handbook of Clinical Neurology*. Amsterdam, Netherlands: Elsevier, 2013, (3rd series: Neurological Rehabilitation, v. 110). p. 67–74.
- WOLPAW, J. R.; WOLPAW, E. W. *Brain-Computer Interfaces: Principles and Practice*. New York: Oxford University Press, 2012. ISBN 9780195388855.
- ZHANG, M. et al. Motor imagery-based brain–computer interface rehabilitation programs enhance upper extremity performance and cortical activation in stroke patients. *NeuroImage: Clinical*, v. 24, p. 101–993, 2019.