

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

Marcelo de Melo Amorim Filho

Interface Cérebro-Máquina via Métodos de Aprendizado de Máquina:
Alinhamento euclidiano para aprendizado por transferência em Common Spatial Pattern
Multibanda

Juiz de Fora
2025

Marcelo de Melo Amorim Filho

Interface Cérebro-Máquina via Métodos de Aprendizado de Máquina:
Alinhamento euclidiano para aprendizado por transferência em Common Spatial Pattern
Multibanda

Trabalho de conclusão de curso apresentado
a Faculdade de Ciências Exatas da Universi-
dade Federal de Juiz de Fora como requisito
parcial à obtenção do grau de bacharel em
Ciência da Computação.

Orientador: Prof. Gabriel Henrique de Souza

Coorientador: Prof. 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)

Amorim, Marcelo de Melo.

Interface Cérebro-Máquina via Métodos de Aprendizado de Máquina :
Alinhamento euclidiano para aprendizado por transferência em Common
Spatial Pattern Multibanda / Marcelo de Melo Amorim Filho. – 2025.

40 f. : il.

Orientador: Gabriel Henrique de Souza

Coorientador: Heder Soares Bernardino

Trabalho de Conclusão de Curso (graduação) – Universidade Federal de
Juiz de Fora, Faculdade de Ciências Exatas. Bacharelado em Ciência da
Computação, 2025.

1. Interface Cérebro-Máquina. 2. Transferência de Aprendizado. 3.
Alinhamento Euclidiano. 4. Eletroencefalograma. I. de Souza, Gabriel H,
orient. II. Bernardino, Heder Soares, coorient. III. Título.

Marcelo de Melo Amorim Filho

Interface Cérebro-Máquina via Métodos de Aprendizado de Máquina:
Alinhamento euclidiano para aprendizado por transferência em Common Spatial Pattern
Multibanda

Trabalho de conclusão de curso apresentado
a Faculdade de Ciências Exatas da Universi-
dade Federal de Juiz de Fora como requisito
parcial à obtenção do grau de bacharel em
Ciência da Computação.

Aprovada em 12 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. Aleksander Yacovenco
Universidade Federal de Juiz de Fora

Dedico este trabalho aos meus familiares e amigos que estiveram ao meu lado durante toda a minha caminhada.

AGRADECIMENTOS

Gostaria de agradecer a minha irmã, Pyettra, por todo o apoio e paciência dada. Também agradeço a minha família, por todo o suporte dado.

Gostaria de agradecer aos professores, Gabriel e Heder, pela orientação e conhecimentos dados para a realização desse trabalho.

*Know all the theories, master all the techniques, but as you
touch a human soul be just another human soul.*

Carl Jung

RESUMO

O acidente vascular cerebral (AVC) é uma das principais causas de morte e incapacidade no mundo. Interfaces Cérebro-Computador, ou *Brain-Computer Interface* (BCI) surgem como uma opção promissora para reabilitação pós-AVC. No entanto, os modelos tradicionais de BCI enfrentam desafios devido à natureza não estacionária dos sinais de eletroencefalografia e às diferenças anatômicas entre indivíduos. Técnicas de Transferência de Aprendizado (TL), como o Alinhamento Euclidiano (EA), têm sido utilizadas para reduzir as diferenças anatômicas, mas frequentemente perdem informações importantes devido ao uso de filtros temporais de banda única. Este estudo propõe uma nova arquitetura para BCI que combina EA com filtros temporais multibanda, incluindo Banco de Filtros (FB), Decomposição Empírica em Modos e Transformada Contínua de Wavelet. Os experimentos foram realizados utilizando o conjunto de dados PhysionetMI, com configurações de 3 e 8 eletrodos, e avaliados por meio de validação cruzada estratificada. Os resultados demonstraram que o modelo EA-FB com o Padrão Espacial Comum (CPS) seguido pela Análise de Discriminante Linear como classificador alcançou os melhores desempenhos, com acurácias de 80% (3 eletrodos) e 73,33% (8 eletrodos), representando uma melhoria de aproximadamente 44% e 43%, respectivamente, em comparação com o EA-CSP tradicional. Além disso, a aplicação do EA antes dos filtros multibanda mostrou-se mais eficaz do que a ordem inversa, sugerindo uma revisão na ordem das etapas do pipeline de BCI. O FB destacou-se como o melhor método de filtragem temporal, provavelmente devido à sua capacidade de isolar os ritmos μ (8-13 Hz) e β (13-30 Hz), cruciais para tarefas de Imaginação Motora. Este trabalho contribui para o avanço das BCIs de reabilitação pós-AVC, reduzindo o tempo de calibração e melhorando a robustez e generalização dos modelos.

Palavras-chave: interface cérebro-máquina; transferência de aprendizado; alinhamento euclidiano; eletroencefalograma.

ABSTRACT

Stroke is one of the leading causes of death and disability worldwide. Brain-Computer Interfaces (BCIs) have emerged as a promising option for post-stroke rehabilitation. However, traditional BCI models face challenges due to the non-stationary nature of electroencephalography signals and anatomical differences between individuals. Transfer Learning (TL) techniques, such as Euclidean Alignment (EA), have been used to reduce anatomical differences, but they often lose important information due to the use of single-band temporal filters. This study proposes a novel BCI architecture that combines EA with multi-band temporal filters, including Filter Bank (FB), Empirical Mode Decomposition, and Continuous Wavelet Transform. The experiments were performed using the PhysionetMI dataset, with 3 and 8 electrode configurations, and evaluated using stratified cross-validation. The results demonstrated that the EA-FB model with the Common Spatial Pattern (CSP) followed by Linear Discriminant Analysis as classifier achieved the best performances, with accuracies of 80% (3 electrodes) and 73.33% (8 electrodes), representing an improvement of approximately 44% and 43%, respectively, compared to the traditional EA-CSP. In addition, the application of EA before the multiband filters proved to be more effective than the inverse order, suggesting a review in the order of the BCI pipeline steps. FB stood out as the best temporal filtering method, probably due to its ability to isolate the μ (8-13 Hz) and β (13-30 Hz) rhythms, crucial for Motor Imagery tasks. This work contributes to the advancement of BCIs for post-stroke rehabilitation, reducing calibration time and improving the robustness and generalization of the models.

Keywords: brain-machine interface; transfer learning; euclidean alignment; electroencephalogram.

LISTA DE ILUSTRAÇÕES

Figura 1: Sistema 10-10 com 64 eletrodos	21
Figura 2: Fluxo de processamento em BCI para reabilitação motora pós-AVC . . .	22
Figura 3: Banco de Filtros	25
Figura 4: Decomposição Empírica com 3 níveis	26
Figura 5: Esquema de cronometragem de um ensaio do conjunto de dados PhysionetMI	29
Figura 6: Literatura e arquiteturas propostas usando Alinhamento Euclidiano . .	30
Figura 7: Posição dos eletrodos escolhidos. Eletrodos azuis foram utilizados no sub- conjunto de 3 e 8 eletrodos, enquanto eletrodos verdes foram utilizados no subconjunto de 8 eletrodos	32
Figura 8: Perfis de desempenho dos resultados	34

LISTA DE TABELAS

Tabela 1 – Acurácia para o caso de 3 eletrodos.	33
Tabela 2 – Acurácia para o caso de 8 eletrodos.	34

LISTA DE ABREVIATURAS E SIGLAS

AVC	Acidente Vascular Cerebral
BCI	Interface Cérebro-Máquina
SNR	Relação Sinal-Ruído
SSVEP	Potenciais Evocados Visuais em Regime Estacionário
MI	Imaginação Motora
EEG	Eletroencefalograma
TL	Transferência de Aprendizado
EA	Alinhamento Euclidiano
FB	Banco de Filtros
EMD	Decomposição Empírica de Modos
CWT	Transformada Contínua de Wavelet
CSP	Padrão Espacial Comum
LDA	Análise Discriminante Linear
RA	Alinhamento Riemanniano
SVM	Máquina de Vetores de Suporte
REA	Alinhamento Híbrido Riemanniano-Euclidiano
TCA	Análise de Componentes de Transferência
FES	Estimulação Elétrica Funcional
MEG	Magnetoencefalografia
FFT	Transformada Rápida de Fourier
IMF	Funções de Modo Intrínseco
SPD	Matrizes Definidas Positivas
CNN	Rede Neural Convolucional

SUMÁRIO

1	INTRODUÇÃO	13
2	TRABALHOS RELACIONADOS	16
3	MATERIAIS E MÉTODOS	20
3.1	ELETROENCEFALOGRAMA	20
3.2	AQUISIÇÃO DOS DADOS DE IMAGINAÇÃO MOTORA	20
3.3	CICLO DE ATIVIDADES DA INTERFACE CÉREBRO-MÁQUINA	21
3.4	BCI PARA REABILITAÇÃO MOTORA PÓS-AVC	23
3.5	ALINHAMENTO EUCLIDIANO	24
3.6	FILTRO TEMPORAL	24
3.6.1	FILTRO PASSA-BANDA E BANCO DE FILTROS	25
3.6.2	DECOMPOSIÇÃO EM MODO EMPÍRICO	25
3.6.3	TRANSFORMADA CONTÍNUA DE WAVELET	26
3.7	EXTRAÇÃO DE CARACTERÍSTICAS	27
3.7.1	PADRÃO ESPACIAL COMUM	27
3.8	CLASSIFICADOR	28
3.8.1	ANÁLISE DISCRIMINANTE LINEAR	28
3.9	DATASET	29
4	TRABALHO PROPOSTO	30
5	EXPERIMENTOS COMPUTACIONAIS	31
5.1	PARÂMETROS	31
5.2	RESULTADOS USANDO 3 ELETRODOS	32
5.3	RESULTADOS USANDO 8 ELETRODOS	33
5.4	ANALISE DOS PERFIS DE PERFORMANCE	34
6	DISCUSSÃO	36
7	CONCLUSÃO	37
	REFERÊNCIAS	38

1 INTRODUÇÃO

O acidente vascular cerebral (AVC) mantém-se como uma das principais causas de incapacidade e mortalidade em todo o mundo, demandando atenção devido ao seu profundo impacto nos indivíduos e sistemas de saúde [Pacheco-Barrios et al. 2022]. Ao longo dos anos, avanços significativos têm sido alcançados no tratamento do AVC, revolucionando a prevenção e reabilitação dos pacientes. Dentre os métodos mais recentes de tratamento, destaca-se a utilização de interfaces cérebro-máquina (BCIs) [Keng e Guan 2017].

As BCIs são sistemas que permitem a comunicação direta entre o cérebro e dispositivos eletrônicos sem a necessidade de mediação muscular periférica [Bashashati et al. 2007]. Esses sistemas traduzem os sinais elétricos cerebrais durante a execução de tarefas em comandos computacionais. Os métodos de aquisição podem ser invasivos ou não invasivos. As abordagens invasivas oferecem melhor relação sinal-ruído (SNR), sendo de 10 a 100 vezes mais eficientes que os métodos não invasivos, porém apresentam maiores riscos como infecções, danos teciduais e rejeição de implantes devido à sua natureza cirúrgica. Já os equipamentos não-invasivos, embora mais seguros, possuem sinais menos precisos. A eletroencefalografia (EEG) destaca-se como o método mais utilizado em BCIs por ser não-invasivo, apresentar resolução temporal satisfatória na ordem de milissegundos (equivalente aos métodos invasivos), além de ser portátil, leve e cerca de 10 vezes mais econômico que as alternativas invasivas [Keng e Guan 2017].

Nas etapas da BCI, o equipamento registra os sinais do cérebro enquanto o sujeito é exposto a uma condição. Depois disso, um modelo computacional classifica o sinal e um dispositivo executa a tarefa com base nessa classificação. Finalmente, a pessoa observa a execução da tarefa e o ciclo se reinicia. Muitas aplicações podem usar BCIs, como experiências imersivas em realidade virtual para reabilitação [Velasco-Álvarez, Ron-Angevin e López-Gordo 2013], mapeamento de atividades neuronais [Zheng e Schieber 2020] e procedimentos assistivos para indivíduos com deficiências, como AVC [Mane, Chouhan e Guan 2020]. Para reabilitação motora pós-AVC, a BCI é usada para fechar um ciclo de aprendizagem por reforço para promover neuroplasticidade na área afetada no cérebro. Seção 3.3 apresenta uma descrição detalhada desse ciclo.

Em sistemas BCI, o paradigma adotado define como os sinais cerebrais são capturados, processados e interpretados. Paradigmas como P300 e Potenciais Evocados Visuais em Regime Estacionário (SSVEP) funcionam ao coletar a resposta cerebral automática a estímulos visuais, onde o primeiro captura o sinal 300 milissegundos depois do estímulo, enquanto o segundo captura a frequência específica do estímulo. Por outro lado, paradigmas como a Imaginação Motora (MI) baseiam-se na modificação dos ritmos sensoriomotores durante a imaginação de movimentos. O tratamento pós-AVC utiliza esse paradigma, uma vez que a imaginação de movimentos debilitados por AVC promove a neuroplasticidade,

recriando circuitos inibidos [Abiri et al. 2019].

Os modelos de BCI são sensíveis ao sujeito que forneceu os sinais cerebrais para treinamento. Devido ao comportamento não-estacionário dos sinais de EEG e às diferenças anatômicas entre os cérebros humanos, os modelos são tipicamente dependentes do indivíduo. As técnicas de Transferência de Aprendizado (TL) surgem para reduzir essas diferenças entre os sinais de diferentes sujeitos, permitindo utilizar dados de um conjunto de indivíduos (domínio fonte) para treinar modelos aplicáveis a outros (domínio alvo) [He e Wu 2020]. Os métodos de Alinhamento Riemanniano (RA) e Alinhamento Euclidiano (EA) destacam-se como as abordagens de TL mais utilizadas. Contudo, esses modelos tradicionais empregam filtragem temporal de banda única, perdendo padrões temporais relevantes presentes em outras faixas de frequência.

Um dos principais problemas enfrentados pelos sistemas BCI é a variabilidade dos sinais cerebrais entre os indivíduos. Essa diferença é causada tanto por características anatômicas individuais quanto pelo comportamento dinâmico dos sinais de EEG, que podem variar ao longo do tempo. Como resultado, modelos de BCI treinados para um indivíduo não podem ser aplicados diretamente a outro, o que limita a generalização desses modelos [He e Wu 2020]. Essa falta de portabilidade cria a necessidade de calibrações frequentes e individualizadas, tornando o uso de BCIs mais complexos e menos eficiente, especialmente em contextos clínicos, como na reabilitação motora.

Além disso, a maioria dos modelos BCI atuais utiliza apenas uma única banda de frequência durante a análise dos sinais cerebrais, o que pode resultar na perda de informações importantes [Bashashati et al. 2007]. Os sinais de EEG contêm dados em diversas faixas de frequência, associados a diferentes atividades cerebrais. Ao ignorar essa riqueza de dados, muitos modelos de BCI apresentam desempenho inferior, especialmente em aplicações que requerem alta precisão, como a reabilitação pós-AVC. Esse problema aumenta a demanda por abordagens mais robustas, capazes de lidar tanto com a variabilidade entre indivíduos quanto com a diversidade dos sinais cerebrais.

A necessidade de desenvolver sistemas BCI mais robustos e precisos é especialmente urgente na área de reabilitação motora, onde a eficiência do modelo pode impactar diretamente os resultados terapêuticos. Se os sistemas BCI forem capazes de interpretar com maior precisão os sinais cerebrais dos pacientes, os exercícios de reabilitação poderão ser mais eficazes, potencializando o processo de neuroplasticidade. Isso não apenas aceleraria a recuperação dos pacientes, mas também tornaria o tratamento menos cansativo, pois reduziria a necessidade de calibrações constantes e ajustes manuais no sistema. Sistemas que utilizam Aprendizado por Transferência são ainda mais eficazes, pois reduzem o tempo de treinamento dos sujeitos.

Além disso, uma BCI mais eficiente permitiria que os pacientes realizassem sessões de reabilitação mais longas e intensas sem sentir fadiga cognitiva. A diminuição do tempo

de calibração do sistema e a melhora na precisão dos comandos interpretados também resultariam em menos interrupções no tratamento [Mane, Chouhan e Guan 2020]. Com o tempo, isso poderia proporcionar uma recuperação mais eficaz e consistente, contribuindo para uma melhora na qualidade de vida dos pacientes, além de reduzir o estresse físico e emocional envolvidos no processo de reabilitação.

Este trabalho propõe diferentes formas de utilizar modelos multibanda com EA, avaliando técnicas de filtragem temporal por Banco de Filtros (FB), Decomposição Empírica em Modos (EMD) e Transformada Contínua de Wavelet (CWT). A combinação de TL com essas técnicas tem sido explorada recentemente na literatura [Xiong e Wei 2022].

Utilizando o dataset PhysionetMI [Goldberger et al. 2000], amplamente reconhecido na literatura, nossos resultados demonstram que a abordagem multibanda combinada com EA melhora significativamente o desempenho dos classificadores de BCI neste cenário. Esta vantagem é particularmente relevante para modelos de BCI aplicados à reabilitação motora pós-AVC, pois reduz o tempo de calibração e simplifica o procedimento para uso com outro paciente.

A importância clínica desta pesquisa torna-se evidente ao considerarmos que o AVC frequentemente resulta em déficits motores persistentes que comprometem a qualidade de vida dos pacientes [Hayes et al. 2003]. As BCIs baseadas em imaginação motora surgem como uma alternativa promissora para induzir neuroplasticidade nas áreas afetadas, fechando um ciclo de aprendizado reforçado que pode acelerar a recuperação funcional [Mane, Chouhan e Guan 2020]. A redução no tempo de calibração obtida através das técnicas propostas pode tornar essas terapias mais acessíveis e eficientes na prática clínica.

Esse trabalho está organizado da seguinte forma: o capítulo 2 relata os trabalhos relacionados ao tema. O capítulo 3 introduz as informações básicas para o entendimento desse trabalho, bem como a fundamentação teórica dos métodos utilizados. O capítulo 4 apresenta a ideia proposta no trabalho, enquanto o capítulo 5 apresenta os parâmetros computacionais utilizados nesse experimento e seus resultados. Finalmente, o capítulo 6 apresenta uma discussão dos resultados obtidos, é o capítulo 7 que conclui este trabalho.

2 TRABALHOS RELACIONADOS

Os sinais de EEG variam significativamente entre indivíduos, devido às diferenças em suas atividades cerebrais [Li et al. 2021]. Essa condição é intensificada em indivíduos que sofreram algum tipo de derrame. Como resultado, essas diferenças impactam significativamente a fase de treinamento em BCI, exigindo uma abordagem personalizada. Portanto, geralmente, é crucial treinar um modelo distinto para cada pessoa. Para lidar com essa situação, métodos de transferência de aprendizado foram propostos.

O primeiro método de TL para BCIs foi proposto por [Zanini et al. 2018]. Esse método, chamado Alinhamento Riemanniano (RA), é baseado na geometria riemanniana de matrizes de covariância do EEG, alinhando a matriz de covariância dos sinais de cada sujeito durante seu estado de repouso. O principal desafio abordado foi a variabilidade inter-sujeitos e inter-sessões, que dificulta a reutilização de dados prévios para calibrar classificadores em novos usuários ou sessões. A solução proposta consiste em transformar as matrizes de covariância de cada sessão/sujeito em relação a uma matriz de referência, alinhando-as no espaço Riemanniano de matrizes definidas positivas (SPD). O método foi testado com dataset MI BCI-2a, mostrando uma melhoria de até 30% na acurácia. Entretanto, esse trabalho demonstrou limitações no método proposto, uma vez que o alinhamento ocorre no espaço Riemanniano, todas as operações subsequentes devem ser efetuadas nesse mesmo espaço, e não nos próprios dados de EEG. A segunda limitação é o fato do cálculo da média Riemanniana das matrizes de covariância ser computacionalmente caro, especialmente quando o número de canais de EEG é grande. Por fim, o RA necessita de dados rotulados ao inserir novos sujeitos no espaço Riemanniano.

Para lidar com essas limitações, [He e Wu 2020] propõe um método de alinhamento de dados no espaço euclidiano para aplicar TL em BCIs, visando superar a variabilidade inter-sujeitos e inter-sessões em EEG. O EA alinha os testes de EEG para cada sujeito no espaço euclidiano usando a média da matriz de covariância dos testes do sujeito como uma matriz de referência. Depois disso, a matriz de referência transformada referente a cada sujeito se torna a matriz identidade. Essa técnica reduz a diferença entre dados de sujeitos distintos, similarmente à RA, mas sem transferir os dados para o espaço Riemanniano. Portanto, é possível usar classificadores não Riemannianos, como Análise Discriminante Linear (LDA) e Máquina de Vetores de Suporte (SVM) [Lotte et al. 2007, Lotte et al. 2018]. O estudo utiliza CSP para extração de características em tarefas de imaginação motora (MI), com classificadores LDA/SVM. Foram testados datasets da Competição BCI IV (MI) [Tangemann et al. 2012] e PhysioNet (ERP) [Goldberger et al. 2000].

Um processo ideal de Alinhamento de Dados é capaz de resolver três mudanças entre dados de diferentes sujeitos [He e Wu 2020]:

1. Deslocamento de Covariância: onde a distribuição das entradas muda;

2. Deslocamento de Probabilidade Prioritária: onde a distribuição das saídas muda; e
3. Mudança de Conceito: onde a relação entre as entradas e as saídas muda.

No entanto, o processo EA lida apenas com o primeiro tipo de mudança, reduzindo a diferença entre os sinais de diferentes sujeitos. Ao comparar modelos, EA aponta melhores resultados do que RA quando a aprendizagem de transferência é usada para aplicações BCI [He e Wu 2020]. Após seu lançamento, diferentes abordagens foram propostas para melhorar EA.

O trabalho de [Li et al. 2021] propõem um método de transferência de aprendizagem (TL) que combina alinhamento de dados nos espaços Riemanniano e Euclidiano com seleção de sujeitos para BCI-MI. O Alinhamento Híbrido Riemanniano-Euclidiano (REA) minimiza a variabilidade entre sujeitos usando uma matriz de referência que integra ambos os espaços. Os classificadores utilizados foram CSP-LDA (espaço Euclidiano) e SCM-MDM (espaço Riemanniano). O REA superou métodos tradicionais em precisão e consistência, especialmente quando combinado com a seleção de sujeitos. As métricas incluíram acurácia e testes estatísticos, mas o método ainda requer adaptações para uso em tempo real.

O estudo de [Gao et al. 2023] introduz um método de aprendizado por transferência em dois estágios (DSTL) para classificação de sinais de EEG em sistemas BCI baseados em MI. A principal dificuldade abordada é a limitação de dados de EEG, causada pela sua variabilidade não estacionária e pelo tempo extenso de calibração para novos usuários. O DSTL atua no pré-processamento e na extração de características: primeiro, o EA reduz diferenças entre sinais de indivíduos distintos; depois, uma ponderação das amostras do domínio-fonte é aplicada, considerando a distância entre matrizes de covariância dos domínios-fonte e alvo. Após a extração de características espaciais com CSP, a Análise de Componentes de Transferência (TCA) minimiza discrepâncias remanescentes entre domínios. Testado em dois datasets públicos de MI da competição BCI-IV [Tangemann et al. 2012] e em dois cenários (transferência multi-fonte para único alvo e fonte única para único alvo), o DSTL superou métodos avançados de TL, atingindo 84,64% e 77,16% de acurácia nos datasets no modo multi-fonte. Os resultados demonstram sua eficácia na redução de diferenças entre domínios sem exigir dados de treinamento específicos.

Comparações de métodos de TL aplicados a classificadores de aprendizagem profunda apontaram que RA e EA apresentam melhores resultados do que técnicas de normalização [Xu et al. 2021, Wang, Yang e Huang 2022, Cao et al. 2018]. No entanto, para essas abordagens de aprendizagem de transferência, o mapa topográfico perde sua correlação com os processos fisiológicos no cérebro. O trabalho de [Wang, Yang e Huang 2022] propõe um método de classificação de EEG para BCI-MI, combinando aprendizado pro-

fundo e TL não supervisionado. O trabalho aborda a variabilidade não estacionária dos sinais de EEG, que prejudica a classificação entre sessões ou indivíduos diferentes. A solução envolve o alinhamento de matrizes de covariância no espaço euclidiano (EA) para reduzir discrepâncias entre domínios-fonte e alvo. Em seguida, o método aplica o CSP para extração de características espaciais e uma rede neural convolucional (CNN) para classificação. Além disso, os autores introduzem um pré-processamento baseado na remoção de ruído de ondas para melhorar a qualidade do sinal, aumentando a robustez na extração de características. Testes em um dataset público de MI [Tangermann et al. 2012] demonstraram que a abordagem supera quatro métodos comparativos, incluindo SVM e CNN com fine-tuning, em termos de acurácia. Os resultados confirmam que a combinação de transferência de aprendizado, processamento de sinais e aprendizado profundo melhora significativamente a classificação de EEG-MI, sendo promissora para aplicações em BCI com dados limitados.

O estudo de [Xiong e Wei 2022] apresenta uma abordagem para reduzir o tempo de calibração em BCIs baseados em MI através da geração de dados artificiais de EEG. O método combina Decomposição Modal Empírica (EMD) com EA, utilizando poucos ensaios reais como base. Primeiro, o EA normaliza os sinais entre sujeitos e sessões, reduzindo variações. Em seguida, a EMD decompõe os sinais em Funções Modais Intrínsecas (IMFs), recombinadas para criar novos ensaios sintéticos. Estes dados artificiais são adicionados ao conjunto original e processados com CSP para extração de características, seguidas por classificadores como LDA e Regressão Logística. Testes nos datasets BCI Competition IV [Tangermann et al. 2012] e III [Blankertz et al. 2006] mostraram que o EA-EMD alcançou 84% de acurácia com apenas 10 ensaios por classe - desempenho comparável a métodos tradicionais que exigem 30-40 ensaios. A técnica superou a EMD convencional, melhorando tanto a variabilidade dos dados quanto a separação entre classes. A abordagem demonstrou ser particularmente eficaz na redução da dependência de grandes volumes de dados reais. Contudo, em sujeitos com baixa separabilidade inicial entre classes MI, os resultados foram menos expressivos, indicando a necessidade potencial de combinar a técnica com métodos como aprendizado por transferência para esses casos específicos. Os resultados sugerem que o EA-EMD é uma solução promissora para acelerar a calibração de BCIs sem comprometer a acurácia.

A Análise de Componentes de Transferência (TCA) também foi usada com EA, melhorando a acurácia do modelo [Demsy, Achancray e Hayashibe 2021, Wu, Jiang e Peng 2022]. O estudo de [Wu, Jiang e Peng 2022] propõe uma abordagem de TL para BCIs baseados em MI, visando reduzir a calibração para novos usuários sem perder acurácia. O TL é aplicado em múltiplas etapas, incluindo filtragem espacial (via CSP regularizado e combinado), seleção de características (usando ReliefF [Kononenko 1994]) e classificação. Técnicas como EA ajudam a reduzir a variabilidade entre sujeitos. Avaliado em três datasets públicos (BCI Competition IV 1/2a [Tangermann et al. 2012] e Horizon

2020 [Kononenko 1994]), o método mostrou melhor desempenho quando poucas amostras do domínio-alvo estavam disponíveis. Combinações avançadas, como RCSP com regularização de adaptação ponderada (wAR), atingiram os melhores resultados. Contudo, a eficácia diminuiu em dados com maior variabilidade inter-sujeitos, e técnicas simples de TL em etapas isoladas (como filtragem espacial) nem sempre melhoraram a classificação. O estudo reforça a necessidade de estratégias robustas de TL e alinhamento de dados para garantir desempenho consistente.

Modificações no Padrão Espacial Comum, ou *Common Spatial Pattern* (CSP), também foram propostas para melhorar os resultados do BCI, como CSP para transformações intra e extra-sujeito ao mesmo tempo [Wei e Ding 2023]. Além disso, muitos experimentos usando EA padrão para modelos de classificação foram adotados [Zhang et al. 2023, Wu et al. 2023], mas EA padrão foi usado como o primeiro passo do modelo e com apenas uma única banda, como um filtro passa-banda de 8-30 Hz. Também, a pesquisa foi direcionada para paradigmas diferentes de Motor Imagery, como Visual Evoked Potential [Kilani et al. 2022, Kilani, Aghili e Hulea 2023, Ying, Wei e Zhou 2022].

Nenhum dos trabalhos citados aqui considera a utilização do EA com técnicas multibandas. Neste trabalho, propomos novos pipelines para EA usando multibandas e aplicação paralela de EA após decomposição do sinal.

3 MATERIAIS E MÉTODOS

Este capítulo aborda os fundamentos do sistema BCI aplicado à reabilitação motora pós-AVC, descrevendo todo o processo envolvido - desde a aquisição dos sinais cerebrais até o processamento dos dados e sua aplicação terapêutica.

3.1 ELETROENCEFALOGRAMA

Um dos dispositivos não invasivos mais utilizados para a coleta de sinais cerebrais é atualmente o eletroencefalograma [Keng e Guan 2017]. O equipamento é composto por um ou mais eletrodos conectados a um sistema de amplificação e registro. Os eletrodos são fixados no couro cabeludo do paciente através, normalmente, de um gel condutor, e quando o equipamento é ligado, eles captam os sinais elétricos do cérebro, que serão processados e registrados posteriormente.


A escolha da posição dos eletrodos é importante, pois ela facilita a extração de informação de áreas específicas do cérebro que estão correlacionadas com o objetivo da extração. Um exemplo disso é a colocação de eletrodos acima do córtex motor, para extrair informações importantes para o paradigma de MI.

Para facilitar essa escolha, foram desenvolvidos sistemas padronizados para a posição dos eletrodos. O sistema de eletrodos 10-10 [Nuwer 2018] usa de 64 a 256 eletrodos, onde cada eletrodo recebe um nome, incluindo letras e números, para facilitar o reconhecimento da sua posição. A Figura 1 apresenta um esquema para o sistema 10-10 com 64 eletrodos. A escolha dos eletrodos usados neste trabalho será discutida na Seção 5.1

3.2 AQUISIÇÃO DOS DADOS DE IMAGINAÇÃO MOTORA

Existem diversos processos experimentais de coleta de dados utilizando EEG. Esses protocolos são chamados de paradigmas. O paradigma em destaque nesse trabalho é o de Imaginação Motora (MI). O MI se baseia no fato de que a imaginação de um movimento sem a execução do mesmo gera padrões de ativação cerebral semelhantes aos observados durante o movimento real. Durante a imaginação dos movimentos, o eletroencefalograma coleta os sinais cerebrais, que serão passados para o BCI pipeline. Esse paradigma é muito útil no processo de reabilitação motora, uma vez que o paciente pode não ter o movimento físico dos membros.

A coleta começa com o paciente se sentando na frente de uma tela, que irá lhe passar as instruções. A tela então indicará qual movimento ele deve imaginar dentre um conjunto de movimentos pre-estabelecidos, como fechar a mão direita ou esquerda. Essa indicação é chamada de *cue*, ou sugestão. Existe um pequeno intervalo de tempo entre a sugestão do movimento e a coleta de dados em si, para que o paciente possa se preparar

Figura 1: Sistema 10-10 com 64 eletrodos

Fonte: Elaborado pelo autor.

para a imaginação. Depois do período de coleta, ocorre um intervalo de descanso, até a próxima sugestão.

Essa sequência para a coleta de um único movimento é chamada de *trial*. A duração e formato do *trial* devem ser constantes durante toda a coleta para o mesmo paciente. Depois da coleta de uma quantidade específica de *trials*, ocorre um período de descanso, devido ao cansaço adquirido pelo paciente durante a coleta. Esse conjunto de *trials* é chamado de sessão. Um paciente pode fazer várias sessões no mesmo dia, e também durante dias diferentes. Entretanto, é recomendável poucas sessões durante um mesmo dia, e entre dias igualmente espaçados, para manter a coerência da coleta.

3.3 CICLO DE ATIVIDADES DA INTERFACE CÉREBRO-MÁQUINA

Para o funcionamento da BCI, a aquisição de dados cerebrais é necessária geralmente. É possível extrair os dados de um paciente e utilizá-los imediatamente, conhecido como dados *online*. Certas instituições e competições costumam adquirir dados de EEG e disponibilizá-los publicamente na forma de *datasets*, conhecidos como dados *offline*. Esses


datasets contêm os dados coletados, além de informações relevantes para quem for utilizá-lo, como, por exemplo, sistema de eletrodos utilizado, quais eletrodos do sistema foram escolhidos e qual foi a frequência de coleta dos dados.

A partir da aquisição dos dados de EEG, um fluxo de processamento de sinais é criado para transformar os dados brutos em comandos executáveis por dispositivos externos. Esse fluxo é chamado de ciclo da Interface Cérebro-Computador, ou *BCI pipeline*. O BCI pipeline pode ter várias etapas diferentes para melhorar seu desempenho.

Inicialmente, os dados brutos de EEG contêm, além dos dados cerebrais, outras informações irrelevantes para o propósito do BCI, como artefatos fisiológicos (movimentos oculares e atividade muscular) e não fisiológicos (ruído eletromagnético). A presença desses artefatos é representada pelo *signal-to-noise* (SNR), o que afeta negativamente o desempenho da BCI. Para mitigar esse efeito, processos de filtragem são utilizados para melhorar o SNR dos dados.

Depois dessa filtragem, ocorre a extração de características, onde o sinal é transformado em representações compactas e discriminativas. Em situações onde essas várias representações são captadas, uma seleção de características pode ser utilizada para reduzir a dimensionalidade, selecionando-se as características mais relevantes. Finalmente, um classificador mapeia as características nas classes de saída escolhidas na construção do *pipeline*, como, por exemplo, “mover cursor para a direita”. A Figura 2 representa o BCI *pipeline* para reabilitação motora pós-AVC. Na reabilitação motora pós-AVC, o *feedback* – informação em tempo real sobre a atividade cerebral do paciente – é fundamental para o processo neuroplástico. Esse retorno sensorial ocorre geralmente de forma bimodal: (1) visual, via representações gráficas na tela (como barras ou animações que respondem à intenção de movimento), e (2) tátil-cinestésico, por meio de estimulação elétrica funcional (FES) que contrai os músculos-alvo, criando um ciclo de aprendizado motor.

Figura 2: Fluxo de processamento em BCI para reabilitação motora pós-AVC



Fonte: Elaborado pelo autor.

3.4 BCI PARA REABILITAÇÃO MOTORA PÓS-AVC

O AVC é uma emergência médica que deixa sequelas, incluindo déficits cognitivos e motores e disfagia orofaríngea [Hayes et al. 2003]. A reabilitação de pacientes pós-AVC é de grande importância para a recuperação de suas funções cognitivas e motoras. Além disso, o BCI para reabilitação pós-AVC é uma alternativa para induzir plasticidade neural, a qual é a capacidade do cérebro de se adaptar e reorganizar, formando novas conexões entre neurônios em resposta a aprendizados, experiências ou lesões. Os BCIs apoiam esse processo, fornecendo estímulos direcionados que criam um ciclo fechado para a reorganização neural. O envolvimento direto com dispositivos externos ativa regiões cerebrais ligadas ao movimento, fortalecendo vias neurais pertinentes e promovendo a plasticidade positiva.

O aprendizado por reforço favorece a BCI para a reabilitação motora pós-AVC, uma vez que envolve a adaptação do comportamento com base nas consequências das ações. Com os BCIs, os indivíduos podem receber *feedback* instantâneo e personalizado, correspondente aos seus esforços de reabilitação. Esse *feedback* cria um reforço positivo, fortalecendo as conexões neurais ligadas aos padrões de movimento direcionados. Além disso, as BCIs visam fechar o ciclo de planejamento motor – o processo neurofisiológico pelo qual o cérebro concebe, organiza e prepara a execução de movimentos, auxiliando na reconexão dos circuitos cerebrais responsáveis pelo controle motor. Ao converter sinais cerebrais em comandos acionáveis para dispositivos externos, as BCIs auxiliam na reabilitação do planejamento motor, promovendo a prática iterativa e o aprimoramento gradual das habilidades motoras. Nos últimos anos, as BCIs têm demonstrado resultados significativos na reabilitação motora pós-AVC [Keng et al. 2011, Keng e Guan 2017]. Esses resultados são semelhantes aos das técnicas de reabilitação convencionais na maioria dos casos [Mane, Chouhan e Guan 2020]. Além disso, a abordagem BCI tem demonstrado resultados proeminentes mesmo para pacientes que sofreram um AVC muito tempo antes do tratamento [Frolov et al. 2017].

Oito pacientes com AVC crônico participaram de um estudo utilizando um sistema BCI baseado em magnetoencefalografia (MEG) para controlar uma órtese mecânica de mão [Chowdhury et al. 2018]. Esse estudo mostra que a maioria dos pacientes com AVC crônico e paralisia completa da mão pode aprender a modular a amplitude do ritmo. Utilizando esse paradigma, eles podem alcançar o controle binário de uma prótese que manipula passivamente a postura de preensão da mão paralisada devido ao AVC. Ao final do período de treinamento de 13 a 22 sessões, os pacientes alcançaram taxas de sucesso que variaram entre 65% e 90%.

Além disso, estudos sobre reabilitação de membros superiores utilizando BCI indicam que a precisão do sistema BCI pode melhorar a função motora. Outros estudos também mostraram uma relação entre a precisão do BCI e ganhos clínicos [Mane, Chouhan e Guan 2020,

Biasiucci et al. 2018, Keng e Guan 2017]. Essa relação se baseia na hipótese de que uma maior precisão do BCI pode melhorar a confiança e a motivação dos pacientes, o que pode promover melhor a plasticidade [Mane, Chouhan e Guan 2020]. Além disso, outra razão para o sucesso da reabilitação com BCI pode ser a correlação entre o engajamento e maiores níveis de atenção do paciente.

No contexto de sistemas BCI para reabilitação de pacientes, é relevante mencionar que um número menor de eletrodos é benéfico em termos de facilidade de tratamento e conforto para o paciente [Souza et al. 2019]. Além disso, o alinhamento de dados é enfatizado para alinhar estímulos e suas respostas, garantindo uma análise temporal mais precisa. O Alinhamento de Dados também se mostra eficaz no aumento da eficiência do sistema e na redução de interferências e ruídos de sinal. Ao utilizar o Alinhamento de Dados, pode-se reduzir o número de ensaios necessários para treinar o modelo, resultando em um tratamento mais rápido e menos exaustivo.

3.5 ALINHAMENTO EUCLIDIANO

O Alinhamento Euclidiano (EA) foi proposto como uma alternativa ao Alinhamento Riemanniano (RA) [He e Wu 2020]. As vantagens do EA são a redução do tempo de alinhamento em comparação ao RA e a manutenção dos dados no espaço euclidiano. O EA utiliza uma matriz de referência, calculada por meio dos ensaios de EEG, para alinhar os dados de diferentes indivíduos. Uma matriz de referência $\bar{R}_s$ é a média da covariância do ensaio para o s -ésimo indivíduo, que é definida por:

$$\bar{R}_s = \frac{1}{N_s} \sum_{n=1}^{N_s} X_s^n (X_s^n)^\top \quad (3.1)$$

onde N_s é o número de tentativas do sujeito s , X_s^n é a n -ésima tentativa do sujeito s . A matriz $\bar{R}_s$ reduz a diferença entre os sujeitos como:

$$E_s^n = \bar{R}_s^{-\frac{1}{2}} \times X_s^n \quad (3.2)$$

onde E_s^n é o sinal do sujeito s após o alinhamento. A nova matriz de referência para todos os sujeitos transformados é igual à matriz identidade. Portanto, o novo espaço é similar para todos os sujeitos.

3.6 FILTRO TEMPORAL

A filtragem temporal é uma técnica utilizada no processamento de dados para extrair ou manipular informações temporais em conjuntos de dados. Seu objetivo é aprimorar a qualidade do sinal, melhorando a relação sinal-ruído [Papageorgiou et al. 2013]. A filtragem temporal remove ou atenua componentes temporais indesejados nos dados, permitindo a identificação de padrões mais significativos ou a redução de ruído. A escolha


de uma técnica de filtragem temporal depende do contexto específico do problema e dos objetivos da análise. Esta seção apresenta quatro filtros temporais: Passa-banda, Banco de Filtros (FB), Decomposição em Modos Empíricos (EMD) e Wavelet Contínuo (CWT).

3.6.1 FILTRO PASSA-BANDA E BANCO DE FILTROS

Filtros Passa-Banda são amplamente empregados em diversas aplicações de processamento de sinais, incluindo sistemas de comunicação sem fio, processamento de áudio e vídeo e EEG. Eles são úteis para isolar sinais de frequências específicas e eliminar ruídos indesejados. Um filtro passa-banda permite que uma faixa específica de frequências passe pelo filtro, atenuando as frequências fora dessa faixa.

Um Banco de Filtros é um grupo de filtros passa-banda que dividem um sinal de entrada em sub-bandas. A Figura 3 mostra um diagrama do Banco de Filtros de Análise.

Figura 3: Banco de Filtros



Fonte: Elaborado pelo autor.

3.6.2 DECOMPOSIÇÃO EM MODO EMPÍRICO

A Decomposição em Modo Empírico (EMD, do inglês *Empirical Mode Decomposition*) [Huang et al. 1998] é um método utilizado para analisar sinais não estacionários — ou seja, sinais cujas propriedades estatísticas (como média, variância e frequência) variam ao longo do tempo — e não lineares. Essa técnica decompõe tais dados em componentes oscilatórias intrínsecas, chamadas de Funções de Modo Intrínseco (IMFs), permitindo a extração de informações que não estão explícitas no sinal original. O cerne deste método reside na identificação empírica dos modos oscilatórios, distinguidos por suas escalas de tempo características. Após essa identificação, os dados são decompostos adequadamente.

O método utiliza o processo de peneiramento para decompor os dados em Funções de Modo Intrínsecas (IMFs) e um resíduo. A Figura 4 apresenta uma representação esquemática de um algoritmo de EMD, com 3 IMFs e um resíduo como saídas. O processo de peneiramento de um sinal x consiste nas seguintes etapas:

1. O processo inicia com a identificação dos máximos e mínimos locais do sinal. Todos os máximos são então conectados por uma spline cúbica, formando o envelope superior - uma curva suave que envolve os picos do sinal, delimitando sua amplitude máxima. Da mesma forma, os mínimos são interpolados para criar o envelope inferior.


A média m_i é calculada ponto a ponto como a média aritmética entre esses dois envelopes, representando a tendência central do sinal ao longo do tempo. O primeiro componente h_i é obtido subtraindo-se esta média m_i do sinal original, resultando nas flutuações locais em torno da tendência principal. Este método é particularmente útil na decomposição de sinais não-estacionários, permitindo isolar componentes oscilatórios específicos.

2. Se o componente h_i for um IMF, este é separado dos dados restantes e designado como c_i . O resultado é um componente r_n . Caso contrário, a Etapa (1) é repetida com h_i como sinal de entrada.
3. Se r_n for uma distribuição normal, o conjunto de dados original x é decomposto em n IMFs c_i e um resíduo r_n , que pode ser a tendência média ou uma constante. Caso contrário, as Etapas (1) e (2) são repetidas.

O procedimento EDM pode ser representado pela seguinte equação:

$$x = \sum_{i=1}^n c_i + r_n \quad (3.3)$$

Figura 4: Decomposição Empírica com 3 níveis



Fonte: Elaborado pelo autor.

3.6.3 TRANSFORMADA CONTÍNUA DE WAVELET

É uma aplicação da transformada wavelet que emprega escalas arbitrárias e wavelets quase arbitrárias [Gómez, Castejón e García-Prada 2016]. Wavelets são oscilações breves localizadas no tempo e na frequência. Nessa transformação, o sinal é decomposto em um conjunto de wavelets, cada uma correspondendo a uma faixa de frequência distinta. A Transformada Wavelet Contínua (CWT) gera uma representação tempo-frequência de um sinal com a melhor localização encontrada pelo modelo tanto na dimensão tempo quanto na dimensão frequência.

A CWT pode ser vista como uma representação gráfica chamada espectrograma, que mostra a intensidade de diferentes frequências ao longo do tempo. Cada ponto no espectrograma reflete a intensidade do componente de frequência associado em um

momento específico. A CWT é especialmente útil para analisar sinais dinâmicos, onde as características de frequência podem variar ao longo do tempo, e a escolha dos parâmetros wavelet e de escala é crítica na CWT, pois determina a sensibilidade da transformada às várias características do sinal. A função CWT de um sinal de entrada $x(t)$ é representada como:

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (3.4)$$

onde a controla o comprimento da wavelet, b controla a posição da wavelet ao longo do eixo do tempo e $\psi^*(\frac{t-b}{a})$ é a versão conjugada complexa da wavelet $\psi(\frac{t-b}{a})$.

3.7 EXTRAÇÃO DE CARACTERÍSTICAS

A extração de características é uma das etapas utilizadas no processamento de dados, responsável por transformar sinais brutos em informações relevantes e compactas. Seu objetivo é selecionar aspectos discriminativos dos dados, facilitando a identificação de padrões e melhorando a eficiência de sistemas de classificação ou análise. Sem uma extração adequada, algoritmos de aprendizado de máquina podem ter desempenho ruim devido à alta dimensão de entrada. A escolha do método depende do tipo de sinal e do objetivo da aplicação. Essa seção apresenta a técnica escolhida para esse trabalho, que é o CSP.

3.7.1 PADRÃO ESPACIAL COMUM

O CSP é uma técnica de filtragem espacial que também extrai características de sinais. O CSP visa encontrar um conjunto de filtros espaciais que maximizem a diferença entre sinais de duas classes com base em suas matrizes de covariância. Sua aplicação é dada por:

$$Z_i = W^T \times E_i \quad (3.5)$$

onde $Z_i \in \mathbb{R}^{S \times T_s}$ é a matriz obtida quando multiplica-se a i -ésima tentativa $E_i \in \mathbb{R}^{S \times T_s}$ pela matriz de transformação $W^T \in \mathbb{R}^{S \times S}$. S e T representam o número de eletrodos e o tamanho do sinal coletado por eletrodo em cada teste, respectivamente. As matrizes de correlação de cada rótulo são usadas para encontrar a matriz de transformação W , definida por

$$\Sigma^{(c)} = \frac{1}{N_c} \sum_n^{N_c} E_n^{(c)} E_n^{(c)T} \quad (3.6)$$

onde $\Sigma^{(c)} \in \mathbb{R}^{S \times S}$ é a matriz de correlação entre os eletrodos, N_c é o número de amostras de treinamento da classe C e $E_n^{(c)}$ é a n -ésima amostra de treinamento da classe C . A maximização é restrita para que a soma das matrizes diagonais formadas pelos autovalores seja igual à matriz identidade, ou seja, $\Lambda^{(1)} + \Lambda^{(2)} = I$. Este problema é equivalente a resolver o problema generalizado dos autovalores, definido como

$$\Sigma^{(1)} W = (\Sigma^{(1)} + \Sigma^{(2)}) W \Lambda \quad (3.7)$$

Finalmente, a seguinte equação é aplicada a Z para extrair suas características:

$$f_i = \log \left(\frac{\text{diag}(Z_i Z_i^T)}{\text{tr}(Z_i Z_i^T)} \right) \quad (3.8)$$

onde f_i representa o vetor de características de Z_i , e $\text{diag}(\cdot)$ e $\text{tr}(\cdot)$ representam a diagonal principal e o traço da matriz, respectivamente. O número de filtros CSP é igual ao número de eletrodos. No entanto, apenas os $m/2$ primeiros e últimos filtros são utilizados. Como o CSP maximiza a variância da classe 1 nos primeiros autovetores e da classe 2 nos últimos, um vetor de características v_i é criado, onde seus elementos são os $m/2$ primeiros componentes e $m/2$ componentes finais de f_i .

3.8 CLASSIFICADOR

O classificador é a última etapa do *pipeline* BCI, responsável por identificar e categorizar padrões a partir das características extraídas dos sinais brutos. Seu objetivo é tomar decisões com base nos dados processados, permitindo a distinção entre diferentes classes ou estados de interesse. A escolha do método de classificação depende do tipo de dados e da complexidade do problema, buscando equilibrar acurácia e eficiência computacional. Essa seção apresenta a técnica escolhida para este trabalho, que é a Análise Discriminante Linear, escolhida por sua simplicidade e eficiência computacional.

3.8.1 ANÁLISE DISCRIMINANTE LINEAR

A Análise Discriminante Linear (LDA) é um método supervisionado usado para classificação e redução de dimensionalidade. Seu objetivo é encontrar uma combinação linear de características (variáveis) que separem da melhor maneira possível duas ou mais classes de um conjunto de dados. O LDA busca encontrar vetores de projeção que maximizem a separação entre as médias das classes (dispersão entre classes) e minimizem a dispersão dentro de cada classe (dispersão intraclasse). Ou seja, ele busca um vetor de projeção w que maximize a razão de fisher dada por:

$$J(w) = \frac{w^T S_B w}{w^T S_W w} \quad (3.9)$$

onde S_B é a dispersão entre classes e S_W é a dispersão interclasse, definidas respectivamente por:

$$S_B = \sum_{i=1}^C N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (3.10)$$

$$S_W = \sum_{i=1}^C \sum_{x \in C} (x - \mu_i)(x - \mu_i)^T \quad (3.11)$$

onde C é o número de classes, N_i é o número de amostras na classe i , μ_i é a média da classe i , μ é a média global. Nesse contexto, w é proporcional à inversa da matriz de dispersão interclasse vezes a diferença entre as médias das classes.

3.9 DATASET


O conjunto de dados Physionet [Goldberger et al. 2000] foi utilizado para realizar os experimentos. Esse conjunto de dados contém os dados registrados de 109 indivíduos que sofreram algum tipo de AVC, com 14 sessões por indivíduo. A aquisição foi realizada utilizando um EEG com taxa de amostragem de 160 Hz e 64 eletrodos monopolares, baseados no sistema de eletrodos 10-10 [Nuwer 2018].

Para as 2 primeiras sessões, foi registrada uma linha de base com os olhos abertos e fechados, sem nenhuma tarefa a ser executada. Essa linha foi posteriormente utilizada para retirar os sinais gerados pelos olhos abertos e fechados dos sinais posteriores. Para outras sessões, há 2 gravações diferentes por sessão. As gravações, bem como os índices das sessões, são as seguintes:

- Movimento do punho esquerdo e direito: 3, 7, 11
- Visualização motora do punho esquerdo e direito: 4, 8, 12
- Movimento dos dois punhos e dos dois pés: 5, 9, 13
- Visualização motora dos dois punhos e dos dois pés: 6, 10, 14

Cada sessão com uma tarefa tem 15 tentativas e cada tentativa tem 8 segundos. A sugestão para a tarefa é apresentada por 1 segundo, seguida por 3 segundos de execução da tarefa. Além disso, há um intervalo de 4 segundos entre cada tentativa. As etapas de cada tentativa são mostradas na Figura 5.

Figura 5: Esquema de cronometragem de um ensaio do conjunto de dados PhysionetMI




Fonte: Elaborado pelo autor

4 TRABALHO PROPOSTO

Um filtro temporal melhora a relação sinal-ruído e, quando aplicado aos dados, pode criar um novo conjunto de dados filtrados. Tradicionalmente, os dados são trabalhados como uma única banda. Ao dividir os dados em várias bandas, é possível aplicar o filtro temporal paralelamente. Neste trabalho, propomos esses filtros com EA para avaliar suas combinações. O CSP é adotado como modelo base, pois é uma abordagem de classificação padrão para MI [He e Wu 2020]. Como o EA pode ser utilizado como uma filtragem espacial, ele pode ser aplicado antes ou depois da filtragem temporal, mas sempre antes da classificação. Propomos aqui duas maneiras de usar EA com filtragem multibanda: usando o EA antes e depois do filtro multibanda. Além disso, pode-se observar que muitos filtros multibanda podem ser usados. Este trabalho se concentra nos modelos de filtros temporais apresentados na Seção 3.6. Os pipelines descritos na Figura 6 estão em ordem: o modelo base com EA [He e Wu 2020], o uso de um filtro temporal antes da etapa de EA e a aplicação de EA antes do filtro temporal. Conforme mostrado na Figura 6, usamos LDA como classificador [Lotte et al. 2007, Lotte et al. 2018].

Figura 6: Literatura e arquiteturas propostas usando Alinhamento Euclidiano



Fonte: Elaborado pelo autor.

5 EXPERIMENTOS COMPUTACIONAIS

Realizamos os experimentos para avaliar as propostas no Capítulo 4. Uma validação cruzada estratificada de 5 *folds* foi realizada para avaliar as abordagens propostas. O teste estatístico não paramétrico de Kruskal-Wallis foi utilizado como teste multigrupo, seguido pelo teste de Dunn como post-hoc com correção de Bonferroni.

Esta seção está dividida da seguinte forma: Inicialmente, apresentamos o conjunto de dados utilizado nos experimentos. Depois, definimos os valores para os parâmetros utilizados em cada modelo. Então, apresentamos os resultados para os casos de 3 e 8 eletrodos. Finalmente, é apresentado um Perfil de Desempenho dos experimentos.

5.1 PARÂMETROS

Os experimentos computacionais foram realizados com dois subconjuntos de posições de eletrodos:

- 3 eletrodos: C3, Cz, C4
- 8 eletrodos: FC3, C3, CP3, FCz, CPz, FC4, C4, CP4

Reduzimos o número de eletrodos nesses dois casos, pois o uso de um número menor de eletrodos torna o tratamento de reabilitação pós-AVC mais confortável para o paciente, mais rápido no treinamento do modelo e menos custoso [Leeb et al. 2007, Souza et al. 2019]. A posição dos eletrodos acima da área motora cerebral é: (i) acima da área motora primária ao usar 3 eletrodos, e (ii) áreas motora, pré-motora e motora suplementar, além daquelas utilizadas (i) ao usar 8 eletrodos [Homan, Herman e Purdy 1987]. As posições desses eletrodos pode ser vista na Figura 7, onde os eletrodos utilizados no subconjunto 3 estão representados pela cor azul e os eletrodos utilizados no subconjunto 8 estão representados pelas cores azul e verde.

Além disso, criamos 2 novas classes: “mão esquerda” e “mão direita”, combinando o movimento e a imaginação motora de cada uma. Apenas essas duas novas classes foram utilizadas, pois é a abordagem mais comum para BCIs de reabilitação pós-AVC.

Todos os dados adquiridos foram reamostrados para 128 Hz usando uma spline cúbica. Ao analisar o conjunto de dados, foram encontradas irregularidades nos testes de EEG dos indivíduos 88, 94 e 101. Essas irregularidades resultaram na remoção desses indivíduos de nossos experimentos computacionais. Assim, os experimentos foram realizados utilizando dados dos 106 indivíduos restantes. A janela de treinamento começou 0,5 segundo após a dica e durou 2 segundos. A mesma janela foi usada para a fase de testes.

foram realizados com as configurações apresentadas na Sessão 4. A Tabela 1 apresenta os resultados para o caso de 3 eletrodos, onde a acurácia para EA-CSP e MB-CSP foi pior do que para EA-(·)-CSP e (·)-EA-CSP, onde $(\cdot) \in \{\text{FB}, \text{EMD}, \text{CWT}\}$. O Banco de Filtros foi o melhor método de filtro temporal, independentemente do uso de EA. EA-FB-CSP superou as demais abordagens. A análise estatística apresentou diferença significativa $p\text{-valor} < 0,001$ para todos os métodos quando comparados a EA-FB-CSP. Além disso, FB-EA-CSP foi o segundo melhor modelo, também com diferença estatística em relação aos demais modelos. Isso indica que o Banco de Filtros é a melhor filtragem temporal avaliada aqui para ser utilizada com EA, independentemente da ordem de sua aplicação no pipeline BCI. Também é possível notar que o uso do EA antes da multibanda obteve melhores resultados em todos os casos testados.

Tabela 1 – Acurácia para o caso de 3 eletrodos.

	Máx	Mín	Mediana	Média $\pm$ std
CSP	0,7222	0,3556	0,5444	0,5384 $\pm$ 0,0756
FB-CSP	0,6667	0,3556	0,5333	0,5262 $\pm$ 0,0668
EMD-CSP	0,6778	0,3444	0,5000	0,4968 $\pm$ 0,0664
CWT-CSP	0,7000	0,3556	0,5111	0,5057 $\pm$ 0,0654
EA-CSP	0,7000	0,4667	0,5556	0,5577 $\pm$ 0,0542
FB-EA-CSP	0,8333	0,5333	0,7111	0,7109 $\pm$ 0,0552
EMD-EA-CSP	0,7556	0,4889	0,6333	0,6308 $\pm$ 0,0530
CWT-EA-CSP	0,7333	0,4556	0,5889	0,5934 $\pm$ 0,0509
EA-FB-CSP	0,9444	0,7000	0,8000	0,7998 $\pm$ 0,0464
EA-EMD-CSP	0,7889	0,5667	0,6889	0,6884 $\pm$ 0,0465
EA-CWT-CSP	0,8111	0,6000	0,6889	0,6906 $\pm$ 0,0488

5.3 RESULTADOS USANDO 8 ELETRODOS

Também testamos os modelos com 8 eletrodos e seus resultados são apresentados na Tabela 2. Os resultados são semelhantes aos do caso com 3 eletrodos. A EA-FB-CSP superou as demais abordagens, o uso da EA antes da multibanda teve um desempenho melhor do que a aplicação da EA em outra ordem do *pipeline* BCI, e o Banco de Filtros é o modelo de filtro temporal com o melhor resultado. Assim como no caso com 3 eletrodos, o valor de p para EA-FB-CSP foi menor que 0,001, quando comparado a cada um dos outros modelos.

Ao comparar as duas configurações de eletrodos, o uso de 3 eletrodos obteve melhores resultados do que com 8 eletrodos em todos os casos. Essa diferença entre 3 e 8 eletrodos foi estatisticamente significativa para todos os modelos. Da mesma forma que no caso com 3 eletrodos, o *pipeline* EA-MB-CSP foi mais robusto do que os outros dois


modelos de *pipeline* utilizados. Os resultados indicaram que o uso da EA como primeira etapa do *pipeline* do BCI torna o modelo mais robusto entre os sujeitos.

Tabela 2 – Acurácia para o caso de 8 eletrodos.

	Máx	Mín	Mediana	Média $\pm$ std
CSP	0,6667	0,3222	0,5111	0,5055 $\pm$ 0,0740
FB-CSP	0,6667	0,3778	0,5111	0,5122 $\pm$ 0,0587
EMD-CSP	0,6444	0,3556	0,4889	0,4899 $\pm$ 0,0685
CWT-CSP	0,6444	0,3333	0,5000	0,5042 $\pm$ 0,0591
EA-CSP	0,6889	0,4667	0,5111	0,5226 $\pm$ 0,0370
FB-EA-CSP	0,7778	0,5333	0,6778	0,6706 $\pm$ 0,0510
EMD-EA-CSP	0,7222	0,4889	0,5833	0,5862 $\pm$ 0,0523
CWT-EA-CSP	0,6778	0,4444	0,5556	0,5623 $\pm$ 0,0468
EA-FB-CSP	0,8333	0,6000	0,7333	0,7268 $\pm$ 0,0453
EA-EMD-CSP	0,7556	0,5333	0,6469	0,6501 $\pm$ 0,0462
EA-CWT-CSP	0,8111	0,5556	0,6667	0,6660 $\pm$ 0,0514

5.4 ANALISE DOS PERFIS DE PERFORMANCE

Figura 8: Perfis de desempenho dos resultados



Fonte: Elaborado pelo autor.

Os perfis de desempenho (PPs) foram utilizados para realizar uma análise geral referente ao valor de acurácia [Souza et al. 2019], onde cada par (sujeito, caso do eletrodo) foi considerado um problema. Os PPs apresentam a porcentagem de problemas foram resolvidos com menos de τ vezes o melhor valor para cada problema. A Figura 8 contém as curvas dos PPs referentes aos resultados dos 11 métodos avaliados neste trabalho. As

seguintes conclusões podem ser destacadas: (i) EA-FB-CSP foi o modelo com o melhor resultado para a maioria dos casos, pois apresentou o maior valor para $\tau = 1$ (cerca de 90% dos 212 problemas). (ii) EA-FB-CSP obteve o melhor desempenho geral no caso médio, pois esta abordagem atingiu a maior área sob a curva do PP; e (iii) EA-FB-CSP é o método mais robusto, com no máximo 10% pior que o melhor caso para um problema. Outros resultados que podem ser observados nos PPs são: (i) FB-EA-CSP foi o segundo método com o resultado médio, mas o 4º método mais robusto; (ii) os 3 casos mais robustos usaram EA antes da multibanda; e (iii) EA-CSP foi melhor e mais robusto do que todos os casos que não usaram EA.

6 DISCUSSÃO

Todos os modelos, no caso de 3 eletrodos, obtiveram melhores resultados do que seus equivalentes no caso de 8 eletrodos. Pode-se observar que a quantidade de eletrodos aumenta a dimensionalidade para o LDA sem informações relevantes para o caso abordado, levando a resultados piores. O LDA tem melhor desempenho quando o número de tentativas por volume no espaço de busca é alto o suficiente para preenchê-lo. Quando a dimensão aumenta, o espaço de busca se torna maior e menos denso. Isso explica porque os modelos no caso de 3 eletrodos apresentam melhores resultados do que no caso de 8 eletrodos. Da mesma forma, o FBCSP separa algumas características para o LDA, pois possui uma etapa de seleção de características, o que melhora o desempenho do modelo.

O pipeline BCI padrão é formado pelas seguintes etapas: Filtragem Temporal, Filtragem Espacial, Extração de Características, Seleção de Características e Classificador. O EA pode ser representado como um filtro espacial devido à sua transformação linear no sinal de entrada. Portanto, melhores resultados são esperados quando o EA é utilizado após a filtragem temporal, como no pipeline BCI. No entanto, os resultados encontrados nos experimentos demonstram o oposto, levando a questionamentos quanto à ordem do estágio BCI. Filtros espaciais antes da etapa temporal podem resultar em novas configurações para o pipeline BCI. Um exemplo é o uso de CSP antes do filtro temporal, com o EA, ou mesmo para problemas intrassujeito. O Banco de Filtros foi o melhor filtro temporal testado aqui. Este resultado é esperado, pois ele utiliza o sinal em sub-bandas de frequência, sendo capaz de selecionar separadamente os ritmos μ (8-13) e β (13-30), o que é crucial para atividades de imagens motoras. As outras técnicas de filtragem temporal aplicadas neste trabalho não utilizam o espectro do sinal de forma tão eficaz, o que explica seus resultados em comparação com o Banco de Filtros.

EA alinha todos os dados de entrada, reduzindo a discrepância entre eles. Isso melhora a robustez do modelo, enquanto a filtragem temporal melhora o desempenho médio do modelo. Por operarem em regiões distintas dos sinais, os dois métodos permitem uma melhora nos resultados obtidos em comparação com o uso individual. Os modelos sem EA não obtiveram bons resultados devido ao baixo número de ensaios por sujeito no conjunto de dados. No entanto, isso não define a qualidade desses *pipelines*, pois eles ainda apresentam vantagens em diversas situações e não podem ser negligenciados para o caso intrassujeito.

7 CONCLUSÃO

Modelos de MI baseados em BCI podem ser usados para reabilitação pós-AVC. Apesar disso, existem algumas dificuldades, como longos períodos de calibração durante a fase de treinamento e baixa resolução do sinal obtido. Propusemos o Alinhamento Euclidiano (EA) com filtros temporais multibanda para reduzir o impacto dessas duas condições. Os modelos foram criados usando Banco de Filtros, Decomposição de Modos Empíricos e Wavelet Contínua como técnicas de filtro temporal. Cada modelo usa um desses filtros temporais, antes ou depois do EA.

Avaliamos os modelos em 2 casos: com 3 e 8 eletrodos no conjunto de dados PhysionetMI. Os modelos usados neste trabalho demonstram como o EA e os filtros temporais multibanda podem ser usados em conjunto para obter modelos mais robustos. Eles também demonstram que alterar a ordem das etapas pode melhorar a qualidade das soluções. O melhor modelo nos experimentos computacionais realizados aqui é o EA-FB-CSP-LDA, ou seja, o modelo que utiliza o Alinhamento Euclidiano antes do Banco de Filtros, com uma melhoria de aproximadamente 44% para três eletrodos e 43% para oito eletrodos quando comparado ao EA-CSP-LDA, atingindo uma acurácia de 80% e 73,33%, respectivamente. O EA antes da filtragem temporal apresentou resultados melhores do que os obtidos pelos modelos com EA após a filtragem temporal. Além disso, o Banco de Filtros apresentou o melhor desempenho.

Os resultados dos modelos no caso de três eletrodos foram melhores do que os modelos treinados com dados de oito eletrodos. Esse resultado é bom para a reabilitação pós-AVC, pois poucos eletrodos são melhores devido à redução do tempo de preparação do tratamento e à melhoria do conforto do paciente.

Novos experimentos usando Seleção de Características ou Seleção de Sujeitos podem ser realizados para aprimorar esses resultados. Além disso, os modelos podem ser aplicados a outras situações, como aquelas que utilizam mais eletrodos para novos paradigmas e com mais ensaios por sujeito. Nossos resultados também apontaram que a filtragem espacial antes da filtragem temporal tem grande potencial para novos *pipelines* de BCI.

REFERÊNCIAS

- ABIRI, R. et al. A comprehensive review of eeg-based brain-computer interface paradigms. *Journal of Neural Engineering*, v. 16, n. 1, p. 011001, 2019.
- BASHASHATI, A. et al. A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *Journal of Neural Engineering*, v. 4, n. 2, 2007.
- BIASIUCCI, A. et al. Brain-actuated functional electrical stimulation elicits lasting arm motor recovery after stroke. *Nature Communications*, v. 9, 2018.
- 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, n. 2, p. 153–159, 2006.
- CAO, Z. et al. Partial transfer learning with selective adversarial networks. In: *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2018. p. 2724–2732.
- CHOWDHURY, A. et al. Active physical practice followed by mental practice using bci-driven hand exoskeleton: A pilot trial for clinical effectiveness and usability. *IEEE Journal of Biomedical and Health Informatics*, v. 22, n. 6, p. 1786–1795, 2018.
- DEMSY, O.; ACHANCCARAY, D.; HAYASHIBE, M. Inter-subject transfer learning using euclidean alignment and transfer component analysis for motor imagery-based bci. In: *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. [S.l.]: IEEE, 2021.
- FROLOV, A. A. et al. Post-stroke rehabilitation training with a motor-imagery-based brain-computer interface (bci)-controlled hand exoskeleton: A randomized controlled multicenter trial. *Frontiers in Neuroscience*, v. 11, 2017.
- GAO, Y. et al. Double stage transfer learning for brain-computer interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 31, p. 1288–1297, 2023.
- GOLDBERGER, A. L. et al. Physiobank, physiotoolkit, and physionet: components of a new research resource for complex physiologic signals. *Circulation*, v. 101, n. 23, p. e215–e220, 2000.
- GÓMEZ, M. J.; CASTEJÓN, C.; GARCÍA-PRADA, J. C. Review of recent advances in the application of the wavelet transform to diagnose cracked rotors. *Algorithms*, v. 9, n. 1, p. 19, 2016. Disponível em: <<https://www.mdpi.com/1999-4893/9/1/19>>.
- HAYES, M. K. et al. The influence of gender and age on disability following ischemic stroke: the framingham study. *Journal of Stroke and Cerebrovascular Diseases*, v. 12, n. 3, p. 119–126, 2003.
- HE, H.; WU, D. Transfer learning for brain-computer interfaces: A euclidean space data alignment approach. *IEEE Transactions on Biomedical Engineering*, 2020.
- HOMAN, R. W.; HERMAN, J.; PURDY, P. Cerebral location of international 10-20 system electrode placement. *Electroencephalography and Clinical Neurophysiology*, v. 66, n. 4, p. 376–382, 1987.

- HUANG, N. E. et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings: Mathematical, Physical and Engineering Sciences*, v. 454, n. 1971, p. 903–995, 1998.
- KENG, K. A.; GUAN, C. Eeg-based strategies to detect motor imagery for control and rehabilitation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 25, n. 4, p. 392–401, 2017.
- KENG, K. A. et al. A large clinical study on the ability of stroke patients to use an eeg-based motor imagery brain-computer interface. *Clinical EEG and Neuroscience*, v. 42, n. 4, p. 253–258, 2011.
- KILANI, S.; AGHILI, S. N.; HULEA, M. Enhancing p300-based brain-computer interfaces with hybrid transfer learning: A data alignment and fine-tuning approach. *Applied Sciences*, v. 13, n. 10, 2023.
- KILANI, S. et al. Reducing calibration time using novel hybrid transfer-learning for p300-based bci applications. In: *International Symposium on Communication Systems, Networks and Digital Signal Processing (CSNDSP)*. [S.l.]: IEEE, 2022.
- KONONENKO, I. Estimating attributes: Analysis and extensions of relief. In: *Machine Learning: ECML-94*. [S.l.]: Springer, 1994. (Lecture Notes in Computer Science, v. 784), p. 171–182.
- LEEB, R. et al. Brain-computer communication: Motivation, aim, and impact of exploring a virtual apartment. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 15, n. 4, p. 473–482, 2007.
- LI, Y. et al. Transfer learning based on hybrid riemannian and euclidean space data alignment and subject selection in brain-computer interfaces. *IEEE Access*, v. 9, p. 18620–18631, 2021.
- LOTTE, F. et al. A review of classification algorithms for eeg-based brain-computer interfaces. *Journal of Neural Engineering*, v. 4, n. 2, p. R1–R13, 2007.
- LOTTE, F. et al. A review of classification algorithms for eeg-based brain-computer interfaces: a 10 year update. *Journal of Neural Engineering*, v. 15, n. 3, 2018.
- MANE, R.; CHOUHAN, T.; GUAN, C. Bci for stroke rehabilitation: Motor and beyond. *Journal of Neural Engineering*, v. 17, n. 4, 2020.
- NUWER, M. R. 10-10 electrode system for eeg recording. *Clinical Neurophysiology*, v. 129, n. 4, p. 668–669, 2018.
- PACHECO-BARRIOS, K. et al. Burden of stroke and population-attributable fractions of risk factors in latin america and the caribbean. *Journal of the American Heart Association*, v. 11, n. 21, 2022.
- PAPAGEORGIOU, T. D. et al. Brain-computer interfaces increase whole-brain signal to noise. *Proceedings of the National Academy of Sciences*, v. 110, n. 33, p. 13630–13635, 2013.

- SOUZA, G. H. de et al. Differential evolution based spatial filter optimization for brain-computer interface. In: *Genetic and Evolutionary Computation Conference*. [S.l.]: ACM, 2019.
- TANGERMANN, M. et al. Review of the bci competition iv. *Frontiers in Neuroscience*, v. 6, p. 55, 2012.
- VELASCO-ÁLVAREZ, F.; RON-ANGEVIN, R.; LÓPEZ-GORDO, M. Bci-based navigation in virtual and real environments. In: *Advances in Computational Intelligence*. [S.l.]: Springer, 2013. p. 525–534.
- WANG, X.; YANG, R.; HUANG, M. An unsupervised deep-transfer-learning-based motor imagery eeg classification scheme for brain-computer interface. *Sensors*, v. 22, n. 6, 2022.
- WEI, Q.; DING, X. Intra-and inter-subject common spatial pattern for reducing calibration effort in mi-based bci. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 31, p. 1040–1049, 2023.
- WU, D.; JIANG, X.; PENG, R. Transfer learning for motor imagery based brain-computer interfaces: A tutorial. *Neural Networks*, v. 153, p. 235–253, 2022.
- WU, X. et al. Improving neucube spiking neural network for eeg-based pattern recognition using transfer learning. *Neurocomputing*, v. 528, p. 1–12, 2023.
- XIONG, W.; WEI, Q. Reducing calibration time in motor imagery-based bcis by data alignment and empirical mode decomposition. *PLoS ONE*, v. 17, n. 1, 2022.
- XU, L. et al. Enhancing transfer performance across datasets for brain-computer interfaces using a combination of alignment strategies and adaptive batch normalization. *Journal of Neural Engineering*, v. 18, n. 5, 2021.
- YING, J.; WEI, Q.; ZHOU, X. Riemannian geometry-based transfer learning for reducing training time in c-vep bcis. *Scientific Reports*, v. 12, n. 1, 2022.
- ZANINI, P. et al. Transfer learning: A riemannian geometry framework with applications to brain-computer interfaces. *IEEE Transactions on Biomedical Engineering*, v. 65, n. 5, p. 1107–1116, 2018.
- ZHANG, X. et al. Multi-source geometric metric transfer learning for eeg classification. *Biomedical Signal Processing and Control*, v. 79, 2023.
- ZHENG, L.; SCHIEBER, M. H. Neuronal activity distributed in multiple cortical areas during voluntary control of the native arm or a brain-computer interface. *eNeuro*, v. 7, n. 6, 2020.