



UNIVERSIDADE FEDERAL DO PARÁ
NÚCLEO DE DESENVOLVIMENTO AMAZÔNICO EM ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

VITOR MENDES VILAS BOAS

**AUTOBCI: INTERFACE CÉREBRO MÁQUINA COM
CONFIGURAÇÃO HIPERPARAMÉTRICA AUTOMATIZADA**

Tucuruí

2021

VITOR MENDES VILAS BOAS

**AUTOBCI: INTERFACE CÉREBRO MÁQUINA COM
CONFIGURAÇÃO HIPERPARAMÉTRICA AUTOMATIZADA**

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada do Núcleo de desenvolvimento Amazônico em Engenharia, da Universidade Federal do Pará, como requisito para a obtenção do título de Mestre em Computação Aplicada.

Orientador: Prof. Dr. Cleison Daniel Silva
Coorientador: Prof. Dr. Otávio Noura Teixeira

Tucuruí

2021

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

- V695a Vilas Boas, Vitor Mendes.
AutoBCI : interface cérebro-máquina com configuração
hiperparamétrica automatizada / Vitor Mendes Vilas Boas. —
2021.
247 f. : il. color.
- Orientador(a): Prof. Dr. Cleison Daniel Silva
Coorientador(a): Prof. Dr. Otávio Noura Teixeira
Dissertação (Mestrado) - Universidade Federal do Pará,
Núcleo de Desenvolvimento Amazônico em Engenharia,
Programa de Pós-Graduação em Computação Aplicada,
Tucuruí, 2021.
1. Interface cérebro-máquina. 2. Imagética motora.
3. Eletroencefalografia. 4. Otimização de
hiperparâmetros. 5. Aprendizagem Bayesiana. I. Título.

CDD 006.31

VITOR MENDES VILAS BOAS

AUTOBCI: INTERFACE CÉREBRO MÁQUINA COM CONFIGURAÇÃO HIPERPARAMÉTRICA AUTOMATIZADA

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada do Núcleo de desenvolvimento Amazônico em Engenharia, da Universidade Federal do Pará, como requisito para a obtenção do título de Mestre em Computação Aplicada.

Data da Defesa: 11 de Março de 2021

Conceito: Aprovado

Banca Examinadora:

Prof. Dr. Cleison Daniel Silva
PPCA/NDAE/UFPA - Orientador

Prof. Dr. Otávio Noura Teixeira
PPCA/NDAE/UFPA - Coorientador

Prof. Dr. Raphael Barros Teixeira
PPCA/NDAE/UFPA - Membro Interno

Prof. Dr. Antonio da Silva Silveira
PPGEE/I TEC/UFPA - Membro Externo



Emitido em 11/03/2021

DISSERTAÇÃO Nº FOLHA DE APROVAÇÃO/2021 - NDAE (11.16.16)
(Nº do Documento: 1)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 17/03/2021 18:28)

ANTONIO DA SILVA SILVEIRA
PROFESSOR DO MAGISTERIO SUPERIOR
ITEC (11.41)
Matrícula: 1930123

(Assinado digitalmente em 17/03/2021 16:57)

CLEISON DANIEL SILVA
PROFESSOR DO MAGISTERIO SUPERIOR
CTUCU (11.16)
Matrícula: 1643262

(Assinado digitalmente em 17/03/2021 23:13)

OTAVIO NOURA TEIXEIRA
PROFESSOR DO MAGISTERIO SUPERIOR
CTUCU (11.16)
Matrícula: 2143534

(Assinado digitalmente em 18/03/2021 20:17)

RAPHAEL BARROS TEIXEIRA
PROFESSOR DO MAGISTERIO SUPERIOR
CTUCU (11.16)
Matrícula: 1805609

Para verificar a autenticidade deste documento entre em <https://sipac.ufpa.br/documentos/> informando seu número: **1**, ano: **2021**, tipo: **DISSERTAÇÃO**, data de emissão: **17/03/2021** e o código de verificação: **eb3561f36b**

Este trabalho é dedicado à minha amada família, em especial ao meu pai que sempre permanecerá vivo em nossos corações.

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me concedido saúde e sabedoria para lidar com todos desafios ao longo dessa jornada.

À minha família pelo carinho, compreensão e apoio incondicional, em especial minha mãe Ana Maria, meu filho Arthur e minha esposa Josiane. Vocês sempre serão minhas fontes de força e motivação.

Aos meus pais Ana e Wilson pelo afeto e por todo o sacrifício diário em prol de nos oferecer conforto, moral e educação.

Ao meu orientador Prof. Dr. Cleison Daniel Silva pela disponibilidade, paciência e palavras de incentivo bem como pelos ensinamentos imprescindíveis os quais levarei por toda a minha vida.

Ao Prof. Dr. Otávio Noura Teixeira, pela coorientação e pelos ótimos conselhos dados no decorrer do mestrado.

À todos os demais professores do PPCA/NDAE/UFPA que de alguma forma contribuíram para o meu desenvolvimento intelectual e acadêmico.

Aos amigos de mestrado Laercio Pontin e Jhoanyn Calvino pela parceria, assim como, aos colegas do grupo de pesquisa Tayla Silva, Vitor Jorge e William Machado com os quais tive o prazer de conviver durante este período.

À Rafael Mendes Duarte pela disponibilização do material base para implementação do sistema proposto neste trabalho.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Tocantins (IFTO) pelo suporte logístico e financeiro que viabilizaram a realização do mestrado, e à todos os seus servidores que tanto colaboraram para o meu crescimento profissional.

À todas as pessoas que direta ou indiretamente contribuíram para que este objetivo fosse alcançado.

“Tudo, antes de ser fácil, é difícil.”
(Thomas Fuller)

RESUMO

Interfaces Cérebro-Máquina baseadas em Imagética Motora (ICM-IM) permitem o controle de dispositivos independente do uso de nervos e músculos periféricos, a partir da modulação voluntária da atividade eletrofisiológica do cérebro. O desafio imposto à ICM-IM não invasivas típicas é extrair padrões que descrevam a intenção motora nos sinais coletados por eletroencefalografia (EEG) e classificá-los a fim de se gerar comandos confiáveis à aplicação. Para tanto a seleção de técnicas de processamento adequadas assim como a parametrização correta do sistema são fundamentais no ajuste de modelos de classificação eficazes. A configuração dos múltiplos hiperparâmetros na cadeia de processamento, comumente realizada de forma manual e inespecífica do usuário, tende a gerar modelos rígidos e incapazes de generalizar bem em diferentes indivíduos, em especial pela alta variabilidade dos padrões de IM observada entre eles. O uso de estratégias para estimativa desses hiperparâmetros conforme as especificidades do sujeito apresenta-se como uma abordagem mais eficaz e tem sido explorada em estudos recentes. Este trabalho propõe uma estrutura baseada em aprendizado *Bayesiano* para configuração automática de hiperparâmetros incorporada à uma nova plataforma computacional ICM-IM de código aberto. O sistema integra todas as etapas básicas da arquitetura de ICM-IM de sub-bandas, desde a aquisição até o controle de uma aplicação virtual. Múltiplas técnicas de processamento compõem um amplo espaço de configuração para busca de instâncias hiperparamétricas particulares que maximizam a performance do sistema e abstraem do usuário a tarefa de ajuste manual. Dados de 72 sujeitos em três conjuntos públicos de EEG foram usados em simulações *off-line* e *on-line* cujo intuito foi validar o funcionamento dos módulos implementados e investigar os efeitos da configuração automática no desempenho de classificação e no controle efetivo da aplicação. Uma melhora expressiva na acurácia de classificação foi observada ao usar modelos provenientes da configuração automática do sistema em comparação à modelos gerados a partir de configurações frequentes na literatura. Os resultados sugerem que a otimização dos hiperparâmetros produz modelos mais assertivos na classificação dos padrões de IM de diferentes usuários e tende a contribuir para um controle mais eficaz da aplicação. Conclui-se que este estudo contribui com o projeto de ICM-IM mais eficazes no reconhecimento dos padrões de IM particulares do usuário ao fornecer um ambiente experimental completo, personalizável e de uso descomplicado pela configuração automatizada. A opção por técnicas mais eficientes no processamento dos sinais também mostrou-se viável e também são consideradas contribuições deste trabalho.

Palavras-chave — Interface Cérebro Máquina. Imagética Motora. Eletroencefalografia. Plataforma de Software. Processamento de Sub-bandas. Configuração Automática. Otimização de Hiperparâmetros. Aprendizagem *Bayesiana*.

ABSTRACT

Motor Imagery-based Brain-Computer Interfaces (MI-BCI) allow control of devices without the use of peripheral nerves and muscles, based on voluntary modulation of brain electrophysiological activity. The challenge imposed on the typical non-invasive MI-BCI is to extract patterns that describe the motor intention in signals collected by electroencephalography (EEG) and classify them to generate reliable commands to the application. For that, the selection of suitable processing techniques as well as the correct parameterization of the system are fundamental in the adjustment of effective classification models. The configuration of multiple hyperparameters in the processing chain, commonly performed manually and unspecified by the user, tends to generate rigid models that are unable to generalize well in different individuals, especially due to the high variability of MI patterns observed among them. The use of strategies to estimate these hyperparameters according to the subject's specificities is presented as a more effective approach and has been explored in recent studies. This work proposes a structure based on Bayesian learning incorporated into a new open source MI-BCI computational platform for automatic configuration of hyperparameters. The system integrates all the basic steps of the ICM-IM subband architecture, from the acquisition to the control of a virtual application. Various processing techniques make up a large configuration space to search for particular hyperparametric instances that maximize system performance and draw the user the manual adjustment task. Data from 72 subjects in three public EEG sets were used in offline and online simulations, whose goal was to validate the operation of the implemented modules and to investigate the effects of the automatic configuration on the classification performance and on the effective control of the application. A significant improvement in the accuracy of classification was observed when using automatic configuration based models of the system compared to models generated from frequent configurations in the literature. The results suggest that the optimization of hyperparameters produces more assertive models in the classification of IM patterns of different users and tends to contribute to a more effective control of the application. It is concluded that this study contributes to the design of ICM-IM more effective in recognizing the user's particular IM patterns by providing a complete experimental environment, customizable and uncomplicated to use by automated configuration. The option for more efficient techniques in signal processing also proved to be viable and are also considered contributions of this work.

Keywords — Brain-Computer Interface. Motor Imagery. Electroencephalography. Software Platform. Sub-band Processing. Automated Configuration. Hyperparameter Optimization. *Bayesian Learning*.

LISTA DE ILUSTRAÇÕES

- Figura 1 – Estrutura básica de um neurônio. O corpo celular controla o metabolismo na estrutura da célula, enquanto que o axônio ramifica-se através dos dendritos para se comunicar com outras células ou órgãos a partir de sinapses nervosas 33
- Figura 2 – Regiões funcionais do córtex cerebral com representação das áreas sensoriais para percepção, áreas motoras para coordenação de movimentos e áreas de associação para integração de informações. 35
- Figura 3 – Representação clássica do homúnculo de Penfield para as áreas do córtex motor responsáveis pela ativação motora de diferentes regiões corporais. A região em destaque, antecipa a área do córtex motor associada às tarefas motoras de interesse específico deste trabalho. 36
- Figura 4 – Representação temporal de um segmento de EEG multicanal 40
- Figura 5 – Segmento de sinal de EEG proveniente de canal único nos domínios do tempo (a) e da frequência (b) com representação espectral equivalente ao ritmo cerebral μ_r 42
- Figura 6 – A curva contínua, construída a partir da média de várias repetições do experimento de sensor único, ilustra a amplitude do pico que descreve o P300 em relação a sua ausência na onda pontilhada. 45
- Figura 7 – Espectro de sinal de EEG representando a informação em frequência associada aos potenciais SSVEP gerados por estímulo visual a partir de led piscando a 7Hz. Nota-se a representação através dos picos na frequência fundamental e nas duas primeiras harmônicas 46
- Figura 8 – (a) Exemplo do fenômeno ERD/ERS ao longo de 1 segundo. A linha vertical indica o início da IM (b) mapa topográfico da distribuição da energia do sinal no escalpo durante a IM das mãos esquerda e direita, ao considerar os ritmos sensório-motores 48
- Figura 9 – (a) Visão topográfica da energia dos sinais com o usuário em repouso, ou seja, sem realizar tarefa motora e (b) quando está envolvido em uma tarefa motora, neste caso, movimento da mão esquerda. Em (c) é apresentado o espectro de frequência dos sinais provenientes de um canal localizado no hemisfério direito sincronizado aos eventos em (a) (curva tracejada) e em (b) (curva sólida). 49
- Figura 10 – ICM aplicada ao ensino de crianças com TDAH utilizando imersão virtual 51

Figura 11 – Diagrama funcional de um sistema ICM-IM típico. Nas etapas de aquisição e processamento são empregadas ferramentas que possibilitam o controle de aplicações a partir do reconhecimento de padrões nos sinais de EEG.	52
Figura 12 – Exemplos de amplificadores de baixo custo e baseados em tecnologia sem fio para coleta dos sinais de EEG. Da esquerda para a direita, os dois primeiros são versões disponibilizadas pela empresa <i>Emotiv</i> que se diferenciam pelo número de eletrodos e cobertura das áreas corticais enquanto que o último ilustra um amplificador <i>OpenBCI</i>	54
Figura 13 – Sistema internacional 10-20 para padronização do posicionamento de eletrodos no escalpo	56
Figura 14 – Cronologia baseada no protocolo <i>Graz</i> . Uma sequência com duração média de 8 segundos é iniciada com um breve alerta sonoro junto à fixação de uma cruz na tela. Entre 2 e 3,25 uma seta indica qual tarefa de IM deve ser realizada nos 4 segundos subsequentes enquanto a cruz fixa permanecer na tela. Um período de pausa para descanso de até 2,5 segundos estabelece a transição entre dois ensaios consecutivos.	58
Figura 15 – Fases de operação em sistemas de ICM-IM. Um conjunto de treinamento suficientemente grande, composto por segmentos de EEG e seus respectivos rótulos de classes IM, é usado para ajustar os algoritmos e criar um modelo de classificação que em seguida pode ser usado na classificação de novos segmentos de EEG	60
Figura 16 – Janela temporal iniciada 0,5 segundo após a dica visual e com largura de 2 segundos a qual é tipicamente adotada na extração de épocas de EEG em sistemas de ICM-IM	63
Figura 17 – Diagrama funcional expandido de um sistema ICM-IM. A etapa de pré-processamento compreende sub-etapas sequenciais que visam o aprimoramento dos sinais de entrada para auxiliar no processo de extração das características descritivas e classificação das intenções cognitivas	64
Figura 18 – (a) Segmento de sinal bruto de EEG referente ao canal localizado em C3 (hemisfério esquerdo) com $Q = 250$ amostras; (b) mesmo segmento de sinal, filtrado usando um filtro passa-faixa butterworth de 5 ^a ordem com Δ_f definido entre as frequências de corte $F_l = 8$ e $F_u = 30Hz$	68

Figura 19 – (a) Segmento de sinal bruto de EEG z_p referente ao canal localizado em C4 (hemisfério direito) com $Q = 500$ amostras ($F_s = 250Hz$). (b) Amplitude dos coeficiente DFT obtidos com a aplicação do algoritmo da FFT no sinal bruto z_p . (c) Espectro do sinal z_p após ser filtrado usando um filtro passa-faixa IIR de 5ª ordem com frequências de corte $F_l = 8Hz$ e $F_u = 30Hz$	70
Figura 20 – Disposição em ordem crescente de $P = 62$ autovalores λ associados aos autovetores correspondentes aos filtros espaciais CSP que maximizam a separabilidade entre duas duas classes de IM ($\mathcal{A} =$ IM mão esquerda, $\mathcal{B} =$ IM mão direita). As matrizes \mathbf{C}_A e \mathbf{C}_B são obtidas de épocas extraídas dos sinais do 54º sujeito no conjunto de dados público de EEG denotado por LE (ver seção 5.2.4.3).	75
Figura 21 – Hiperplano de separação entre classes definido pela função de discriminação linear do método LDA. Nesse caso, o sinal da função define a classe à qual o vetor de entrada pertence	81
Figura 22 – Representação de uma SVM linear com margem suave em problema não separável linearmente	85
Figura 23 – Modelo de um perceptron (neurônio artificial k) para processamento dos elementos em um vetor de características \mathbf{x} , composto por pesos sinápticos, um combinador linear e uma função de ativação não linear (tangente hiperbólica).	90
Figura 24 – Estrutura de uma rede MLP com duas camadas ocultas e a camada de saída para problema de classificação binária	92
Figura 25 – Diagrama funcional da cadeia de processamento baseada em sub-bandas (SBCSP), caracterizada pela decomposição dos sinais de entrada em N_s sub-bandas as quais são processadas paralelamente usando o método CSP como referência	96
Figura 26 – Matriz de confusão para um problema de decisão binária, em que denomina-se uma classe como positiva e outra como negativa	100
Figura 27 – Ciclo BO usando Processos <i>Gaussianos</i> em um problema \mathbb{R}^1 . A cada iteração a função de aquisição é maximizada para determinar o novo ponto candidato a ser avaliado pela função objetivo.	109
Figura 28 – Processo metodológico	112

Figura 29 – Visão geral do AutoBCI incluindo o gerenciamento do fluxo de amostras para utilização em duas fases sequenciais: calibração e execução. O modelo ajustado na calibração com ajuda do <i>auto setup</i> é aplicado na classificação de padrões de IM em sinais coletados em tempo real objetivando a tradução em comandos para controle de uma aplicação virtual.	114
Figura 30 – Diagrama esquemático do módulo de aquisição ao atuar no gerenciamento do fluxo de sinais e do protocolo experimental de coleta tanto na fase de calibração quanto na fase de execução	118
Figura 31 – Equipamentos eletrônicos para coleta de EEG integrados ao módulo de aquisição do AutoBCI: (a) visão ampliada da placa <i>Cyton</i> ; (b) placa <i>Cyton</i> em dimensão padrão alimentada por um módulo de baterias; (c) módulo adicional <i>Daisy</i> em dimensão ampliada; (d) <i>dongle</i> USB para comunicação <i>bluetooth</i> e; (e) capacete <i>Ultracortex modelo Mark IV</i> com eletrodos a seco para posicionamento no escalpo	120
Figura 32 – Cadeia de processamento de sub-bandas (SBCSP) implementada no AutoBCI	124
Figura 33 – Extração de épocas de EEG de treinamento com base no par de argumentos que definem uma janela temporal J . Os traços em azul, delimitam a janela típica projetada no protocolo <i>Graz</i> , a qual está localizada à $J_d = 0,5$ segundos após a dica e possui $J_l = 2$ segundos de largura. . .	127
Figura 34 – Projeção dos hiperparâmetros na cadeia de processamento de sub-bandas implementada	130
Figura 35 – Comparativo entre as amostras no sinal $\tilde{\mathbf{x}}_p \in \mathbb{R}^{1 \times Q}$ obtido após filtragem usando um filtro IIR de 5ª ordem com faixa de interesse $\Delta_f \triangleq [8, 16]Hz$ (a) e os termos nas bases senoidal e cossenoidal dos coeficientes $\mathbf{\tilde{x}}_p \in \mathbb{R}^{1 \times M}$ correspondentes às frequências na mesma faixa Δ_f (b). Como ambos foram obtidos de um mesmo sinal bruto \mathbf{Z}_p , coletado a uma frequência de amostragem $F_s = 250Hz$, têm-se $Q = 500$ amostras. Ao mesmo tempo, com uma resolução $\delta_f = \frac{F_s}{Q} = 0,5$ entre <i>bins</i> de frequência consecutivos, têm-se $M = 16$	134
Figura 36 – Diagrama funcional do processo de ajuste do modelo de classificação a partir da configuração automática de hiperparâmetros promovida pelo <i>auto setup</i>	137

Figura 37 – Diagrama esquemático da fase de execução <i>on-line</i> . O amplificador empurra amostras de EEG para as etapas de processamento. Um <i>buffer</i> B armazena as amostras mais recentes e pode ser acessado pelos módulos de processamento de sinal. A cada δ_t segundos, esses módulos processam os dados atualmente em B e realizam uma classificação	138
Figura 38 – Posicionamentos dos sensores de EEG baseado no sistema internacional 10-20 adotados na aquisição dos três conjuntos de dados adotados no trabalho: 2A, 2B e LE. À esquerda as posições circulados em azul correspondem ao 22 eletrodos considerados no conjunto de dados 2A enquanto que o quadrado vermelho indica a posição no escalpo dos 3 eletrodos do conjunto 2B. À direita, os 16 eletrodos convenientemente selecionados são destacados pelo circulo azul em meio à matriz completa de eletrodos associada aos sinais do conjunto LE	144
Figura 39 – Telas do jogo ICM Space Game durante duas tentativas de controle do cursor 1D (nave). O jogo representa a aplicação virtual incorporada ao AutoBCI e é usado no teste de controle <i>on-line</i> da plataforma	148
Figura 40 – Tela inicial da plataforma AutoBCI pela qual é possível ter acesso às funcionalidades do sistema após o registro do usuário	154
Figura 41 – Interface de configuração do modo de aquisição real no AutoBCI. A sequencia numérica indica os passos que devem ser seguidos pelo usuário na preparação do sistema e integração com o <i>hardware</i> de aquisição . . .	156
Figura 42 – Configuração para aquisição simulada no AutoBCI. Na sequencia apresentada, um arquivo com dados públicos de EEG de um dos conjuntos reconhecidos pelo sistema é convertido para formato compreendido pelo AutoBCI e selecionado para reprodução na mesma taxa de amostragem usada durante a coleta original dos sinais, também compatível com as taxas de amostragem do <i>OpenBCI</i>	157
Figura 43 – Interface de configuração do protocolo experimental no AutoBCI. A sequênciã numérica indica os passos a serem seguidos pelo usuário para definição do número de execuções e tentativas para cada tarefa motora bem como a cronologia de eventos de coleta em cada tentativa.	159

Figura 44 – Exemplo de sequência de eventos, equivalente à uma única tentativa de MI, apresentada ao usuário durante a coleta de sinais de EEG usando o protocolo experimental. No início de cada tentativa um sinal sonoro breve é tocado concomitante a apresentação de uma cruz fixa na tela, que neste caso permanece na tela por 2 segundos. Em seguida a dica na forma de uma seta para a direita ou para esquerda define a tarefa motora esperada pelos próximos 4 segundos. Em $t = 6$ o usuário recebe instruções para relaxar durante a pausa curta, até que o processo seja reiniciado na próxima tentativa a partir de $t = 10$	160
Figura 45 – Interface de configuração inicial do procedimento de calibração do modelo de classificação no AutoBCI.	162
Figura 46 – Interface de seleção e configuração manual dos algoritmos para compor a cadeia de processamento do AutoBCI. Os grupos de hiperparâmetros são agrupados conforme as etapas de processamento e os valores definidos na instância apresentada correspondem às definições da cadeia típica de sub-bandas sugerida por (NOVI et al., 2007)	163
Figura 47 – Passos para configuração automática da cadeia de processamento no AutoBCI. Ao ativar o <i>auto setup</i> o sistema seleciona, configura e valida iterativamente múltiplas combinações de técnicas de processamento de forma a compor uma cadeia de processamento adequada ao usuário	165
Figura 48 – Processo de busca pelo conjunto ótimo de hiperparâmetros a partir da busca <i>Bayesiana</i> promovida pelo método <i>auto setup</i> . Diferentes instâncias da cadeia de processamento são avaliadas a fim de se obter uma configuração que maximize a acurácia esperada.	166
Figura 49 – Interface de apresentação dos resultados da validação <i>off-line</i> do modelo de classificação no AutoBCI	167
Figura 50 – Interface de configuração dos parâmetros de controle no AutoBCI. As definições são usadas pelo sistema na tradução das saídas do módulo de processamento em sinais de comando para a aplicação virtual	168
Figura 51 – Interface de configuração dos parâmetros específicos do ICM Space Game. As definições controlam o ambiente e a jogabilidade da aplicação virtual	170
Figura 52 – Telas extraídas durante múltiplas tentativas de controle da aplicação virtual usando IM das mãos direita e esquerda no AutoBCI. A sequência delimita o início e o fim de uma única sessão de controle, da primeira de 20 tentativas até a apresentação dos resultados ao usuário	171

Figura 53 – Registros em inglês obtidos durante uma sessão de controle usando o sistema de aquisição simulada. Os registros relatam o processo de envio de amostras ao <i>Buffer</i> de entrada pelo simulador a partir da leitura do posicionamento do alvo (<i>target</i>) bem como a composição do <i>buffer</i> de decisão pelas saídas de classificação a cada checagem do limiar de comando	173
Figura 54 – Dispersão das acurácias de classificação considerando todos os 72 sujeitos avaliados e comparativo individual entre os respectivos desempenhos obtidos com modelo AS e modelos CMBU (a) e CMSB (b).	177
Figura 55 – Dispersão e distribuição por sujeito dos índices de iterações do <i>auto setup</i> cujas instâncias hiperparamétricas foram responsáveis pelo modelo com máxima acurácia esperada. Os pontos representam o número de iterações necessárias para convergência da busca <i>Bayesiana</i> para cada modelo/sujeito. As cores diferem os sujeitos quanto à base de dados a qual pertencem	180
Figura 56 – Dispersão dos desempenhos em cada uma das $N_{iter} = 100$ iterações da busca <i>Bayesiana</i> no AS. As linhas horizontais representam as acurácias médias entre todos os sujeitos nos três modos de configuração apresentadas na Tabela 4 e os pontos em azul representam a acurácia do modelo definitivo	181
Figura 57 – Janelas J usadas na extração de épocas de treinamento e validação do modelo de classificação cujas propriedades J_d e J_l em relação à dica compuseram as instâncias hiperparamétricas ótimos, \mathbf{h}^* , por sujeito. A faixa em amarelo compreende a janela típica com $J_d = 0,5$ e $J_l = 2$. . .	183
Figura 58 – Distribuição das instâncias ótimas para os hiperparâmetros conforme os valores de domínio de J_D (a) e de J_L (b). A separação por cores indica a proporção de cada conjunto de dados nos percentuais.	184
Figura 59 – Intervalos de frequências Δ_f cujos extremos representados pelas frequências de corte inferior, F_l , e superior, F_u , foram ajustados pelo <i>auto setup</i> ao considerar os dados de treinamento de cada sujeito e o espaço de configuração hiperparamétrica na otimização <i>Bayesiana</i> . As linhas pontilhadas delimitam o intervalo comumente adota em configurações manuais. tal qual $\Delta_f = [8, 30]$ Hz	186
Figura 60 – Distribuição por ritmos cerebrais contemplados entre as instâncias ótimas dos hiperparâmetros de frequência que delimitam o intervalo $\Delta_f = \{F_l, F_u\}$. As cores indicam a proporção de ocorrências para cada conjunto de dados.	187

Figura 61 – Instâncias ótimas obtidas com o <i>auto setup</i> para os hiperparâmetros N_s e N_r , ao considerar dados dos 72 sujeitos avaliados	189
Figura 62 – Distribuição de classificadores pertencentes à \mathcal{H} entre as instâncias ótimas obtidas com o <i>auto setup</i> para os 72 sujeitos avaliados (a) e proporção dos três conjuntos de dados públicos na referida distribuição (b)	191
Figura 63 – Diagrama de caixas para as acurácias médias de validação dos modelos obtidos a partir dos três modos de configuração hiperparamétrica para os 9 sujeitos na base 2A	196
Figura 64 – Diagrama de caixas para as acurácias médias de validação dos modelos obtidos a partir dos três modos de configuração hiperparamétrica para os 9 sujeitos na base 2B	201
Figura 65 – Diagrama de caixas para as acurácias médias de validação dos modelos obtidos a partir dos três modos de configuração hiperparamétrica para os 54 sujeitos na base LE	207
Figura 66 – Dispersão das acurácias de validação dos modelos associados aos 54 sujeitos do conjunto LE e obtidos usando o <i>auto setup</i> (pontos na curva sólida em vermelho) e as abordagens de configuração manual do sistema. Os sujeitos estão posicionados no eixo horizontal em ordem crescente das acurácias do modelo AS para uma melhor comparação entre os desempenhos individuais	208
Figura 67 – Comparativo do tempo médio de ajuste dos modelos de classificação em função do número de sub-bandas ao filtrar os sinais usando IIR ou FFT. As curvas denotam média entre os tempos de ajuste nas 7.200 iterações do <i>auto setup</i> de todos os sujeitos	212
Figura 68 – Comparativo entre as taxas médias de acerto ao alvo (a) e taxas médias de acerto de comando (b) calculadas a partir das tentativas de controle do cursor virtual usando o <i>auto setup</i> e as configurações manual da plataforma AutoBCI. Os pontos representam a projeção das ITRs médias obtidas para os 72 sujeitos usando o CMSB e CMBU nas respectivas ITRs médias associadas ao <i>auto setup</i>	216

LISTA DE TABELAS

Tabela 1	–	Categorização típica dos ritmos da atividade cerebral conforme a banda de frequência e a amplitude	41
Tabela 2	–	Descrição dos hiperparâmetros considerados na composição do espaço de configuração \mathcal{H} . A restrição indica a interdependência entre os hiperparâmetros e atua sobre o respectivo domínio condicional	131
Tabela 3	–	Definições de valor para o conjunto de hiperparâmetros para os dois modos de configuração manual, CMBU e CMSB, ambos usados na validação da plataforma AutoBCI. Os valores foram definidos com base em estudos correlatos, tais quais Ang et al. (2008) e Ang et al. (2012a).	146
Tabela 4	–	Média das acurácias de validação, acm_{γ} usando os três modos de configuração (AS, CMBU e CMSB) e para as três bases públicas de sinais consideradas (2A, 2B e LE). O desvio padrão é usado como medida de dispersão entre os sujeitos	175
Tabela 5	–	Comparativo entre acurácias individuais de generalização dos modelos associados aos sujeitos do conjunto 2A e ajustados usando os dois modos de configuração manual, CMSB e CMBU, e o <i>auto setup</i>	194
Tabela 6	–	Instâncias ótimas do conjunto de hiperparâmetros obtidas com <i>auto setup</i> para os 9 sujeitos do conjunto 2A	196
Tabela 7	–	Comparativo entre a acurácia (%) dos modelos individuais obtidos com o <i>auto setup</i> (AS) e os melhores resultados em estudos citados ao longo deste trabalho os quais usaram o conjunto de dados 2A na avaliação de seus métodos, não necessariamente relacionados à otimização hiperparamétrica em ICM-IM	198
Tabela 8	–	Comparativo entre acurácias individuais de generalização dos modelos associados aos sujeitos do conjunto 2B e ajustados usando CMSB, CMBU, e AS	200
Tabela 9	–	Instâncias ótimas do conjunto de hiperparâmetros obtidas com <i>auto setup</i> para os 9 sujeitos do conjunto 2B	202
Tabela 10	–	Comparativo entre o desempenho de classificação dos modelos obtidos com o <i>auto setup</i> e os melhores resultados em trabalhos validados usando os dados do conjunto 2B na avaliação de seus métodos	203
Tabela 11	–	Acurácias de validação individuais dos modelos associados aos sujeitos do conjunto LE e ajustados usando CMSB, CMBU, e AS. As colunas 5 e 6 denotam os ganhos de desempenho obtidos com o AS em relação às contrapartes de configuração manual	206

Tabela 12 – Instâncias ótimas do conjunto de hiperparâmetros responsáveis pelos maiores e melhores ganhos de desempenho ao aplicar o <i>auto setup</i> em relação às configurações manuais entre os sujeitos da base pública LE .	209
Tabela 13 – Comparativo entre a acurácia (%) dos modelos individuais obtidos com o <i>auto setup</i> e os melhores resultados em estudos citados ao longo deste trabalho os quais usaram o conjunto de dados LE na avaliação de seus métodos, não necessariamente relacionados à otimização hiperparamétrica em ICM-IM	209
Tabela 14 – Acurácias médias de validação e tempos médios de ajuste dos modelos de classificação usando as instâncias ótimas de hiperparâmetros de cada sujeito nos três conjuntos de dados e considerando os dois métodos de filtragem temporal: FFT e IIR.	211
Tabela 15 – Comparativo entre os resultados da simulação de controle <i>on-line</i> usando as médias nas quatro métricas definidas e calculadas com base nos dados de operação obtidos de cada um dos 72 sujeitos e modos de configuração da plataforma AutoBCI	214
Tabela 16 – Relação das maiores e menores diferença entre as taxas médias de acerto ao alvo (ITR_{hit}) associadas ao uso do <i>auto setup</i> e ao uso representaram aumento em relação às os maiores e menores ganhos em ITR da abordagem AS em relação às abordagens de configuração manual.	217

LISTA DE ABREVIATURAS E SIGLAS

AEP	Potencial Auditivo Evocado (do inglês <i>Auditory-Evoked Potential</i>)
ANN	Redes Neurais Artificiais (do inglês <i>Artificial Neural Networks</i>)
AUC	Área Abaixo da Curva (do inglês <i>Area Under Curve</i>)
AVC	Acidente Vascular Cerebral
BCI	<i>Brain-Computer Interface</i>
BO	Otimização <i>Bayesiana</i> (do inglês <i>Bayesian Optimization</i>)
CAR	Referência Média Comum (do inglês <i>Common Average Reference</i>)
CSP	Padrões Espaciais Comuns (do inglês <i>Common Spatial Patterns</i>)
CSSD	Decomposição Espacial de Subespaços Comuns (do inglês <i>Common Spatial Subspace Decomposition</i>)
DFT	Transformada Discreta de Fourier (do inglês <i>Discrete Fourier Transform</i>)
DGNO	Otimização Global para Redes Neurais Profundas (do inglês <i>Deep Networks for Global Optimization</i>)
ECG	Eletrocardiografia
ECoG	Eletrocorticografia
EEG	Eletroencefalografia
EI	Esperança de Melhoria (do inglês <i>Expected Improvement</i>)
ELA	Esclerose Lateral Amiotrófica
EMG	Eletromiografia
EOG	Eletrooculografia
ERP	Potenciais Relacionados à Eventos (do inglês <i>Event-related Potentials</i>)
ERS/ERD	(Des)sincronização Relacionada a Evento (do inglês <i>Event Related (De)synchronization</i>)
ErrP	Potencial Relacionado a Erros (do inglês <i>Error-related Potential</i>)
FFT	Transformada Discreta de <i>Fourier</i> (do inglês, <i>Fast Fourier Transform</i>)

FIR	Resposta Impulsiva Finita (do inglês <i>Finite Impulse Response</i>)
fMRI	Ressonância Magnética funcional (do inglês <i>functional Magnetic Resonance Imaging</i>)
fNIRS	Espectroscopia de Infravermelho Próximo funcional (do inglês <i>Near-Infrared Spectroscopy</i>)
GP	Processos <i>Gaussianos</i> (do inglês <i>Gaussian Processes</i>)
GUI	Interface Gráfica do Usuário (do inglês <i>Graphical User Interface</i>)
HPO	Otimização Hiperparamétrica (do inglês <i>Hyperparameter Optimization</i>)
ICA	Análise de Componentes Independentes (do inglês <i>Independent Component Analysis</i>)
ICM	Interface Cérebro-Máquina
IIR	Resposta Impulsiva Infinita (do inglês <i>Infinite Impulse Response</i>)
IM	Imagética Motora
ITR	Taxa de Transferência de Informação (ITR, do inglês <i>Information Transfer Rate</i>)
KNN	K-ésimos Vizinhos mais Próximos (do inglês <i>K-nearest Neighbors</i>)
LAR	Referência Laplaciana (do inglês <i>Laplacian Reference</i>)
LDA	Análise de Discriminantes Lineares (do inglês <i>Linear Discriminant Analysis</i>)
LFP	Potencial de Campo Local (do inglês <i>Local Field Potential</i>)
LR	Regressão Logística (do inglês <i>Logistic Regression</i>)
M1	Córtex Motor Primário
MEG	Magnetoencefalografia
ML	Aprendizado de Máquina (do inglês <i>Machine Learning</i>)
MLP	Redes Neurais Artificiais Perceptron de Múltiplas Camadas (do inglês <i>Artificial Neural Networks Multi-Layer Perceptron</i>)
OMS	Organização Mundial de Saúde

P300	Potencial positivo que ocorre em torno de 300ms após dado estímulo
PCA	Análise de Componentes Principais (do inglês <i>Principals Component Alalysis</i>)
PI	Probabilidade de Melhoria (do inglês <i>Probability of Improvement</i>)
ROC	Curva Característica de Operação do Receptor (do inglês <i>Receiver Operating Characteristic curve</i>)
SBCSP	Padrões Espaciais Comuns de Sub-banda (do inglês <i>Sub-Band Common Spatial Patterns</i>)
SCP	Potencial Cortical Lento (do inglês <i>Slow Cortical Potential</i>)
SMAC	Modelo Sequencial Baseado em Florestas Aleatórias (do inglês <i>Sequential Model-Based Algorithm Configuration</i>)
SMR	Ritmos Sensório Motores (do inglês <i>Sensorimotor Rhythms</i>)
SMBO	Otimização Baseada em Modelo Sequencial (do inglês <i>Sequential Model-Based Optimization</i>)
SNC	Sistema Nervoso Central
SNP	Sistema Nervoso Periférico
SNR	Relação Sinal-Ruído (do inglês <i>Signal to Noise Ratio</i>)
SSVEP	Potencial Visualmente Evocado em Estado Estacionário (do inglês <i>Steady State Visually Evoked Potential</i>)
STFT	Transformada de <i>Fourier</i> de Tempo Curto (do inglês <i>Short Time Fourier Transform</i>)
SVM	Máquina de Vetores de Suporte (do inglês <i>Support Vector Machines</i>)
TDAH	Transtorno do Déficit de Atenção com Hiperatividade
TPE	Estimador de Parzen com Estrutura em Árvore (do inglês <i>Tree Parzen Estimators</i>)
UCB	Limite de Confiança Superior (do inglês <i>Upper Confidence Bound</i>)

SUMÁRIO

1	INTRODUÇÃO	26
1.1	Definição do problema de pesquisa	27
1.2	Objetivos	29
1.3	Caracterização da pesquisa	30
1.4	Organização do documento e notação	31
2	FUNDAMENTAÇÃO TEÓRICA	32
2.1	Aspectos anatômicos e fisiológicos do cérebro	32
2.2	Técnicas de imageamento da atividade cerebral	36
2.3	Eletroencefalografia (EEG)	39
2.3.1	Ritmos da atividade cerebral	40
2.4	Paradigmas de ICM e biosinais de controle	43
2.5	Aplicações de ICM	50
3	ARQUITETURA FUNCIONAL DE ICM-IM	52
3.1	Aquisição de sinais de EEG	53
3.1.1	Posicionamento de sensores no escalpo	55
3.1.2	Protocolo experimental de coleta	57
3.1.3	Bases públicas de dados	58
3.2	Processamento de sinais de EEG em sistemas de ICM-IM	59
3.2.1	Fases de operação	60
3.2.1.1	Extração de épocas de EEG	61
3.2.2	Pré-processamento e aprimoramento dos sinais	63
3.2.2.1	Filtragem temporal	65
3.2.2.1.1	Filtros digitais de resposta impulsiva	66
3.2.2.1.2	Transformada Discreta de <i>Fourier</i> (DFT)	69
3.2.2.2	Filtragem espacial	71
3.2.2.2.1	Padrões Espaciais Comuns (CSP)	73
3.2.3	Extração de características	76
3.2.4	Classificação	77
3.2.4.1	Análise de Discriminantes Lineares (LDA)	79
3.2.4.2	Regressão Logística (LR)	81
3.2.4.3	Máquina de Vetores de Suporte (SVM)	83
3.2.4.4	K-ésimos vizinhos mais próximos (KNN)	86
3.2.4.5	ANN Perceptron de Múltiplas Camadas (MLP)	89
3.2.5	Processamento baseado em Sub-bandas	95
3.3	Avaliação de desempenho em ICM-IM	98
3.3.1	Acurácia de classificação	99

3.3.2	Matriz de confusão	99
3.3.3	Taxa de transferência de informação (ITR)	101
3.3.4	Outras formas de avaliação	102
4	CONFIGURAÇÃO DE HIPERPARÂMETROS	104
4.1	Otimização hiperparamétrica (HPO)	105
4.2	Otimização <i>Bayesiana</i> (BO)	106
4.2.1	Modelo probabilístico substituto	108
4.2.2	Função de aquisição	110
4.2.3	TPE para otimização de EI	111
5	METODOLOGIA	112
5.1	Experimentação preliminar	113
5.2	Desenvolvimento do sistema	113
5.2.1	Ferramentas e ambiente de implementação	116
5.2.2	Sistema de aquisição de dados	117
5.2.3	<i>Hardware</i> de aquisição integrado	118
5.2.4	Modo de aquisição simulada	120
5.2.4.1	Base de dados <i>BCI Competition IV-2a</i> (2A)	121
5.2.4.2	Base de dados <i>BCI Competition IV-2b</i> (2B)	122
5.2.4.3	Base de dados multi-paradigma (LE)	122
5.2.5	Cadeia de processamento	123
5.2.6	Ajuste do modelo de classificação	125
5.2.6.1	Método de configuração automática de hiperparâmetros: <i>auto setup</i>	128
5.2.6.1.1	Composição dos dados de treinamento e validação	129
5.2.6.1.2	Hiperparâmetros e espaço de configuração	130
5.2.6.1.3	FFT aplicada ao ajuste eficiente do modelo	133
5.2.6.1.4	Função objetivo e avaliação de instâncias	135
5.2.7	Execução e controle <i>on-line</i>	137
5.2.7.1	Estratégia para geração de comandos	139
5.3	Teste e validação	142
5.3.1	Validação de desempenho <i>off-line</i>	144
5.3.2	Teste de controle <i>on-line</i> simulado	146
5.3.2.1	Ambiente virtual de experimentação <i>on-line</i>	147
5.3.2.2	Especificações e procedimentos experimentais	149
5.4	Análise dos Resultados	152
6	PLATAFORMA AUTOBCI	154
6.1	Módulo de Aquisição de Sinais de EEG	155
6.2	Módulo de Processamento	161

6.2.1	Configuração manual do sistema	163
6.2.2	Configuração automática do sistema (<i>auto setup</i>)	164
6.2.3	Ajuste e validação <i>off-line</i> do modelo de classificação	166
6.3	Módulo de Controle	167
7	RESULTADOS E DISCUSSÕES	174
7.1	Resultados de validação <i>off-line</i>	174
7.1.1	Resultados para o conjunto de sujeitos 2A	194
7.1.2	Resultados para o conjunto de sujeitos 2B	200
7.1.3	Resultados para o conjunto de sujeitos LE	205
7.1.4	Análise de eficiência computacional: FFT <i>vs.</i> filtro convencional IIR	210
7.2	Resultados dos testes de simulação <i>on-line</i>	213
8	CONCLUSÕES E PERSPECTIVAS FUTURAS	218
9	PUBLICAÇÕES	225
	REFERÊNCIAS	226
	APÊNDICES	248
A	249

1 INTRODUÇÃO

A busca pela compreensão do funcionamento do cérebro e de como são estabelecidas as conexões neuronais com as demais partes do corpo humano desperta interesse crescente por parte da comunidade científica (SILVERTHORN, 2017). Avanços recentes na neurociência comprovam que a integração com tecnologias computacionais acelerou descobertas e descortinou diversas possibilidades científicas acerca da aplicação do controle cognitivo (ABIRI et al., 2019).

Neste contexto, as Interfaces Cérebro-Máquina (ICM), do termo em inglês *Brain-Computer Interface* – BCI, posicionam-se como sistemas que visam fornecer um canal de comunicação alternativo ao cérebro ao promover uma conexão direta com o mundo externo e independente à qualquer atividade muscular periférica (WOLPAW et al., 2002).

Em suma, sistemas de ICM permitem o envio de mensagens ou comandos à dispositivos à partir da coleta, do processamento e da tradução de sinais biológicos relativos à atividade neuronal (CLERC; BOUGRAIN; LOTTE, 2016a). As alterações na atividade cerebral provocadas de maneira voluntária ou involuntária com a execução de tarefas cognitivas específicas descrevem biosinais mensuráveis e interpretáveis por esses sistemas (NEUPER; KLIMESCH, 2006; GANDHI et al., 2015).

Dentre as formas de indução voluntária de biosinais em sistemas de ICM, a Imagética Motora (IM) destaca-se como uma das mais comuns. Diferentemente de suas contrapartes de potencial evocado, o paradigma de IM não exige estimulação externa e confere autonomia ao usuário para modulação da própria atividade cerebral (CLERC; BOUGRAIN; LOTTE, 2016a). A modulação voluntária nesse caso consiste em gerar padrões de atividade cerebral que descrevam sua intenção motora a partir da simulação mental do movimento de algum membro ligado ao sistema nervoso periférico (SNP), como mãos, pés ou língua, por exemplo (LOTTE, 2014; VAZ, 2016).

O conceito por trás da IM consiste no fato de que a imaginação de um movimento, ativa áreas do cérebro responsáveis pela geração de movimentos reais, em especial na região sensório-motora do córtex, a qual, entre outras funções, controla o sistema neuromuscular incluindo os membros periféricos do corpo humano (GRAIMANN; ALLISON; PFURTSCHELLER, 2010; SILVERTHORN, 2017). Na prática, a realização de uma tarefa de IM específica altera a atividade rítmica do cérebro e o fenômeno conhecido como (Des)Sincronização relacionada a eventos (ERS/ERD, do inglês *Event Related (De)Synchronization*) pode ser mensurado utilizando de técnicas de neuroimagem (PFURTSCHELLER; SILVA, 1999).

Há um número expressivo de técnicas de neuroimagem capazes de medir as oscilações da atividade cerebral tanto de forma invasiva quanto de forma não invasiva. A

eletroencefalografia (EEG) destaca-se como uma das mais eficazes, especialmente quando aplicadas ao escopo de sistemas de ICM devido, principalmente, à alta resolução temporal, ao custo relativamente baixo, à alta portabilidade e ao risco mínimo à integridade física dos usuários proporcionados por esta técnica (NICOLAS-ALONSO; GOMEZ-GIL, 2012; TEPLAN, 2002).

Os sinais de EEG descrevem os potenciais elétricos gerados pela atividade cerebral a partir de eletrodos posicionados diretamente no escalpo e, portanto, sem a necessidade de procedimentos cirúrgicos (TAN; NIJHOLT, 2010). Esses sinais possuem características de amplitude e frequência relativamente definidas, as quais possibilitam o monitoramento da oscilação nos ritmos cerebrais relacionada ao estado mental do indivíduo, com propriedades distinguíveis nos domínios do tempo, do espaço e da frequência conforme a tarefa cognitiva realizada (SILVA et al., 2016; MORASH et al., 2008).

Assim, as Interfaces Cérebro-Máquina baseadas em Imagética Motora (ICM-IM) apoiam-se na relação entre os sinais oscilatórios observados no EEG e o fenômeno ERS/ERD associado à determinada tarefa motora. O objetivo ao desenvolver uma ICM-IM, portanto, é reconhecer padrões que descrevam a intenção motora do indivíduo a partir do processamento dos sinais de EEG e, com isso, gerar mensagens ou sinais de comando sob demanda à uma aplicação (NICOLAS-ALONSO; GOMEZ-GIL, 2012; LOTTE et al., 2018).

A arquitetura de uma ICM-IM compreende algoritmos de processamento de sinais e reconhecimento de padrões geralmente dispostos em cadeia, formando cinco estágios consecutivos: aquisição, aprimoramento de sinal, extração de características, classificação e interface de controle (KHALID et al., 2009; VAZ, 2016).

Diferentes técnicas de processamento e aprendizado de máquina têm sido constantemente propostas a fim de melhorar o processo de decodificação das propriedades do sinal de EEG que definem a intenção motora do indivíduo em sistemas de ICM-IM (LOTTE, 2014; BASHASHATI et al., 2007). Abordagens baseadas em bancos de filtros com decomposição dos sinais em sub-bandas de frequência, comprovadamente mais assertivas na classificação de IM em comparação à estratégias de banda única, são um exemplo da evolução genuína na cadeia de processamento obtida ao longo dos anos (NOVI et al., 2007; ANG et al., 2012a)

1.1 Definição do problema de pesquisa

Embora sejam evidentes os avanços recentes, ainda são grandes os desafios impostos ao desenvolvimento de sistemas de ICM-IM (CHO et al., 2017). Aspectos críticos como treinamento do usuário, custo de calibração do sistema e a própria confiabilidade da predição em tempo real, ainda podem ser otimizados (GUGER et al., 2012; NAM; NIJHOLT;

LOTTE, 2018). Estratégias visando o ajuste eficiente dos algoritmos, especialmente em cadeias de processamento com elevada demanda computacional (e.g. sub-bandas), também são objetos de estudo permanente no contexto de ICM-IM (SILVA, 2017).

A ausência de uma arquitetura definitiva de processamento está, em grande parte, relacionada ao fato de que decodificar adequadamente a intenção motora de diferentes indivíduos no EEG a ponto de traduzi-la em comandos confiáveis não é uma tarefa trivial (NICOLAS-ALONSO; GOMEZ-GIL, 2012). A alta variabilidade da atividade cerebral inter e intra-indivíduos somada à natureza ruidosa e não-estacionária dos sinais de EEG, faz com que as características do sinal apresentem padrões particulares para cada usuário e impõe desafios importantes ao reconhecimento eficaz desses padrões em projetos de ICM-IM (CLERC; BOUGRAIN; LOTTE, 2016a).

Outrossim, as características incomuns que exprimem a intenção motora de diferentes indivíduos, exigem que a escolha dos algoritmos para compor a cadeia de processamento bem como a configuração dos múltiplos hiperparâmetros responsáveis pelo ajuste do modelo de classificação sejam realizadas de forma personalizada (CLERC; BOUGRAIN; LOTTE, 2016a; WEI; WEI, 2016).

De fato, a atribuição de valores à hiperparâmetros, representa uma etapa relevante no treinamento de algoritmos de aprendizado de máquina em geral, uma vez que os modelos de predição são calibrados com base nesses valores (SANDERS; GIRAUD-CARRIER, 2017; BERGSTRA; YAMINS; COX, 2013a). Em sistemas de ICM-IM não é diferente, haja vista que toda a sequência de processamento dos sinais de EEG é compreendida por diversos hiperparâmetros que requerem configuração antes mesmo do ajuste do modelo (BASHASHATI; WARD; BASHASHATI, 2016a).

Todos estes fatores sugerem que a construção de modelos com capacidade preditiva adequada para distinção entre os padrões de IM deve passar necessariamente pelas características cognitivas particulares de cada usuário (MIAO et al., 2017). Destarte, é improvável que uma configuração manual e universal do sistema, independente dos padrões individuais que descrevem a intenção motora, implique desempenho e usabilidade satisfatórios (BASHASHATI; WARD; BASHASHATI, 2016b; KUMAR; SHARMA, 2018).

Apesar disso, a configuração dos hiperparâmetros em sistemas ICM-IM é tipicamente uma tarefa humana, realizada de forma manual e empírica, com a tendência de se ter uma configuração única para a cadeia de processamento independentemente dos padrões particulares manifestos nos sinais cerebrais (YANG et al., 2017; FENG et al., 2018).

Mesmo que eficiente quando o número de hiperparâmetros é relativamente pequeno, a configuração manual dos hiperparâmetros requer tempo e tende a exigir do experimentador um conhecimento específico acerca do universo multidisciplinar de uma ICM-IM, podendo

significar uma barreira para o uso cotidiano fora do laboratório ao sugerir uma relação de dependência entre as figuras do usuário e do projetista do sistema (ALLISON; NEUPER, 2010; BERGSTRA et al., 2011).

Ademais, a exploração manual do espaço de configuração tende a se tornar ainda mais inviável à medida que cadeias de processamento mais sofisticadas e com espaço de configuração de alta dimensionalidade são escolhidas para o projeto, haja vista que o ajuste de todos os hiperparâmetros exigiria um grande número de combinações possíveis e, conseqüentemente de execuções para se obter uma solução ótima conjunta, submetendo o usuário à um processo desgastante e comprometendo de forma progressiva o desempenho e a usabilidade do sistema (SUK; LEE, 2011; BASHASHATI; WARD; BASHASHATI, 2016a; SILVA, 2017).

No contexto em que a configuração dos hiperparâmetros é uma etapa importante no ajuste dos modelos de aprendizagem e devido às condições variáveis e não estacionárias dos sinais cerebrais no âmbito de sistemas de ICM-IM, levanta-se os seguintes questionamentos:

- i. *Em que medida a configuração de hiperparâmetros pode impactar o desempenho de classificação em sistemas de ICM-IM?*
- ii. *Como descomplicar a tarefa de configuração dos algoritmos na cadeia de processamento ICM-IM e, ao mesmo tempo, prover um sistema com arquitetura personalizada e capaz de reconhecer com máxima eficácia os padrões de IM particulares do usuário?*

Em busca de respostas para os questionamentos apresentados e a fim de fornecer uma possível solução computacional prática a partir dos mesmos, este trabalho propõe o desenvolvimento de uma plataforma ICM-IM experimental de escopo completo que permita a configuração automática dos hiperparâmetros na cadeia de processamento e, com isso, a obtenção de modelos de classificação adequados às características cognitivas de cada usuário.

1.2 Objetivos

Geral

Investigar a influência da configuração hiperparamétrica no desempenho de sistemas de ICM-IM a partir do desenvolvimento de uma plataforma de código aberto, capaz de implementar as etapas típicas de ICM-IM de sub-bandas e de fornecer um método de configuração eficiente, personalizado e automático dos hiperparâmetros na fase de ajuste do modelo de classificação.

Específicos

Para alcançar o objetivo principal, o desenvolvimento do trabalho levou em consideração os seguintes objetivos específicos:

- Implementar módulos especializados que contemplem todas as etapas da arquitetura de sistemas de ICM-IM de sub-bandas, a saber: aquisição, processamento e controle.
- Implementar múltiplas técnicas de pré-processamento e reconhecimento de padrões em sinais de EEG, a fim de permitir cadeias de processamento com diferentes composições;
- Implementar um método de seleção de modelos com amplo espaço de configuração e que permita o ajuste eficiente e automático de hiperparâmetros com base nos padrões cognitivos particulares do usuário;
- Integralizar módulos, técnicas de processamento e método de configuração automática em ferramenta computacional única desenvolvida sob os princípios de código aberto;
- Validar a ferramenta tendo em vista os efeitos da configuração automática de hiperparâmetros no desempenho de classificação e na simulação de controle de um cursor virtual;
- Publicizar a ferramenta em ambiente público para fins de divulgação e desenvolvimento colaborativo.

1.3 Caracterização da pesquisa

Com base no método de caracterização proposto por Prodanov e Freitas (2013), a pesquisa apresenta natureza aplicada, em especial pela utilização de métodos multidisciplinares na construção de uma solução específica, de cunho prático, associando conceitos nas áreas de neurociência, engenharia e computação.

Do ponto de vista dos objetivos traçados, estes sugerem um tipo de pesquisa exploratória ao convergirem para a investigação acerca do real impacto no uso de abordagens de seleção automática de modelos de classificação em âmbito específico de sistemas de ICM-IM, a partir da proposição de diferentes técnicas e abordagens de inteligência computacional incorporadas a uma solução de *software* que visa contribuir para a maximização do desempenho, da usabilidade e da eficiência computacional desse tipo de tecnologia.

Quanto aos procedimentos metodológicos, adota-se o caráter experimental com base no levantamento e teste de hipótese. O caráter experimental da pesquisa é evidenciado pela investigação dos efeitos da configuração automática dos algoritmos no desempenho de

classificação usando uma plataforma de ICM-IM própria. A validação é predominantemente quantitativa, baseada na análise estatística dos resultados e na correlação entre variáveis e condições e seus respectivos efeitos no desempenho, aferida por métricas bem definidas, conforme sugere Gil et al. (2002).

1.4 Organização do documento e notação

Este documento está estruturado em nove capítulos que abordam sequencialmente os temas associados à pesquisa. Após este capítulo introdutório, o Capítulo 2 apresenta a fundamentação teórica relacionada aos aspectos gerais da neurociência englobados no desenvolvimento de sistemas de ICM. No Capítulo 3 são apresentadas as principais etapas do processamento de sinais de EEG e as especificidades do escopo de ICM-IM. Subsequentemente, o Capítulo 4 aborda os assuntos relacionados à seleção de modelos e à otimização hiperparamétrica no escopo de aprendizado de máquina com foco nas técnicas adotadas neste trabalho. Os aspectos metodológicos do desenvolvimento do trabalho são apresentados no Capítulo 5 e complementados pelo Capítulo 6 o qual apresenta as funcionalidades disponíveis na plataforma ICM-IM de código aberto desenvolvida. Posteriormente, no Capítulo 7, os resultados alcançados nos experimentos com a ferramenta proposta são discutidos, enquanto que, no Capítulo 8, são fornecidas algumas conclusões acerca dos resultados e as perspectivas de trabalhos futuros. Por fim, o Capítulo 9 lista as publicações derivadas do estudo seguido da seção de apêndices que descreve os experimentos secundários realizados durante a pesquisa que ainda podem ser objetos de publicação.

Ao longo do documento, letras maiúsculas e minúsculas em negrito são usadas para indicar matrizes e vetores, respectivamente, ao passo que letras em itálico denotam grandezas escalares. Denota-se por $\mathbb{R}^{N \times M}$ o conjunto de matrizes reais de dimensão $N \times M$. Um expoente $^{-1}$ à direita de uma matriz demonstra sua inversa, já a letra T sobrescrita à direita de uma matriz indica sua transposta, isto é, a permutação de linhas por colunas. Duas barras verticais à direita e à esquerda de uma matriz ou vetor, $\| \cdot \|$, denotam sua norma, enquanto que, quando envolvem um escalar, elas representam seu valor absoluto. Assim como o símbolo \mathbb{R} corresponde ao conjunto dos números reais, o símbolo \mathbb{C} representa o conjunto dos números complexos.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentadas as teorias que sustentam o desenvolvimento de sistemas de ICM. A seção 2.1 cobre brevemente os aspectos fisiológicos e anatômicos do cérebro humano. Em seguida, na seção 2.2 são abordadas as principais tecnologias de medição da atividade cerebral, sendo que, na seção 2.3 um enfoque maior é dado à medição por EEG. Posteriormente, os tipos mais populares de ICM são apresentados na seção 2.4 com referência aos sinais de controle. Finalmente, o Capítulo é encerrado com a apresentação de algumas aplicações de sistemas de ICM na seção 2.5.

2.1 Aspectos anatômicos e fisiológicos do cérebro

O cérebro é uma das estruturas mais complexas do corpo humano e seu funcionamento é objeto de estudo constante no meio científico (BEAR; CONNORS; PARADISO, 2017). Por proporem fundamentalmente controle e comunicação a partir do registro e do processamento da atividade cerebral, o projeto de ICM requer uma compreensão básica dos aspectos anatômicos e fisiológicos do cérebro e de suas conexões.

Os neurônios são os componentes fundamentais do cérebro e do sistema nervoso em geral, constituindo-se como células que interagem com o meio e entre si através de sinais químicos e elétricos, formando uma rede neural capaz de controlar as funções fisiológicas, comportamentais e motoras do corpo (BEAR; CONNORS; PARADISO, 2017). O neurônio difere-se de outras células, principalmente, devido à capacidade de polarização em sua estrutura, bem como por possuir regiões morfológicas distintas, cada qual com suas funções específicas (GIOVANINI, 2017). As atividades cerebrais geradas pela interação entre essas células podem ser classificadas em dois tipos básicos: as hemodinâmicas e as eletrofisiológicas (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

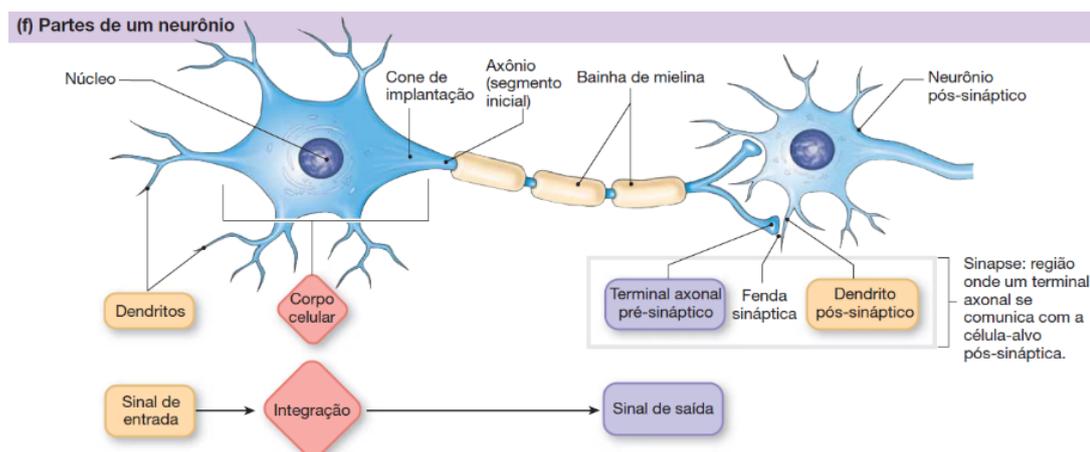
A resposta hemodinâmica descreve alterações no fluxo sanguíneo cerebral onde neurônios ativos recebem uma taxa maior de glicose em relação a áreas de neurônios inativos (MCFARLAND; WOLPAW, 2011). Essas mudanças são metabólicas, estando relacionadas com a atividade neuronal de maneira indireta (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

A atividade eletrofisiológica por sua vez, baseia-se no fluxo de corrente elétrica gerado pela troca de informações entre os neurônios (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Por serem tecidos excitáveis, os neurônios são capazes de propagar sinais elétricos rápidos, gerados pelo desequilíbrio entre íons nos meios intracelular e extracelular, desencadeando um potencial de ação como resposta à estímulos que descreve a atividade eletrofisiológica (SILVERTHORN, 2017).

A Figura 1 mostra a estrutura funcional de um neurônio formada essencialmente

por três partes: corpo celular (soma), o axônio e os dendritos. Nota-se na representação que cada uma dessas partes é formada por outros componentes com funções específicas para o tráfego de informação eletroquímica entre os neurônios no cérebro.

Figura 1. Estrutura básica de um neurônio. O corpo celular controla o metabolismo na estrutura da célula, enquanto que o axônio ramifica-se através dos dendritos para se comunicar com outras células ou órgãos a partir de sinapses nervosas



Fonte: Silverthorn (2017)

Na perspectiva eletrofisiológica, quando os neurônios são estimulados, um pulso nervoso primário percorre seu tronco dendrítico até que seja transmitido para outro neurônio através das sinapses nervosas. Dessa forma, enquanto o cérebro processa determinada informação, reações químicas caracterizadas pela entrada e saída de íons do neurônio, produzem correntes sinápticas secundárias, alterando a diferença de potencial entre os meios intracelular e extracelular (SANEI; CHAMBERS, 2007; BAILLET; MOSHER; LEAHY, 2001).

Eventualmente, essa mudança de potencial atinge um limiar específico (aproximadamente $70\mu\text{V}$) de despolarização dentro da célula, desencadeando a transmissão de um pulso eletroquímico ao longo do neurônio e transmitindo a informação através do tecido neural. Esse fenômeno, conhecido como potencial de ação, interfere nas cargas iônicas e altera a diferença de potencial de equilíbrio do tecido celular, gerando campos elétricos mensuráveis no interior e na superfície craniana (PURVES et al., 2004).

De acordo com Silverthorn (2017), o sistema nervoso humano é comumente apresentado como a junção de duas partes complementares entre si: o sistema nervoso central (SNC) e o sistema nervoso periférico (SNP). O SNC é composto pela medula espinal e pelo encéfalo, enquanto que o SNP é constituído por neurônios sensoriais e motores que atuam como receptores e condutores de informações entre os meios interno e externo ao corpo humano e o SNC. Em suma, na dinâmica funcional do sistema nervoso, os neurônios do SNC integram a informação recebida dos neurônios sensoriais do SNP e determinam se

uma resposta deve ser transmitida ou não através dos neurônios motores até os músculos e glândulas periféricas.

Nessa estrutura, o cérebro representa a maior parte do encéfalo no SNC sendo responsável por todas as operações mentais de alto nível, como concentração, pensamento, aprendizagem e controle motor (BASTOS; ADAMATTI; BILLA, 2016; SILVERTHORN, 2017). De acordo com Tan e Nijholt (2010), o cérebro é um conjunto complexo de subsistemas concorrentes, cada qual especializada em tarefas cognitivas distintas. Genericamente, ele pode ser subdividido em quatro zonas topográficas que possuem funções específicas no controle do corpo humano, sendo: córtex cerebral, cerebelo, hipotálamo e tálamo (PRADA, 2010; PURVES et al., 2004).

Uma fenda sagital, chamada de sulco-central, divide a estrutura do cérebro em dois hemisférios simétricos, esquerdo e direito. O córtex é uma camada espessa de matéria cinzenta que se estende por toda a parte mais externa do cérebro, acima de cada hemisfério. As demais estruturas, como cerebelo e tálamo, são chamadas de áreas sub corticais (SILVERTHORN, 2017; DUARTE, 2017).

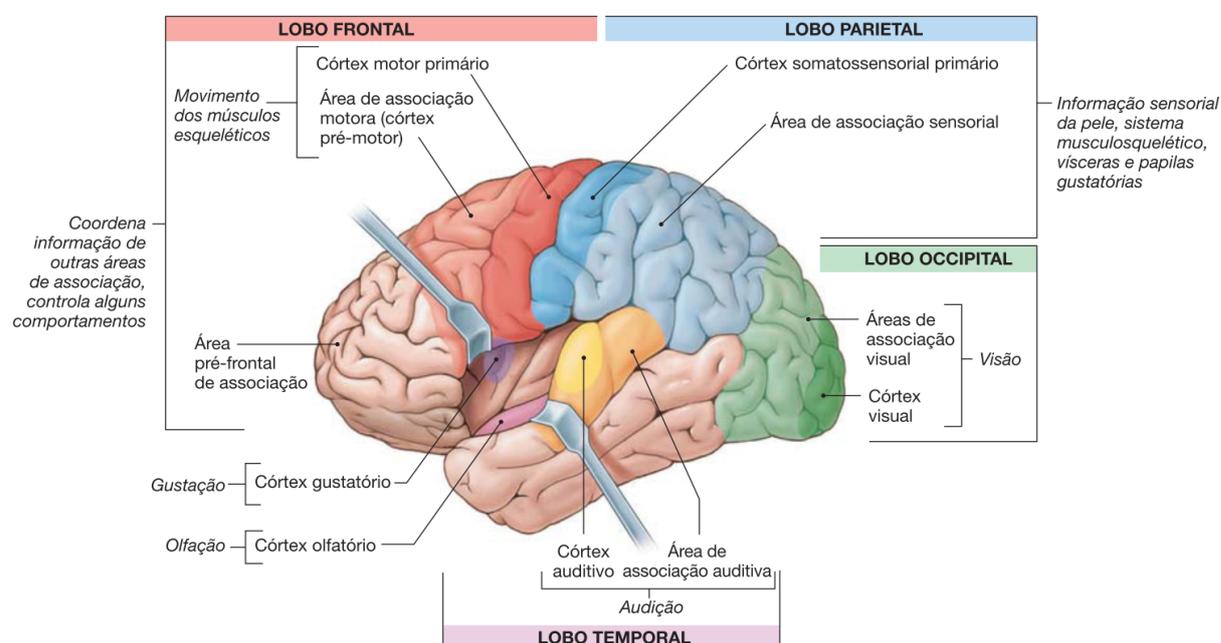
Partes menores, denominadas lobos, dividem o córtex cerebral. No total, quatro lobos externos e a ínsula formam a área cortical, sendo essa última visível somente com a abertura da área externa do córtex. Dentre os lobos externos, estão: frontal, parietal, occipital e temporal (REUTER-LORENZ et al., 2010).

De acordo com Purves et al. (2004), os lobos são determinados por pequenos sulcos ao longo do córtex e desempenham diferentes papéis no controle das funções e respostas neurológicas associadas às diversas regiões do corpo humano. O lobo frontal é separado do lobo parietal pelo sulco central e do lobo temporal por uma fissura lateral enquanto que o lobo occipital fica na parte traseira do cérebro (GRAIMANN; ALLISON; PFURTSCHELLER, 2010).

A Figura 2 apresenta uma visão lateral do hemisfério esquerdo do cérebro onde é possível observar de forma sintetizada suas regiões anatômicas bem como as funções das áreas corticais mencionadas.

Cada lobo tem funções especializadas: o lobo temporal contém o córtex auditivo primário e está relacionado com o processamento de informações auditivas, compreensão da linguagem e alguns aspectos de memória; o lobo parietal relaciona-se com informações somatossensoriais e é dedicado ao sentido do tato e com estímulos originados pela sensibilidade do corpo e reconhecimento espacial; o lobo occipital contém o córtex visual primário por onde processa informações visuais; o lobo frontal é responsável pelo planejamento racional e pelo movimento realizando o processamento da atividade motora (BASTOS; ADAMATTI; BILLA, 2016).

Figura 2. Regiões funcionais do córtex cerebral com representação das áreas sensoriais para percepção, áreas motoras para coordenação de movimentos e áreas de associação para integração de informações.

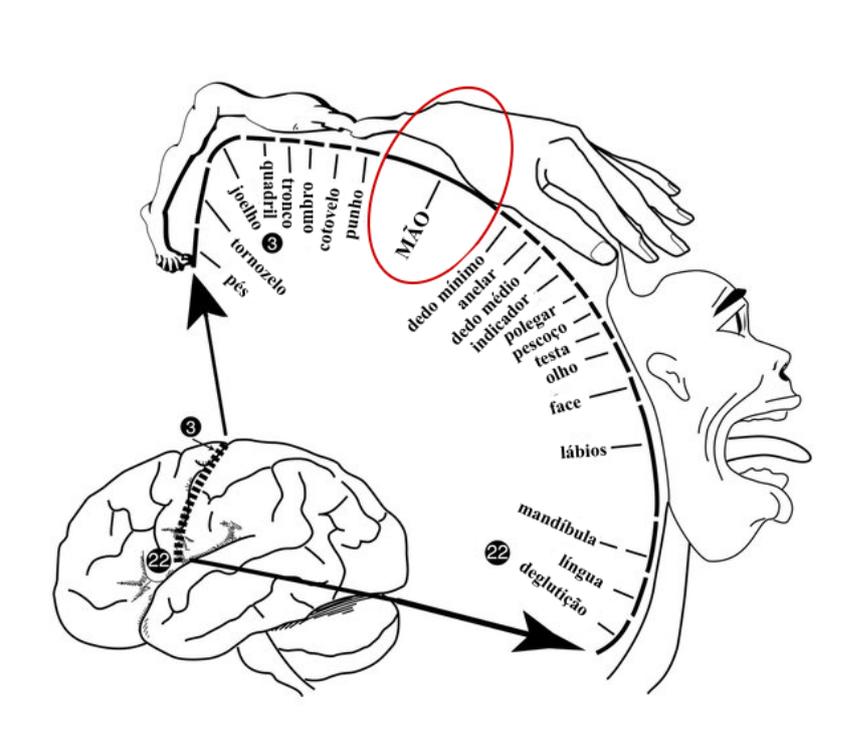


Fonte: Silverthorn (2017)

Quanto ao aspecto funcional, Silverthorn (2017) distinguiu três áreas especializadas para compor o córtex, sendo: áreas sensoriais, áreas motoras e áreas de associação. As primeiras recebem estímulos sensoriais e as traduzem em consciência. As áreas motoras, geram comandos para direcionamento dos movimentos do músculo esquelético. Já as áreas de associação integram as informações de áreas sensoriais e motoras, podendo direcionar comportamentos voluntários. Geralmente a informação é processada por mais de uma área.

O córtex motor primário (M1), localizado ao longo do sulco central no lobo frontal, é a região particular do córtex normalmente explorada em sistemas ICM por sua intrínseca relação com as funções motoras (GRAIMANN; ALLISON; PFURTSCHELLER, 2010). Conforme apresentado na Figura 2, essa região representa uma área estreita da superfície do córtex, compreendida aproximadamente de uma orelha a outra e subdividida em zonas responsáveis pelo controle motor de cada parte específica do corpo humano. O homúnculo motor de *Penfield*, apresentado na Figura 3, ilustra a relação entre as diferentes partes do corpo humano e a porção do M1 responsável por controlá-las. Como a representação do córtex é simétrica ao ser analisado de uma visão superior, o mapeamento na Figura 3 vale para ambos os hemisférios, esquerdo e direito. Nesta perspectiva Silverthorn (2017) descreve a dominância de tarefas cognitivas de um hemisfério sobre outro através do fenômeno de lateralização cerebral. De maneira simplificada, este fenômeno implica que, em caso de ocorrência de um dano cerebral no hemisfério esquerdo, por exemplo, a parte contralateral do corpo humano, ou seja o lado direito, também é afetada (GUBERT, 2019).

Figura 3. Representação clássica do homúnculo de Penfield para as áreas do córtex motor responsáveis pela ativação motora de diferentes regiões corporais. A região em destaque, antecipa a área do córtex motor associada às tarefas motoras de interesse específico deste trabalho.



Fonte: Adaptado de Wolpaw e Wolpaw (2012)

As características desse processamento das informações pelo cérebro, geralmente contralateral e também descritas por Purves et al. (2004) e Bear, Connors e Paradiso (2017), são especialmente úteis ao projeto de ICM-IM que exploram a informação espacial associada ao controle de determinada função motora por um dos hemisférios do cérebro (PFURTSCHELLER; NEUPER, 2001).

2.2 Técnicas de imageamento da atividade cerebral

Diferentes métodos de neuroimagem podem ser utilizados para monitorar a atividade cerebral, seja ela hemodinâmica ou eletrofisiológica. Esses métodos podem ser categorizados, dentre outras perspectivas, como abordagens invasivas e não invasivas (SETHI; UPADHYAY; SINGH, 2018). As abordagens invasivas, em geral, caracterizam-se pela implantação cirúrgica de sensores para captura de sinais intracranianos a fim de se obter sinais com resolução espacial ampliada, ao passo que, abordagens não invasivas medem os sinais transcranianos sem requerer intervenções cirúrgicas (AMIRI et al., 2013b; WOLPAW et al., 2002).

A resposta indireta hemodinâmica associada às propriedades sanguíneas, pode

ser monitorada utilizando métodos não invasivos de neuroimagem como a ressonância magnética funcional (fMRI, do inglês *functional Magnetic Resonance Imaging*) e a espectroscopia de infravermelho próximo funcional (fNIRS, do inglês *functional Near Infrared Spectroscopy*) por exemplo (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Tanto a fMRI quanto a fNIRS têm como propriedades principais de monitoramento o fluxo e os níveis de oxigenação sanguíneos no cérebro, diferenciando-se essencialmente pelo mecanismo de medição (ABIRI et al., 2019).

A fMRI usa ressonância magnética para medir a intensidade do fluxo sanguíneo entre diferentes regiões do cérebro com base no princípio de que o aumento da atividade cerebral em uma região, aumenta o gasto proporcional de energia e, conseqüentemente, a quantidade de sangue necessária para repor tal gasto energético. Enquanto isso, tecnologias fNIRS baseiam-se na absorção e dispersão de luz infravermelha pelo cérebro para determinar as mudanças na oxigenação do tecido cortical e nas membranas neuronais causadas pela ativação dos neurônios em resposta à estimulação óptica (SILVA, 2017; TAN; NIJHOLT, 2010).

Além disso, apesar de apresentarem alta resolução espacial ($< 1\text{cm}$), ambas as técnicas dispõem de baixa resolução temporal (5 à 8 segundos em média) decorrente do não imediatismo do fenômeno de entrada sanguínea no cérebro no caso da fMRI e da resposta lenta dos tecidos ao disparo infravermelho ao usar fNIRS (TAN; NIJHOLT, 2010).

Uma vantagem adicional na medição por fNIRS, porém, consiste de que a luz emitida é não ionizante podendo ser usada por períodos prolongados e de forma segura. Esse aspecto ajuda a explicar a existência de equipamentos portáteis, de configuração simplificada e relativamente baratos no mercado (CLERC; BOUGRAIN; LOTTE, 2016a). Por outro lado, os equipamentos para medição por fMRI são normalmente caros e volumosos dada a necessidade de fornecerem supercondutibilidade magnética (TAN; NIJHOLT, 2010).

No âmbito da atividade eletrofisiológica, os campos elétricos originados pelas correntes sinápticas neuronais também podem ser quantificados tanto de forma invasiva como não invasiva. Duas das técnicas de medição invasiva mais comuns são a eletrocorticografia (ECoG) e o potencial de campo local (LFP, do inglês *Local Field Potential*). Ambas baseiam-se na implantação de matrizes de microeletrodos dentro do crânio para captar a atividade elétrica gerada por uma população de neurônios, sendo que na ECoG esses sensores são posicionados na superfície do córtex ao passo que a técnica LFP usa sondas de profundidade para medição intracortical (NICOLAS-ALONSO; GOMEZ-GIL, 2012; TEPLAN, 2002).

Quanto aos métodos transcranianos, que proporcionam uma medição não invasiva dos campos elétricos, outras duas tecnologias de medição são tipicamente mencionadas no

contexto de ICM: a magnetoencefalografia (MEG) e o EEG (PFURTSCHELLER; SILVA, 1999; CHAUDHARY; BIRBAUMER; CURADO, 2015; CORSI et al., 2019). O mecanismo de medição da MEG baseia-se no potencial dos campos magnéticos gerados pela atividade elétrica do cérebro. Já o EEG, mede a diferença do próprio potencial elétrico gerado no cérebro ao comparar um eletrodo posicionado em algum ponto do couro cabeludo e um eletrodo de referência (TAN; NIJHOLT, 2010; SANEI; CHAMBERS, 2007).

Uma vantagem da técnica MEG em relação ao EEG, consiste na obtenção de imagens mais profundas e bem definidas do cérebro, uma vez que o crânio é praticamente transparente aos feixes de ondas magnéticas. Não obstante, assim como no modo magnético de medição hemodinâmica pelo fMRI, os equipamentos MEG são relativamente caros e volumosos devido a necessidade de supercondutibilidade (TAN; NIJHOLT, 2010).

No caso do EEG, apesar da baixa resolução espacial provocada por diversas fontes de ruído e pela própria estrutura craniana que atenua ainda mais a baixa amplitude do potencial elétrico neuronal (5 a 100 μV), este destaca-se principalmente pela alta resolução temporal e disponibilidade de equipamentos portáteis e de baixo custo relativo (SANEI; CHAMBERS, 2007).

Diante das várias técnicas de imageamento apresentadas, não é difícil inferir que os métodos invasivos, apesar de disporem de resoluções espacial e temporal mais satisfatórias, têm desvantagens importantes em relação às abordagens não invasivas devido ao inerente risco cirúrgico para o usuário. Isso significa que, embora sejam capazes de captar com mais qualidade informações fidedignas do estado cognitivo, elas são acompanhadas por altos riscos à integridade física do indivíduo e, portanto, são menos comuns em aplicações práticas de ICM, especialmente com indivíduos saudáveis (WANG et al., 2018; ABIRI et al., 2019).

Ademais, segundo McFarland e Wolpaw (2011), mesmo que não invasivos, os métodos baseados em respostas hemodinâmicas (e.g. fMRI e fNIRS) ou possuem um custo muito elevado para aplicação ou possuem resposta inerentemente lenta em comparação à métodos eletrofisiológicos, fazendo com que também sejam pouco utilizados no contexto de ICM. Igualmente, embora a medição magnética por MEG seja presente em alguns estudos de ICM, os altos custos a tornam inviável para grupos menores de pesquisa e para uso fora do ambiente laboratorial (CLERC; BOUGRAIN; LOTTE, 2016a).

Assim, a possibilidade de medição na ordem de centenas de milissegundos caracterizada pela alta resolução temporal, a portabilidade e o melhor custo benefício do EEG, faz com que esta técnica se sobressaia perante as demais e a torne especialmente atraente para uso em pesquisas de ICM (NICOLAS-ALONSO; GOMEZ-GIL, 2012; LIN; JIANG, 2015). Estas razões, justificam a escolha do EEG como técnica de imageamento adotado

no escopo deste trabalho.

2.3 Eletroencefalografia (EEG)

Como já abordado, as correntes sinápticas geradas pelos transmissores eletroquímicos fluem dentro e através dos conjuntos neuronais e originam campos elétricos passíveis de serem quantificados no escalpo por EEG (SANEI; CHAMBERS, 2007). A atividade elétrica observada no EEG, caracteriza-se por representar a soma das contribuições dos campos elétricos de cada uma das células que compõem o tecido cerebral em uma determinada região (BUENO, 2017; SILVA, 2017).

Formalmente o EEG pode ser definido como um método de neuroimagem, comumente não-invasivo, cujos sinais denominados de eletroencefalograma são coletados por eletrodos posicionados no escalpo e representam o fluxo de correntes elétricas observáveis durante excitações sinápticas neuronais (NIEDERMEYER; SILVA, 2005; SCHOMER; SILVA, 2018).

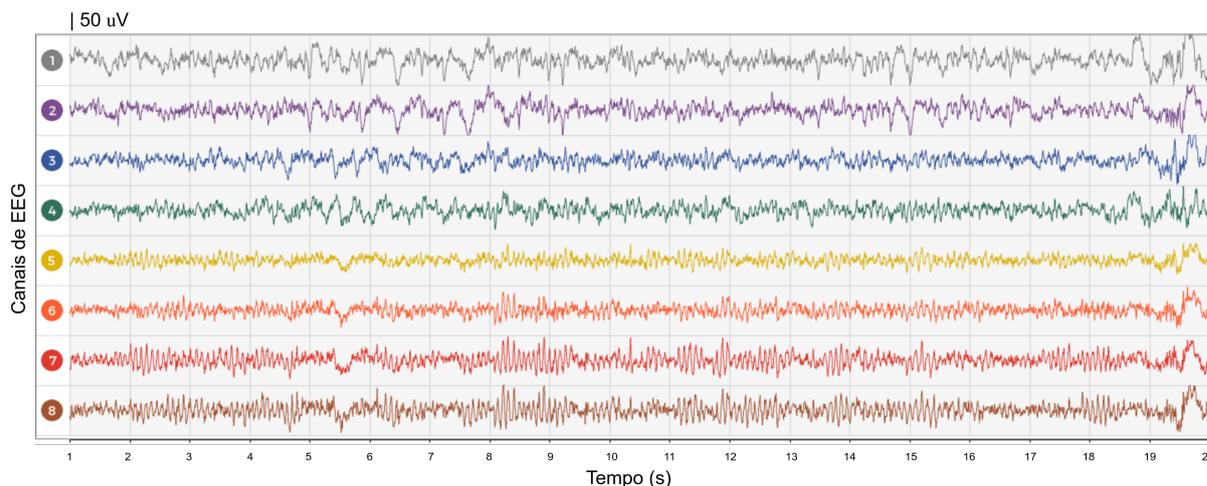
Os sinais de EEG provêm de variações espaço-temporais de potenciais gerados principalmente por neurônios presentes no córtex cerebral em grande parte orientados perpendicularmente em relação à superfície (SANEI; CHAMBERS, 2007). De acordo com (NIEDERMEYER; SILVA, 2005), a amplitude do sinal de EEG apresenta variações em torno de $\pm 200\mu\text{V}$. Na prática, o sinal medido no EEG descreve a diferença de potencial, criada pela propagação das correntes elétricas na cabeça, entre um ponto no escalpo e um eletrodo de referência (CLERC; BOUGRAIN; LOTTE, 2016a).

Os eletrodos captam o sinal da superfície da cabeça e os transmitem ao amplificador, que, por sua vez, está conectado ao computador, tornando os sinais passíveis de processamento (TEPLAN, 2002). Na Figura 4, um segmento de sinal multicanal é plotado no domínio do tempo. Os sinais provenientes dos 8 eletrodos posicionados no escalpo representam amostras coletadas no tempo discreto a uma dada taxa de amostragem.

Além de ser uma técnica não invasiva, o EEG permite a obtenção de sinais da atividade elétrica neuronal com resolução temporal em milésimos de segundos, o que permite a coleta de sinais de longa duração (WOLPAW; WOLPAW, 2012; BASTOS; ADAMATTI; BILLA, 2016). No entanto a impedância e a localização relativamente distante dos eletrodos em relação aos fenômenos que originam as correntes sinápticas intracorticais prejudica sobremaneira a resolução espacial dos sinais (TEPLAN, 2002).

Nesse sentido, um dos fatores prejudiciais na propagação dessas correntes é o crânio cuja estrutura óssea possui baixa condutibilidade se comparada ao cérebro e ao escalpo, o que causa uma suavização espacial dos potenciais elétricos através da difusão (efeito *smearing*) e atenuação das correntes (CLERC; BOUGRAIN; LOTTE, 2016a; NUNEZ;

Figura 4. Representação temporal de um segmento de EEG multicanal



Fonte: Gerado pelo autor usando a ferramenta *OpenVIBE*

SRINIVASAN et al., 2006). As camadas de tecidos e os fluidos presentes entre os sensores e o córtex, como o próprio escalpo, também atenuam consideravelmente o sinal, o que requer um alto ganho aos potenciais medidos pelos sensores para que a visualização do sinal de EEG seja possível (SILVA, 2017; TAN; NIJHOLT, 2010).

Uma das vantagens da eletrofisiologia é a possibilidade de isolar oscilações em diferentes frequências (CLERC; BOUGRAIN; LOTTE, 2016a). Sob a perspectiva espectral, os sinais cerebrais podem ser categorizados em diferentes tipos de ondas ou ritmos diferenciados por sua frequência, amplitude, forma e localização relativamente bem definidos (WOLPAW; WOLPAW, 2012).

As características dos ritmos cerebrais variam entre os indivíduos conforme alguns fatores como: idade, grau de atenção, cansaço mental e morfologia craniana (PRADA, 2010). Além disso, segundo Bear, Connors e Paradiso (2017), condições patológicas, como a epilepsia e tumores cerebrais, também estão associadas às variações nos ritmos cerebrais, o que torna a análise dos sinais de EEG uma ferramenta contribuinte para o entendimento das funções sensoriais do cérebro.

2.3.1 Ritmos da atividade cerebral

Comumente são listados na literatura, cinco ritmos distintivos produzidos pela atividade elétrica cerebral e que são observáveis em sinais de EEG. Embora haja controvérsias nas bandas de frequência representativas em cada ritmo, podendo variar dependendo do autor, Wolpaw e Wolpaw (2012), Nidal e Malik (2014) e Nam, Nijholt e Lotte (2018) os classificam conforme as faixas na Tabela 1.

As características de amplitude e frequência de cada ritmo respondem à realização de diferentes tarefas mentais (WOLPAW; WOLPAW, 2012; FERREIRA, 2008). Outrossim,

Tabela 1. Categorização típica dos ritmos da atividade cerebral conforme a banda de frequência e a amplitude

Ritmo	Frequência (Hz)	Amplitude (μV)
<i>Delta</i> (δ_r)	0.5 – 4	100 – 200
<i>Theta</i> (θ_r)	4 – 8	5 – 10
<i>Alpha</i> (α_r)	8 – 13	20 – 80
<i>Beta</i> (β_r)	13 – 30	1 – 5
<i>Gamma</i> (γ_r)	≥ 30	0.5 – 2

a ocorrência desses ritmos normalmente tem relação com uma área específica do córtex, conforme as regiões ilustradas na Figura 2 (BEAR; CONNORS; PARADISO, 2017).

Os ritmos δ_r e θ_r , por exemplo, registram os níveis de sonolência do indivíduo e podem estar associados ao estado de meditação, vigília, stress, bem como à disfunções cerebrais de atenção. Enquanto que o ritmo γ_r associa-se a processos mentais mais complexos como consciência e percepções sensoriais sonoras e visuais (FERREIRA, 2008; SANEI; CHAMBERS, 2007; BASTOS; ADAMATTI; BILLA, 2016).

Quanto aos ritmos β_r , estes podem ser medidos principalmente nas regiões frontal e parietal do cérebro e relacionam-se com o processamento de informações externas estando fortemente ligados às atividades motoras, assim como os ritmos α_r que, por sua vez, têm origem nas zonas occipital e frontal do córtex e sofrem atenuação considerável durante a realização de movimentos (FERREIRA, 2008; SANEI; CHAMBERS, 2007).

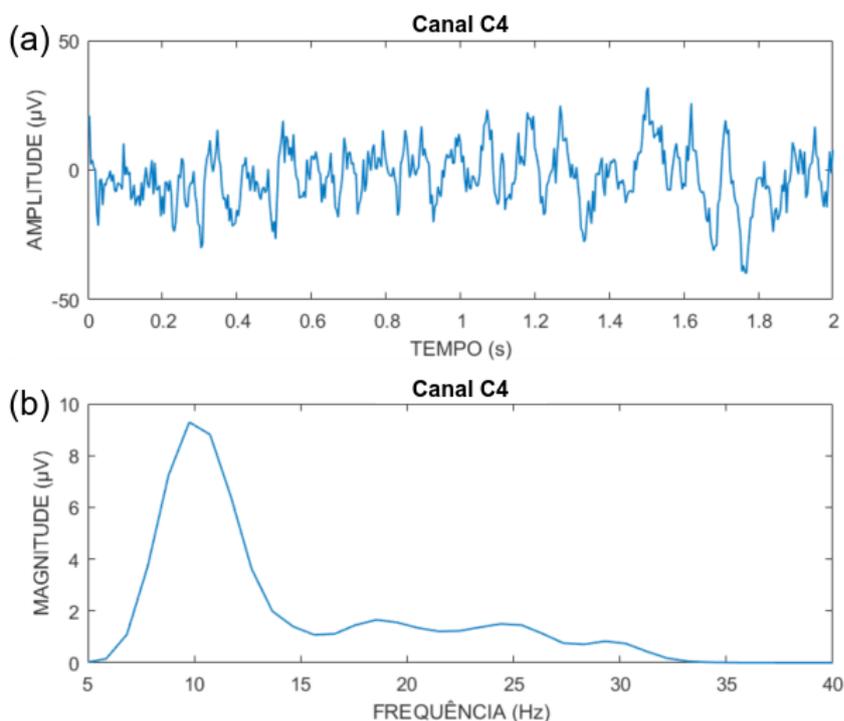
Outro ritmo característico proveniente da atividade elétrica cerebral é o ritmo mu (μ_r). A onda μ_r é um tipo especial de ritmo α_r originado predominantemente na região do M1 e observado quando o indivíduo se encontra em repouso, sofrendo forte supressão durante a realização ou imaginação de algum movimento (PRADA, 2010; SILVA, 2017).

Esse fenômeno, representado em forma de energia, têm efeito contralateral à atividade motora, ou seja, os ritmos μ_r são atenuados sobre o hemisfério esquerdo do cérebro quando a mão direita, por exemplo, é movimentada e vice-versa (FELZER, 2001; PURVES et al., 2004; MORASH et al., 2008). Acerca da faixa de frequência compreendida pelos ritmos mu, estas também podem variar conforme o autor, porém, em geral está definida entre 7 e 12Hz (PFURTSCHELLER; SILVA, 1999; MCFARLAND; WOLPAW, 2011; ABIRI et al., 2019).

De acordo com Wolpaw et al. (2002) e Gubert (2019), os ritmos μ_r e β_r , por estarem associados a áreas corticais conectadas a canais sensoriomotores do cérebro, podem fornecer informações confiáveis para sistemas de comunicação e controle baseados em EEG, sendo particularmente úteis para o estudo de sistemas ICM-IM. A Figura 5 representa um

segmento de sinal, relativo à um único canal de EEG, tanto no domínio do tempo quanto no domínio da frequência. O espectro em 5-b resalta a magnitude na banda de frequência compreendida pelo ritmo μ_r , especificamente. Embora o EEG sofra de uma baixa relação

Figura 5. Segmento de sinal de EEG proveniente de canal único nos domínios do tempo (a) e da frequência (b) com representação espectral equivalente ao ritmo cerebral μ_r



Fonte: Autoria própria

sinal-ruído (SNR, do inglês *Signal to Noise Ratio*), em geral, os estudos de ICM que o adotam superam em quantidade e viabilidade os baseados em outros métodos de aquisição, devido a todos os fatores já mencionados (i.e. baixo custo relativo, portabilidade e resolução temporal) (NOURMOHAMMADI; JAFARI; ZANDER, 2018; NAM; NIJHOLT; LOTTE, 2018).

Desde que foi relatado pela primeira vez por *Hans Berger*, em 1929, o EEG evoluiu gradualmente no decorrer dos anos até atingir o alto grau de complexidade observados atualmente (SANEI; CHAMBERS, 2007).

Minguillon, Lopez-Gordo e Pelayo (2017), por sua vez, destacam a constante sofisticação das abordagens de aprimoramento e algoritmos de filtragem que, ao serem aplicados nos sinais, atuam para minimizar a interferência de biopotenciais indesejados conhecidos como artefatos.

2.4 Paradigmas de ICM e biosinais de controle

A categorização de uma ICM pode ser realizada com base em diversos aspectos distintos, que se estendem desde o tipo de atividade cortical e técnica de aquisição adotada até o propósito ligado ao tipo de aplicação do sistema (e.g. reabilitação, controle ou comunicação) (GRAIMANN; ALLISON; PFURTSCHELLER, 2010; ABIRI et al., 2019).

Uma visão geral dos tipos de sistemas ICM, considerando diversos atributos, pode ser conferida em (Graumann, Allison e Pfurtscheller (2010), pág. 23). De forma análoga, Nourmohammadi, Jafari e Zander (2018), sob a perspectiva de ICMs aplicada ao controle de dispositivos com altos graus de liberdade, também apresenta uma classificação baseada em três aspectos: técnicas de aquisição, autonomia do usuário e tipos de fenômenos neurológicos.

Ao assumir uma taxonomia de alto nível, por exemplo, os sistemas de ICM podem ser categorizados como *passivos*, quando o objeto de estudo não é diretamente dedicado à comunicação ou controle, mas sim à análise do estado mental do usuário, ou *ativo/reativo* quando esses sistemas propõem uma comunicação direta entre o usuário e a aplicação para a qual são enviadas mensagens ou comandos com base no reconhecimento dos padrões cognitivos do indivíduo (CLERC; BOUGRAIN; LOTTE, 2016a).

No âmbito de ICMs ativas/reativas, especificamente, os sistemas baseados em EEG, conforme já discutido, monitoram e detectam determinados padrões nos sinais que descrevem mudanças na atividade elétrica cerebral (WOLPAW; WOLPAW, 2012; SILVA, 2017). Tais mudanças, em geral, têm relação com tarefas cognitivas e podem ser provocadas de forma voluntária (ativa) ou involuntária (reativa) pelo usuário (GRAIMANN; ALLISON; PFURTSCHELLER, 2010).

Clerc, Bougrain e Lotte (2016a) explicam que, para além das técnicas de processamento empregadas pela ICM, a confiabilidade da comunicação entre o usuário e a aplicação também depende da seleção sistemática das tarefas mentais executadas pelo usuário, cujo objetivo é gerar um fenômeno neurológico específico e possibilitar a extração de informações diferenciáveis do sinal ruidoso produzido pelo cérebro.

Nesta perspectiva, a estratégia usada para geração dos fenômenos neurológicos (biosinais) de interesse define os paradigmas de ICM. Em outras palavras, a autonomia dada ao usuário para modular a atividade cerebral, a partir de tarefas cognitivas específicas que possibilitem gerar padrões mensuráveis por EEG, é uma das formas mais comuns de tipificação de sistemas de ICM (NOURMOHAMMADI; JAFARI; ZANDER, 2018).

Basicamente, as mudanças no padrão elétrico cerebral mensuráveis por EEG, comuns no contexto de ICM, podem ser divididas em dois grupos principais, sendo: potenciais evocados e potenciais induzidos. Os potenciais evocados representam biosinais precedidos

por alguma forma de estimulação exógena, fornecida pela ICM, ao passo que os potenciais induzidos são gerados pelo próprio usuário de forma espontânea, independentemente de estímulo externo (AMIRI; FAZEL-REZAI; ASADPOUR, 2013a; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Outra nomenclatura comumente usada para diferenciar sistemas de ICM a partir das abordagens evocadas ou induzidas é relacioná-los aos termos síncronos e assíncronos, respectivamente, em que o sincronismo neste caso, refere-se justamente à dependência da resposta neurológica do usuário ao estímulo externo (BUENO, 2017; VAZ, 2016; NOOH; YUNUS; DAUD, 2011).

Em se tratando dos potenciais evocados, estes também são reconhecidos como potenciais relacionados à eventos (ERP, do inglês *Event-related Potentials*) ou potenciais de atenção seletiva, uma vez que o usuário pode ou não prestar atenção especial ao estímulo fornecido (CLERC; BOUGRAIN; LOTTE, 2016a; VAZ, 2016). Os ERPs são gerados em resposta à estímulos visuais, auditivos ou táteis, a fim de produzir uma resposta neurológica específica que, ao ser detectada, pode ser usada para controle síncrono da aplicação (CLERC; BOUGRAIN; LOTTE, 2016a).

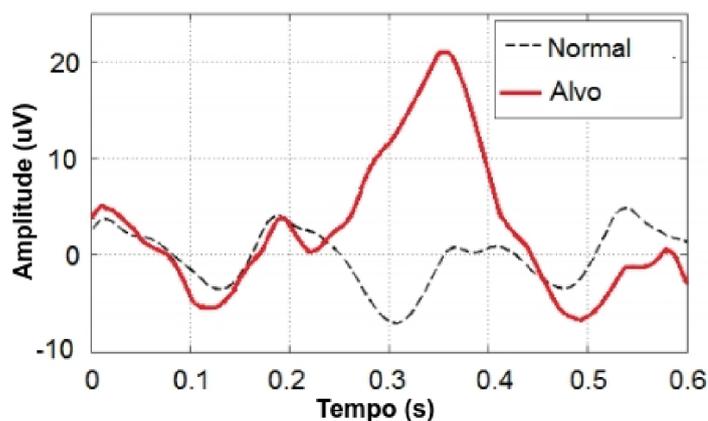
Há diversos paradigmas ERP relatados no contexto de ICM, por exemplo: potencial P300, potencial visualmente evocado de regime estacionário (SSVEP, do inglês *Steady State Visually Evoked Potential*), potencial auditivo evocado (AEP, do inglês *Auditory-Evoked Potential*), potencial cortical lento (SCP, do inglês *Slow Cortical Potential*) e potencial relacionado a erros (ErrP, do inglês *Error-related Potential*) (ABIRI et al., 2019; NOURMOHAMMADI; JAFARI; ZANDER, 2018). Dentre os ERPs disponíveis, dois se destacam em aplicações ICM em relação aos demais, são eles: os potenciais P300 e o SSVEP Fatourehchi et al. (2007).

Os potenciais P300 são evocados a partir de estímulos visuais, auditivos ou táteis apresentados intensivamente ao usuário. A alteração da representação neural, que descreve o potencial P300 de interesse, pode ser observada nos sinais de EEG aproximadamente 300 milissegundos após o início da reação involuntária do usuário à um estímulo pouco frequente em meio a outros estímulos frequentes (SILVA, 2017).

Em suma, o P300 é um pico positivo com amplitude variável entre 5 e 10 μV perceptível no EEG, geralmente em eletrodos posicionados no lobo parietal, quando o usuário é surpreendido por um estímulo estranho aos demais (PRADA, 2010; AMIRI; FAZEL-REZAI; ASADPOUR, 2013a). A Figura 6 ilustra a forma de onda que descreve o fenômeno P300 no EEG.

Um experimento comum para geração de potenciais P300 é a utilização de estímulos visuais a partir da apresentação de uma matriz de letras do alfabeto ao usuário, em que

Figura 6. A curva contínua, construída a partir da média de várias repetições do experimento de sensor único, ilustra a amplitude do pico que descreve o P300 em relação a sua ausência na onda pontilhada.



Fonte: Silva (2017)

o usuário é orientado a escolher uma única letra e nela focar sua atenção enquanto as linhas e colunas piscam aleatoriamente. Quando a letra desejada pisca, um potencial P300 é gerado e pode ser detectado pelo sistema (GIOVANINI, 2017; WOLPAW et al., 2002).

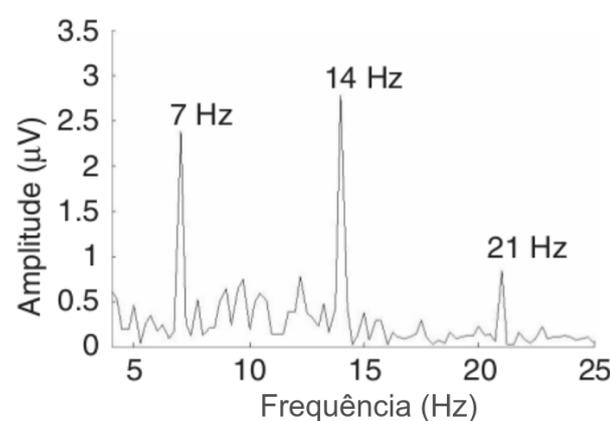
Já para o caso dos biosinais de SSVEP, múltiplos estímulos visuais repetitivos são apresentados ao indivíduo em frequências constantes a fim de gerar uma resposta oscilatória contínua, a qual resulta em um padrão de sinais de EEG consistente e correlacionado com a frequência de cintilação (ABIRI et al., 2019). O usuário deve manter o foco visual nos estímulos apresentados, para que seja possível observar um aumento da atividade cerebral de frequências correspondentes na região do córtex visual (SENA, 2018).

Uma vez que cada estímulo visual pode apresentar frequências de oscilação distintas, os potenciais SSVEP resultantes possibilitam a geração de diferentes comandos (SILVA, 2017). A Figura 7 ilustra o espectro de um segmento de sinal de EEG onde o potencial SSVEP é representado pela amplitude em harmônicas associadas as oscilações de um led piscando a uma frequência de 7Hz na do monitor.

Normalmente, o SSVEP apresenta vantagens importantes de desempenho e tempo de treinamento quando comparado a outras modalidades ERP, como o P300, bem como aos potenciais induzidos (CHEN et al., 2015; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Por outro lado, apesar de ERPs exigirem um treinamento consideravelmente menor para que o usuário consiga gerar o fenômeno neurológico desejado (GRAIMANN; ALLISON; PFURTSCHELLER, 2010), dois obstáculos principais são normalmente relatados em ICMS baseadas nesse tipo de potencial, tais quais: (i) geralmente requerem a atenção do usuário ao monitor que exhibe os estímulos, o que limita sua mobilidade e a portabilidade do sistema; (ii) o custo operacional é alto quando se usa continuamente o SSVEP por um

Figura 7. Espectro de sinal de EEG representando a informação em frequência associada aos potenciais SSVEP gerados por estímulo visual a partir de led piscando a 7Hz. Nota-se a representação através dos picos na frequência fundamental e nas duas primeiras harmônicas



Fonte: Giovanini (2017)

longo período de tempo, tornando complexa a manutenção do engajamento do usuário (WANG et al., 2018).

A geração dos potenciais induzidos, por sua vez, se dá a partir da modulação da atividade elétrica cerebral em resposta à realização voluntária pelo usuário de tarefas cognitivas previamente definidas. Apesar de não exigirem estimulação externa, esses potenciais requerem treinamento relativamente longo para que o usuário aprenda a modular a atividade cerebral de forma satisfatória (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

O potencial induzido mais difundido no contexto de ICMs baseadas em EEG é o fenômeno neurológico associado aos ritmos sensório motores (SMR, do inglês *Sensorimotor Rhythms*), os quais compreendem as propriedades associadas aos ritmos cerebrais μ_r e β_r (NAM; NIJHOLT; LOTTE, 2018; SENA, 2018; PFURTSCHELLER; NEUPER, 2001).

Conforme abordado na seção 2.3.1, a amplitude dos SMR varia quando há atividade elétrica nas áreas sensório-motoras do cérebro relacionadas ao controle de movimentos no corpo. O que torna os potenciais dos ritmos SMR interessantes, é o fato de que, assim como a realização de um movimento real de algum membro (e.g. pés, mãos, língua), a própria imaginação desses movimentos, IM, também gera os padrões oscilatórios correspondentes à ação e mensuráveis nos sinais de EEG (MULDER, 2007).

A IM ativa áreas sensório-motoras no cérebro em especial na região do M1 envolvidas na preparação e execução do movimento (LOTZE; COHEN, 2006). Com isso, o indivíduo é capaz de induzir voluntariamente padrões de atividade elétrica neural que descrevem sua intenções motoras, ao realizar a IM de um membro (LOTTE, 2014; VAZ, 2016; BERNARDI, 2018). Portanto, ao realizar a IM, geralmente das mãos, pés e língua, o fenômeno neurológico ERS/ERD, pode ser detectado no sinal de EEG através de sensores

posicionados nessas áreas (OLIVAS-PADILLA; CHACON-MURGUIA, 2019).

A ERD representa a supressão da energia dos sinais de EEG em faixas de frequência específicas, em geral a compreendida pelo ritmo μ_r em resposta à dessincronização de um grupo localizado de neurônios no cérebro, ocorrido na preparação ou durante a realização da IM (ou movimento real). Enquanto que o ERS corresponde ao aumento da energia dos sinais, também em faixa de frequência específica, coberta normalmente pelos ritmos SMR μ_r e β_r , em resposta à sincronização do ritmo oscilatório de um grupo de neurônios após a realização do evento (NICOLAS-ALONSO; GOMEZ-GIL, 2012; WIERZGAŁA et al., 2018).

Conforme Morash et al. (2008), esses fenômenos relativos à imaginação de um movimento específico apresentam padrões de dimensionalidade e intensidade distintos entre si e são distinguíveis no EEG em âmbito espectral, temporal e espacial.

Outro ponto fundamental para o projeto de sistemas de ICM-IM, consiste no fato de que, no âmbito espacial do escalpo, esses fenômenos neurológicos são observáveis em maior intensidade contralateralmente no cérebro. No caso de movimentos das mãos (IM ou real), por exemplo, o efeito ERD/ERS ocorre com intensidade variada nos eletrodos posicionados no hemisfério oposto ao membro envolvido na tarefa, ou seja, movimentos cinestésicos da mão direita são perceptíveis com maior fidelidade no hemisfério esquerdo e vice-versa (PFURTSCHELLER; SILVA, 1999).

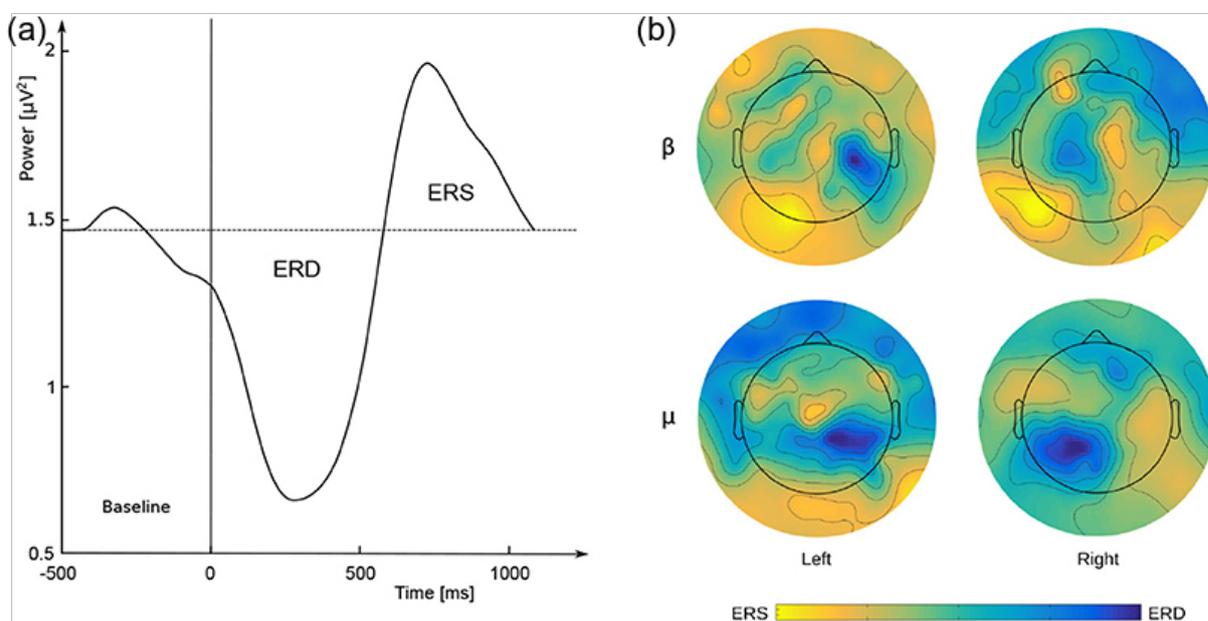
Essa característica é explorada no processamento de sinais de EEG em sistemas ICM-IM no sentido de reconhecer o tipo de tarefa motora realizada com base na diferença de energia entre eletrodos nos dois hemisférios. A Figura 8 ilustra a ocorrência do fenômeno ERS/ERD no sinal de EEG a partir da IM das mãos, nos domínios temporal, com os eventos sequenciais de supressão e aumento da energia no sinal, e espacial, considerando a energia dos ritmos μ_r e β_r .

Apesar da autonomia dada ao usuário por sistemas ICM-IM, ao dispensar o uso de estímulos na geração do ERD/ERS, a modulação voluntária desses fenômenos não é um processo trivial e requer habilidade do usuário em se manter engajado o suficiente a ponto de conseguir alterar a própria atividade cerebral através da IM (CLERC; BOUGRAIN; LOTTE, 2016a).

Essa habilidade, normalmente, é desenvolvida através de etapas de treinamento, as quais costumam gerar fadiga mental ao usuário, mas que são fundamentais para que ele consiga gerar os padrões permitindo que sistemas BCI interpretem suas intenções motoras e gerem sinais de controle (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

A MI exige elevado grau de engajamento do usuário para produzir os padrões necessários para que o sistema possa ser treinado e consiga identificar sua intenção

Figura 8. (a) Exemplo do fenômeno ERD/ERS ao longo de 1 segundo. A linha vertical indica o início da IM (b) mapa topográfico da distribuição da energia do sinal no escalpo durante a IM das mãos esquerda e direita, ao considerar os ritmos sensório-motores



Fonte: Retirada de Wierzgała et al. (2018)

motora através dos sinais de EEG. O grau de engajamento é considerado um fator crítico em sistemas de ICM-IM, uma vez que a supressão de energia no ERD, resultante da dessincronização dos neurônios, na prática, é o que possibilita a identificação da intenção motora via sinais de EEG (MAHMOUDI; ERFANIAN, 2006). Para ilustrar, a Figura 9 apresenta os efeitos no espaço e no espectro do engajamento.

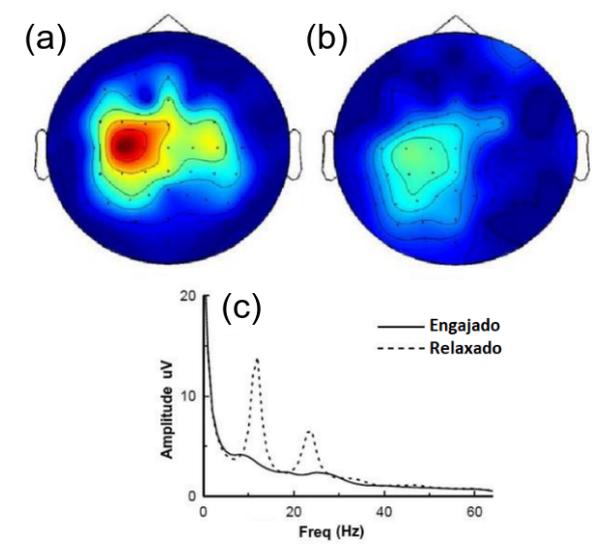
O estado da arte em sistemas ICM contempla, além da grande diversidade de aplicações, a existência de importantes desafios que ainda devem ser superados. Conforme alertam Amiri, Fazel-Rezai e Asadpour (2013a), deficiências como baixa acurácia e confiabilidade, baixa taxa de transferência de informações e condições ruins de usabilidade acabam por limitar o desempenho dos sistemas.

De acordo com Scherer et al. (2013), o fato de que as atividades cerebrais não são estacionárias tampouco universais, dificulta a decodificação adequada do sinal cerebral exigindo treinamento extensivo do usuário.

Em alguns tipos de aplicações, a estabilidade do controle é um fator crítico no desenvolvimento de sistemas de ICM. O desgaste causado pela contínua repetição de tarefas mentais, adicionado a distrações mentais e desconcentração podem levar à perda do controle, o que torna a preocupação com a rotina de treinamento imprescindível na idealização do projeto (NOURMOHAMMADI; JAFARI; ZANDER, 2018).

Neste cenário, de acordo com Choi et al. (2017), versões híbridas de sistemas de ICM surgem como uma alternativa interessante para superação de alguns desses problemas, haja

Figura 9. (a) Visão topográfica da energia dos sinais com o usuário em repouso, ou seja, sem realizar tarefa motora e (b) quando está envolvido em uma tarefa motora, neste caso, movimento da mão esquerda. Em (c) é apresentado o espectro de frequência dos sinais provenientes de um canal localizado no hemisfério direito sincronizado aos eventos em (a) (curva tracejada) e em (b) (curva sólida).



Fonte: Adaptada de Duarte (2017)

vista que proporcionam a complementação entre os paradigmas convencionais individuais a fim de agregar vantagens e dirimir desvantagens.

Choi et al. (2017) definem sistemas de ICM híbridos como a aplicação de diferentes paradigmas, combinando um sistema de ICM com outro sistema não necessariamente de ICM, mas baseado em fenômenos neurológicos ou fisiológicos, com vistas a ampliar a diversidade dos sinais de entrada.

São diversas as combinações possíveis entre paradigmas ICM para caracterização de sistemas híbridos. Taxonomias com base na usabilidade (CHOI et al., 2017) ou no desempenho de classificação (HONG; KHAN, 2017) foram propostas. Hong e Khan (2017) foram além ao revisarem as versões híbridas de ICM também com base no número de comandos. Apesar do vasto universo de possibilidades apresentado nesses estudos, nota-se, uma complementação natural entre alguns paradigmas BCI, como a combinação de IM com SSVEP, por exemplo (ALLISON; NEUPER, 2010).

Não obstante, vale ressaltar que, embora a hibridização esteja sendo considerada uma alternativa em potencial para contornar algumas ineficiências e buscar robustez nos sistemas de ICM, a implementação de sistemas híbridos costuma adicionar complexidade ao projeto e tende a diminuir a usabilidade em alguns casos, especialmente no uso de potenciais ERP (AMIRI; FAZEL-REZAI; ASADPOUR, 2013a).

2.5 Aplicações de ICM

A evolução nas propostas de ICM evidenciada nos últimos anos ampliou o potencial científico e a versatilidade desses sistemas, tornando-os aplicáveis em diversos contextos (GRANDINI, 2017). Na área médica, por exemplo, são crescentes os projetos de sistemas que visam a reabilitação de pessoas que sofreram algum grau de comprometimento das funções motoras, seja por acidentes de trânsito ou por outras lesões cerebrais (RAMOS-MURGUIALDAY et al., 2013).

Diferentes distúrbios podem perturbar os canais neuromusculares através dos quais o cérebro se comunica e controla o ambiente externo (WOLPAW et al., 2002). Acidente vascular cerebral (AVC), lesão medular, paralisia cerebral, esclerose lateral amiotrófica (ELA), entre outras ocasiões podem prejudicar as vias neurais que controlam os músculos e causar perda dos potenciais de comunicação (ISHFAQUE et al., 2013; WOLPAW; WOLPAW, 2012).

Segundo a Organização Mundial de Saúde (OMS), aproximadamente quinhentas mil pessoas ficam incapacitadas anualmente devido à algum tipo de comprometimento severo das funções motoras com interrupção da comunicação entre o SNC e o SNP (DUARTE, 2017; WORLD HEALTH ORGANIZATION; INTERNATIONAL SPINAL CORD SOCIETY, 2013). No Brasil, especificamente, cerca de cerca de 7% da população convive com deficiência motora causada por danos físicos, mentais ou sensoriais (BRASIL, 2010; GIOVANINI, 2017).

Neste contexto, sistemas de ICM especialmente os baseados em imagética motora, ICM-IM, apresentam-se como ferramentas de apoio ao restabelecimento da mobilidade desses pacientes (BASHASHATI et al., 2007; ISHFAQUE et al., 2013). O principal objetivo de sua aplicação, é ampliar o grau de autonomia de indivíduos com inabilidades motoras graves criando um canal alternativo para o cérebro que permita-lhes o controle efetivo de dispositivos como próteses (MENG et al., 2016), cadeiras de rodas (BI; FAN; LIU, 2013) ou algum outro tipo de sistema motor artificial.

No caso de pessoas acometidas por doenças neurodegenerativas como a ELA ou transtornos mentais como o Transtorno do Déficit de Atenção com Hiperatividade (TDAH) (GANDHI et al., 2015), o desenvolvimento desses sistemas idealiza a melhora da qualidade de vida a partir da restauração da independência dos pacientes, propiciando-lhes, a possibilidade da exploração remota de ambientes (LEEB et al., 2015) ou apoio à comunicação (BIRBAUMER et al., 1999).

Além disso, outros estudos com sistemas de ICM aplicados à reabilitação de distúrbios neurais como estresse pós-traumático, ansiedade e até mesmo depressão são frequentemente propostos (PICHIORRI et al., 2015). A Figura 10, por exemplo, ilustra um

sistema de ICM projetado para crianças com TDAH utilizando técnicas de realimentação neural (*neurofeedback*) e ferramentas de realidade virtual.

Figura 10. ICM aplicada ao ensino de crianças com TDAH utilizando imersão virtual



Fonte: Clerc, Bougrain e Lotte (2016b)

Apesar de encontrar amplo campo de aplicação na saúde, em especial na reabilitação de pacientes que perderam suas funções motoras, os estudos que abordam o desenvolvimento de sistemas de ICM não se limitam a área médica (CLERC; BOUGRAIN; LOTTE, 2016b; COYLE, 2016).

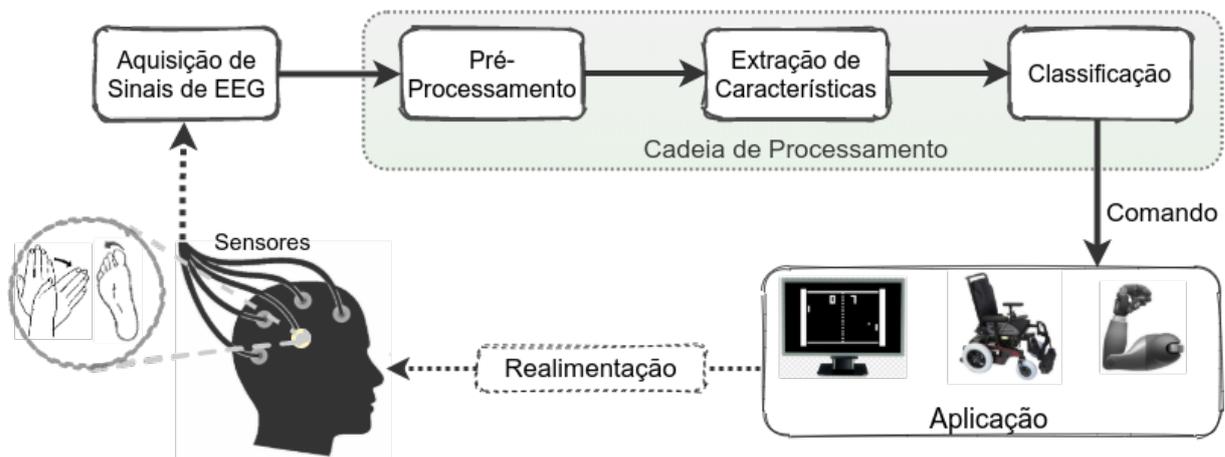
O potencial científico desses sistemas é notório também em outras áreas e abrange uma série de aplicações possíveis. Ambientes inteligentes (EDLINGER; GUGER, 2012; LEE et al., 2013), neuromarketing (VECCHIATO et al., 2010; KHUSHABA et al., 2013), educação (VELLOSO, 2014; HUANG et al., 2014), entretenimento (KAPLAN et al., 2013; VOURVOPOULOS; LIAROKAPIS; CHEN, 2015; BONNET; LOTTE; LÉCUYER, 2013; HOLZ et al., 2013; MARSHALL et al., 2013) e segurança (GÖHRING et al., 2013) também fazem parte do campo de aplicações ICM.

Projetos que visem o controle de aplicações inteligentes ou robóticas, como *drones* (LAFLEUR et al., 2013; DUARTE, 2017) ou braços mecânicos (SUNNY et al., 2016; BOUSSETA et al., 2018) também são frequentemente propostos, comprovando assim a versatilidade desses sistemas bem como sua crescente evolução. Diversas outras aplicações ICM podem ser encontradas em Abdulkader, Atia e Mostafa-Sami (2015), Grandini (2017) e Clerc, Bougrain e Lotte (2016b).

3 ARQUITETURA FUNCIONAL DE ICM-IM

Neste capítulo, os aspectos relacionados especificamente ao projeto de sistemas de ICM-IM são abordados, com destaque para as principais etapas que compõem a arquitetura destes sistemas bem como para as estratégias e ferramentas comumente utilizadas. As seções a seguir cobrem as principais etapas realizadas durante o processamento, desde a aquisição de sinais de EEG até o reconhecimento de padrões que descrevem e classificam a intenção motora do indivíduo. Uma visão geral das etapas de um sistema ICM-IM típico, é apresentada na Figura 11.

Figura 11. Diagrama funcional de um sistema ICM-IM típico. Nas etapas de aquisição e processamento são empregadas ferramentas que possibilitam o controle de aplicações a partir do reconhecimento de padrões nos sinais de EEG.



Fonte: Autoria própria

Ao adotar uma visão mais abrangente, nota-se que a arquitetura de uma ICM-IM contempla basicamente três blocos principais, são eles: aquisição, processamento e controle (ABDULKADER; ATIA; MOSTAFA-SAMI, 2015). O processo sequencial é iniciado pela etapa de aquisição dos sinais elétricos no cérebro utilizando um amplificador de EEG. Em seguida, os sinais "brutos" de EEG são pré-processados com intuito de aprimorar sua representação e realçar as características úteis do ponto de vista do reconhecimento dos padrões ligados à intenção motora.

A expectativa com a extração de características a partir de um sinal devidamente filtrado é que essas descrevam a intenção motora do usuário a partir das informações temporais, espectrais e espaciais intrínsecas nos sinais coletados (LOTTE, 2014). A representação vetorial dessas características é submetida a um classificador com o objetivo de categorizar os dados em um universo previamente definido onde tarefas motoras (e.g. IM da mão esquerda e IM da mão direita) são representadas em classes distinguíveis por padrões específicos (PFURTSCHELLER; SILVA, 1999). A saída desse classificador é

traduzida em um sinal básico de comando que deverá ser enviado à aplicação integrada ao sistema (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Uma característica cíclica ao sistema é imposta pelo processo de realimentação, o qual ocorre em forma de *feedback* para o usuário contribuindo na modulação adequada da atividade cerebral. O tipo de *feedback* fornecido, em geral, está associado ao tipo de aplicação que se deseja controlar, podendo ser tátil, visual, sonoro ou híbrido, por exemplo (CLERC; BOUGRAIN; LOTTE, 2016a). Em caso de *feedback* visual, é comum que a própria resposta da aplicação à tentativa de modulação efetuada pelo usuário seja considerada uma forma de realimentação natural. Aspectos mais aprofundados acerca de cada uma das etapas na Figura 11 serão abordados nas seções a seguir.

3.1 Aquisição de sinais de EEG

Conforme já destacado, a primeira etapa no fluxo de um projeto típico de ICM-IM consiste na aquisição dos sinais de EEG a partir de sensores acoplados no escalpo do indivíduo (CLERC; BOUGRAIN; LOTTE, 2016a). Um amplificador, conectado aos eletrodos, agrega um aparato eletrônico composto por filtros e conversores analógico-digitais capazes de modular os sinais biológicos para processamento usando o computador (FREITAS, 2017).

Em geral, os eletrodos são produzidos de metais condutores como prata ou ouro e podem ser úmidos, requerendo a colocação de gel condutor entre o eletrodo e o couro cabeludo para aumentar a condutibilidade, ou secos, onde o eletrodo é colocado diretamente sobre a pele sem a necessidade de gel, como é o caso dos amplificadores da Figura 12 (NAM; NIJHOLT; LOTTE, 2018).

A coleta do EEG é implicada por algumas dificuldades inerentes à própria técnica de neuroimagem. Um dos desafios é separar o sinal útil de fontes de ruídos persistentes, dentre as quais uma comum refere-se ao aumento de impedância observada ao longo do experimento a partir do uso de eletrodos úmidos. A utilização desses eletrodos exige cuidados extras por parte da equipe técnica na preparação da pele no couro cabeludo e checagem periódica nos níveis de impedância a fim de mantê-los controlados (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

As distorções causadas nos sinais de EEG pela oscilação na impedância, podem ser atenuadas com a reaplicação do gel condutor nos eletrodos durante o experimento, no entanto, esse procedimento requer tempo e, portanto, tende a aumentar a fadiga do usuário (TEPLAN, 2002; SILVA, 2017).

Ao longo dos anos, com o avanço da tecnologia, sistemas de aquisição volumosos e caros, viáveis apenas em ambiente hospitalar e laboratorial por dependerem de uma

estrutura complexa e fixa, como conexão à rede de energia e salas dedicadas (TEPLAN, 2002), vem sendo substituídos por amplificadores portáteis e com baixo custo, possibilitando o projeto de ICMs focadas em usabilidade (CLERC; BOUGRAIN; LOTTE, 2016b).

Tecnologias de aquisição sem fio e os próprios sensores a seco são alternativas importantes que, além de contribuírem para a portabilidade e usabilidade, também atenuam naturalmente os ruídos de rede nos sinais (ou ruídos de linha), antes amplificados pelos meios condutores Abiri et al. (2019).

Apesar de estudos recentes apontarem qualidade inferior em relação aos sinais gravados com eletrodos úmidos (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017), os eletrodos a seco não exigem a aplicação de gel condutor para melhorar a interface eletrodo/couro cabeludo, o que torna a experimentação mais confortável para o usuário. O *trade-off* entre os benefícios de eletrodos úmidos e eletrodos a seco ainda é objeto de estudo constante em pesquisas na neurociência (CLERC; BOUGRAIN; LOTTE, 2016b).

Amplificadores de baixo-custo, projetados com essas tecnologias, como os sistemas de aquisição *Emotiv*¹ e *Neurosky*², por exemplo, apesar da qualidade questionável devido ao número baixo de eletrodos, são amplamente utilizados em pesquisas de ICM atuais (CLERC; BOUGRAIN; LOTTE, 2016b). Wang et al. (2018), Rosca et al. (2018) e Song et al. (2016) por exemplo, utilizam um amplificador *Emotiv* na aquisição de sinais de EEG em seus projetos ICM para controle de *drones*.

Além disso, amplificadores desenvolvidos com foco particular em pesquisas de ICM associam boa qualidade e baixo custo e são cada vez mais frequentes no meio científico, [e o caso dos modelos fornecidos pela iniciativa *OpenBCI*³ (CLERC; BOUGRAIN; LOTTE, 2016b). A Figura 12 ilustra alguns exemplos de amplificadores de EEG de uso potencial em ICM.

Figura 12. Exemplos de amplificadores de baixo custo e baseados em tecnologia sem fio para coleta dos sinais de EEG. Da esquerda para a direita, os dois primeiros são versões disponibilizadas pela empresa *Emotiv* que se diferenciam pelo número de eletrodos e cobertura das áreas corticais enquanto que o último ilustra um amplificador *OpenBCI*



Fonte: Emotiv⁴ e OpenBCI⁵ (2020)

¹ <https://www.emotiv.com>

² <http://neurosky.com>

³ <https://openbci.com>

Conforme destacado na seção 2.3, registros da atividade cerebral com EEG permitem medir diferenças de potencial elétrico ao longo do tempo entre um eletrodo ativo e um eletrodo de referência (TEPLAN, 2002). Um eletrodo de aterramento (GND) também é necessário para quantificar a tensão diferencial entre os pontos ativos e de referência (NAM; NIJHOLT; LOTTE, 2018).

Assim, além do amplificador, a configuração mínima para a medição de EEG requer o posicionamento de pelo menos três eletrodos no escalpo, no entanto, matrizes multicanais densas são encontradas na literatura podendo compreender até 256 eletrodos ativos (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Independentemente do número de eletrodos utilizado, os sinais nos canais estabelecidos são coletados, digitalizados e amostrados pelo amplificador a uma dada taxa F_s , a qual depende da característica do próprio amplificador. Uma vez amostrados e enviados ao computador, os sinais de EEG podem ser processados em tempo real ou armazenados em memória para processamento futuro.

Além dos elementos físicos de coleta, dois outros componentes são fundamentais para o processo de coleta de sinais de EEG em projetos de ICM-IM, são eles: a estratégia de posicionamento dos eletrodos no escalpo e o protocolo experimental usado no treinamento dos usuários e na obtenção de exemplos de EEG que descrevam satisfatoriamente as tarefas mentais para ajuste dos algoritmos (BASHASHATI et al., 2007; PFURTSCHELLER; NEUPER, 2001).

3.1.1 Posicionamento de sensores no escalpo

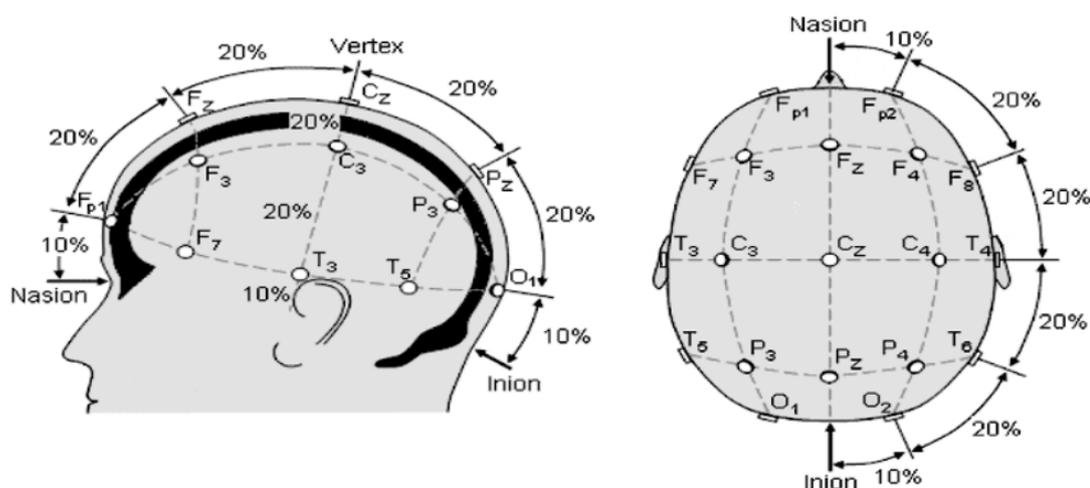
A técnica de EEG coleta a atividade cerebral por meio de uma matriz de eletrodos sistematicamente posicionados no couro cabeludo e, uma vez que a área do córtex tem relação direta com respostas mentais sensório-motoras, o local onde cada eletrodo é posicionado tem total relevância na análise dos sinais pelo sistema ICM-IM. A variação dos ritmos SMR também observada em âmbito espacial torna a distribuição dos eletrodos um aspecto crucial no reconhecimento de padrões que identifiquem a intenção motora do indivíduo (LOTTE, 2014).

A fim de facilitar o trabalho de posicionamento dos eletrodos em locais predefinidos do escalpo e garantir a colocação correta dos eletrodos na superfície da cabeça independentemente do usuário envolvido, padrões internacionais de posicionamento de eletrodos para uso em aquisições de EEG foram propostos ao longo dos anos (JURCAK; TSUZUKI; DAN, 2007). Os sistemas de posicionamento de eletrodos permitem a reprodutibilidade de trabalhos (VAZ, 2016).

O padrão ISO 10-20 (JASPER, 1958), apresentado na Figura 13, é um dos sistemas

de posicionamento amplamente utilizados tanto em pesquisas científicas independentes quanto no meio hospitalar (KHAN; HONG, 2017):

Figura 13. Sistema internacional 10-20 para padronização do posicionamento de eletrodos no escalpo



Fonte: Clerc, Bougrain e Lotte (2016a)

Em linhas gerais, o sistema apresentado determina a posição dos eletrodos definindo distâncias de 10% a 20% em relação às dimensões da cabeça do indivíduo (CLERC; BOUGRAIN; LOTTE, 2016b; WOLPAW; WOLPAW, 2012). Utiliza-se dois pontos de referência para definir a localização dos eletrodos e com isso as porcentagens medem a distância entre a parte superior do nariz (*Nasion*) e a parte posterior da cabeça (*Inion*) (SUBHA et al., 2010).

Na Figura 13 também é possível observar que os eletrodos são rotulados por letras conforme a região do escalpo (ver Figura 2) e hemisfério onde estão posicionados (representação numérica) (GRAIMANN; ALLISON; PFURTSCHELLER, 2010).

As letras correspondem às regiões específicas, onde C representa a região central (córtex motor), P a parietal, F a frontal, Fp a frontal polar, T a temporal e O a área occipital. Os números ímpares, subscritos em cada letra, indicam eletrodos posicionados no hemisfério esquerdo e os números pares, no hemisfério direito. O subscrito z indica eletrodos posicionados na linha central, no plano sagital que separa os dois hemisférios (CLERC; BOUGRAIN; LOTTE, 2016a; BERNARDI, 2018).

Embora o sistema 10-20 tenha sido o padrão mais comum em pesquisas recentes (WOLPAW; WOLPAW, 2012; SUBHA et al., 2010), outros sistemas de posicionamento listados em Jurcak, Tsuzuki e Dan (2007) também são aplicáveis à sistemas de ICM. Quando uma cobertura mais ampla da superfície encefálica é necessária, por exemplo, o sistema 10-10 pode ser uma alternativa por projetar uma matriz mais densa de eletrodos.

Nesse caso, eletrodos intermediários são adicionados com base nos pontos de referência do sistema 10-20 (SHARBROUGH, 1991).

3.1.2 Protocolo experimental de coleta

A modulação da atividade cerebral a partir de simulações motoras nem sempre é uma tarefa trivial e requer habilidade por parte do indivíduo. Este fato torna comuns os casos em que o indivíduo é incapaz de gerar os padrões necessários para que a ICM-IM detecte sua real intenção (ALLISON et al., 2010). Alguns estudos apontam que um percentual significativo de usuários podem apresentar este tipo de comportamento, conhecido na literatura como analfabetismo em ICM, sendo que o número de casos pode aumentar ou diminuir a depender das técnicas de aquisição e processamento adotadas bem como se o ambiente onde os experimentos são realizados é muito ou pouco controlado (LEE et al., 2019; MASKELIUNAS et al., 2016).

Outrossim, mesmo em usuários experientes, atividades mentais muito específicas geram sinais altamente não estacionários por dependerem de diversos fatores relacionados ao estado geral do indivíduo no momento da coleta (CLERC; BOUGRAIN; LOTTE, 2016a). Neste sentido, a fim de prover um roteiro de coleta controlada, a implementação de um sistema de ICM-IM normalmente requer um protocolo experimental com eventos organizados cronologicamente a fim de permitir a obtenção de sinais de EEG em sincronia com a execução de tarefas cognitivas específicas (SILVA, 2017).

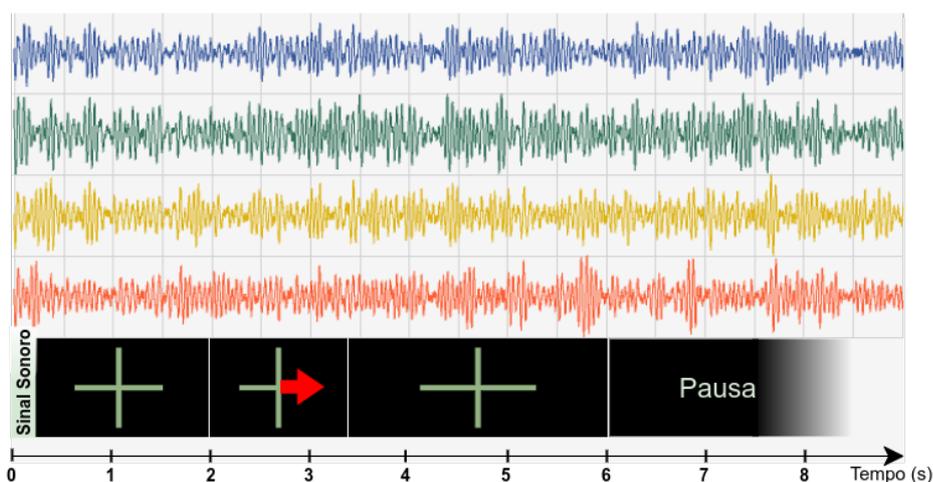
Os principais objetivos de se usar um protocolo de coleta no escopo de sistemas ICM-IM estão relacionados à: (i) treinamento do usuário para modulação satisfatória da atividade cerebral e geração do fenômeno associado à intenção motora; (ii) obtenção de exemplos rotulados para ajuste supervisionado dos algoritmos na cadeia de processamento (PFURTSCHELLER; NEUPER, 2001).

Para tanto, uma sequência de instruções orienta o usuário a executar ações sob demanda e em momentos específicos enquanto os sinais de EEG e a cronologia de cada evento são registrados. Uma única execução da sequência de instruções é denominada ensaio (ou tentativa). Múltiplos ensaios são realizados a fim de que o usuário seja sistematicamente submetido à uma lista de dicas que o indicam qual tarefa motora executar e em que momento deve iniciar o engajamento em cada ensaio, enquanto permanece sentado confortavelmente em uma cadeira em frente a um monitor (ABIRI et al., 2019).

A execução sob demanda de tarefas motoras e a marcação dos instantes em que cada classe de IM é executada pelo usuário ao longo de toda a coleta, permitem que segmentos de EEG sejam associados à tarefas específicas, o que é especialmente útil para ajustar os algoritmos de aprendizado de máquina (CLERC; BOUGRAIN; LOTTE, 2016a).

Um protocolo experimental frequentemente adotado na coleta de sinais de EEG para sistemas de ICM-IM, atende por protocolo *Graz* (PFURTSCHELLER; NEUPER, 2001; BRUNNER et al., 2008). O protocolo é assim intitulado por ter sido originalmente proposto por pesquisadores da Universidade Austríaca de *Graz*. Foi idealizado justamente para uso em pesquisas com ICM-IM e é bastante difundido no meio científico (MÜLLER-PUTZ et al., 2016). A Figura 14 apresenta um exemplo de ensaio baseado no protocolo *Graz*, típico em ICM-IM.

Figura 14. Cronologia baseada no protocolo *Graz*. Uma sequência com duração média de 8 segundos é iniciada com um breve alerta sonoro junto à fixação de uma cruz na tela. Entre 2 e 3,25 uma seta indica qual tarefa de IM deve ser realizada nos 4 segundos subsequentes enquanto a cruz fixa permanecer na tela. Um período de pausa para descanso de até 2,5 segundos estabelece a transição entre dois ensaios consecutivos.



Fonte: Autoria própria, inspirado em Clerc, Bougrain e Lotte (2016a) e Brunner et al. (2008).
Sinais gerados via software *OpenBCI*

Como pode ser observado, a sequência de instruções apresentada ao usuário obedece a uma cronologia pré-definida que, em geral, consiste em quatro eventos: preparação, dica, execução da tarefa e pausa. O alerta sonoro junto à fixação da cruz na tela informam o usuário para se concentrar na realização da tarefa iminente. Dicas em forma de setas direcionais são usadas para instruir o usuário sobre qual tarefa motora executar (e.g. IM das mãos, pés e língua). O início e a duração de cada evento, em cada ensaio, são registrados em sincronia com o conjunto completo de sinais de EEG possibilitando o cruzamento futuro (BRUNNER et al., 2008; WOLPAW; WOLPAW, 2012).

3.1.3 Bases públicas de dados

Embora sejam notórios os avanços no sentido de descomplicar o processo de coleta de sinais de EEG, em especial através da modernização dos amplificadores e revisão de protocolos experimentais, a aquisição em larga escala, a partir de um grande número

de sujeitos e de ensaios, ainda requer uma estrutura laboratorial especializada que nem sempre mostra-se viável (VAZ, 2016).

Nesse contexto, os conjuntos de dados públicos de EEG têm sido importantes para o avanço acelerado em pesquisas no contexto de sistemas BCI. Dentre as principais contribuições, permitem a validação *off-line* de novas abordagens e ferramentas bem como ampliam reprodutibilidade dos resultados para comparação qualitativa entre os estudos a partir de dados confiáveis e consolidados (TANGERMANN et al., 2012).

Com o objetivo de estimular a cooperação entre pesquisadores e o compartilhamento do conhecimento, em geral, os dados de EEG são coletados profissionalmente e disponibilizados por meio de competições internacionais, organizadas por grupos e instituições de pesquisa para que novos algoritmos de aprendizado de máquina aplicados ao processamento de sinais em sistemas BCI sejam testados e validados (TANGERMANN et al., 2012; BRUNNER et al., 2008).

3.2 Processamento de sinais de EEG em sistemas de ICM-IM

Como visto, os sinais de EEG coletados na etapa de aquisição mantêm informações do potencial elétrico em cada eletrodo ao longo do tempo. De acordo com Clerc, Bougrain e Lotte (2016a), as informações contidas no EEG são provenientes de diferentes fontes, as quais se misturam às informações relativas à atividade cerebral e podem apresentar variações de amplitude significativas ao serem analisadas no tempo, na frequência e no espaço.

Para possibilitar o reconhecimento do fenômeno ERS/ERD associado à determinada tarefa motora na atividade cerebral, após a etapa de aquisição, os sinais de EEG são submetidos à transformações progressivas realizadas com o objetivo final de ressaltar informações relevantes do ponto de vista de classificação da intenção motora do indivíduo (BLANKERTZ et al., 2008a).

Diante disso, as etapas na cadeia de processamento que sucedem a aquisição são fundamentais no projeto de sistemas de ICM-IM, uma vez que são responsáveis pelo aprimoramento dos sinais tornando factível o reconhecimento de padrões em sinais originalmente ruidosos (KUMAR; INBARANI, 2017). Conforme indica Vaz (2016), o processamento de sinais é um dos principais desafios encontrados em sistemas ICM, sendo que o projeto de sistemas com desempenho e usabilidade satisfatórios depende da escolha de técnicas eficazes de filtragem, extração de características e classificação.

Anterior à explanação das principais etapas da cadeia de processamento típica de sistemas ICM-IM apresentada na Figura 11 bem como das técnicas comumente empregadas em cada uma dessas etapas, a seção 3.2.1 introduz um aspecto fundamental da abordagem

comumente empregada nesses sistemas que permite o reconhecimento de padrões de IM em sinais de EEG em tempo real.

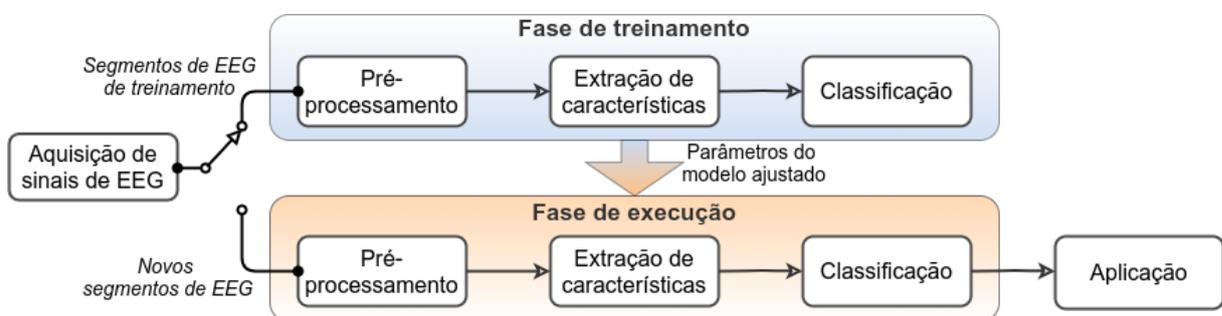
3.2.1 Fases de operação

Um aspecto importante no projeto típico de sistemas de ICM-IM diz respeito ao fato de que a arquitetura de processamento é projetada levando-se em consideração duas fases sequenciais, normalmente denominadas de fase de treinamento e fase de execução (NAM; NIJHOLT; LOTTE, 2018). A principal razão para a divisão do projeto em duas fases relaciona-se com o tipo de aprendizado definido em sistemas ICM-IM típicos, o qual geralmente corresponde à um problema de aprendizado supervisionado (NICOLAS-ALONSO; GOMEZ-GIL, 2012; GRAIMANN; ALLISON; PFURTSCHELLER, 2010).

Os algoritmos responsáveis pelo reconhecimento dos padrões de IM nos sinais de EEG são ajustados na fase de treinamento e um modelo de classificação é obtido a partir de um grupo de exemplos previamente rotulados, comumente chamado de conjunto de treinamento. Na fase de execução, o modelo ajustado é usado para classificar novos segmentos de EEG, os quais podem ser coletados previamente com o intuito de validar o modelo de classificação (execução *off-line*) ou coletados em tempo real a fim de ser possível controlar uma aplicação (execução *on-line*) (LOTTE et al., 2018; ANG; GUAN, 2016).

Para ilustrar a vertente do aprendizado supervisionado no escopo de ICM-IM, a representação da Figura 15 expande a visão genérica do sistema mostrada anteriormente de modo a contemplar as duas fases sequenciais de operação mencionadas.

Figura 15. Fases de operação em sistemas de ICM-IM. Um conjunto de treinamento suficientemente grande, composto por segmentos de EEG e seus respectivos rótulos de classes IM, é usado para ajustar os algoritmos e criar um modelo de classificação que em seguida pode ser usado na classificação de novos segmentos de EEG



Fonte: Adaptado de Ang et al. (2012a) e Gubert (2019)

Nota-se a partir da Figura 15 que as etapas de processamento se equivalem nas duas fases de operação, sendo o controle da aplicação possível somente durante a fase de execução após o ajuste do modelo. Para tanto, segmentos de EEG são extraídos periodicamente do fluxo contínuo de sinais fornecido pelo amplificador em tempo real,

submetidos às transformações sequenciais durante o processamento e, eventualmente, a saída do classificador é convertida em sinais de comando para a aplicação.

Uma vez que o ajuste dos algoritmos na fase de treinamento depende de múltiplos exemplos rotulados, i.e. segmentos de EEG associados à classes de IM, a obtenção desse conjunto de treinamento é um requisito obrigatório em sistemas de ICM-IM síncronos. Para satisfazer a esse requisito, normalmente realiza-se a segmentação dos sinais coletados em porções menores de EEG, nas quais espera-se que os padrões de IM estejam descritos (NOOH; YUNUS; DAUD, 2011; NAM; NIJHOLT; LOTTE, 2018).

Logo, a extração de épocas, conforme é conhecido o processo de segmentação, representa uma etapa importante na arquitetura de sistemas de ICM-IM síncronos, com o protocolo experimental centrado na dica exercendo um papel crucial na composição do conjunto de treinamento e por consequência no ajuste do modelo (PFURTSCHELLER; SILVA, 1999).

3.2.1.1 Extração de épocas de EEG

Conforme mencionado na seção 3.1.2 um dos objetivos do protocolo experimental durante a coleta de sinais de EEG é a obtenção de exemplos rotulados para calibração supervisionada dos algoritmos de aprendizagem (PFURTSCHELLER; NEUPER, 2001). Em uma única sessão de coleta na fase de treinamento múltiplas repetições do protocolo experimental, denominadas ensaios, são executadas para que o usuário realize por várias vezes cada imagética motora desejada.

O conjunto completo de sinais de EEG, coletado enquanto as instruções são apresentadas em cada ensaio, é armazenado como matriz bidimensional de modo que as colunas representem os sensores no escalpo e as linhas representam as amostras obtidas de cada sensor ao longo do tempo de coleta, incluindo as pausas entre os ensaios. Como cada ensaio inclui eventos organizados cronologicamente, os rótulos dos eventos e as amostras que marcam o início de cada evento também são registrados para que seja possível extrair segmentos de EEG sincronizados com a realização de IM (DUARTE, 2017; BRUNNER et al., 2008).

O evento que instrui o usuário sobre quando e qual IM realizar, ou *dica*, pode servir como um referencial para delimitar o segmento de EEG em que é esperada a ocorrência de IM. Dessa forma, pode-se extrair uma porção menor dos sinais, tipicamente denominada de época, e desprezar sinais coincidentes à eventos marginais, ou seja, que não estão diretamente relacionados com a realização da IM propriamente dita (WEI; WEI, 2016). Portanto, o momento em que a dica é fornecida exerce um papel crucial na extração de exemplos para compor o conjunto de treinamento (NAM; NIJHOLT; LOTTE, 2018;

MÜLLER-PUTZ et al., 2016).

Em uma sessão de coleta hipotética onde 100 ensaios são executados, sendo que em 50 deles é indicada a realização de IM da mão esquerda e em outros 50 da mão direita por exemplo, pode-se extrair 100 épocas de EEG em torno do momento da apresentação da dica, 50 para cada classe de IM. Neste caso, o conjunto de treinamento pode ser formado pelas épocas extraídas, juntamente com os respectivos rótulos de classe.

No entanto, apesar de a sequência mostrada na Figura 14 sugerir que o usuário está engajado na tarefa mental durante todo o período entre o momento em que a dica é fornecida e o início da pausa para descanso, a manutenção do engajamento por um período longo de tempo, de modo a preservar a caracterização do fenômeno de IM no sinal de EEG é improvável (BRUNNER et al., 2008; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

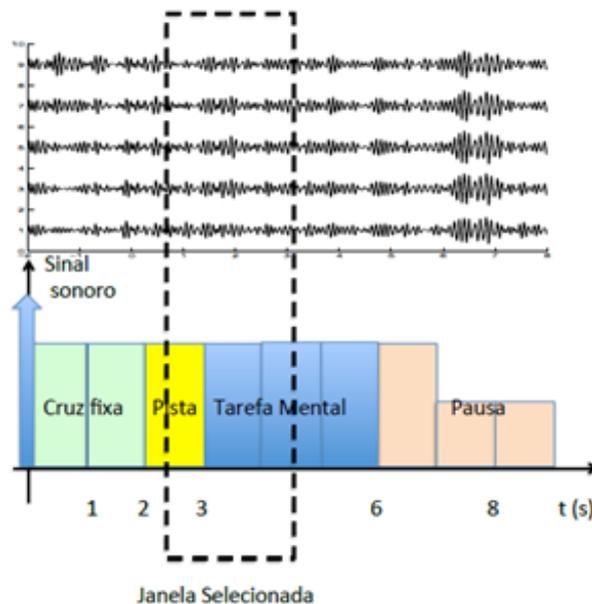
Aliás, a manutenção do engajamento por parte do usuário é um ponto crítico no âmbito de sistemas ICM-IM, dada a característica não estacionária dos ritmos SMR no sinal de EEG ligada ao fato de que esses ritmos são sensíveis ao estado de atenção do indivíduo que tende a cair com o tempo. Este aspecto contribui para que o processo de aquisição de sinais seja desgastante para o experimentador e especialmente para o usuário (CLERC; BOUGRAIN; LOTTE, 2016a).

Portanto, sabendo que o nível de engajamento normalmente é mantido por períodos curtos de tempo, uma estratégia comum é a adoção de uma janela temporal, J , menor que o período entre a dica e a pausa, para extração de épocas de EEG (GRAIMANN; ALLISON; PFURTSCHELLER, 2010). Tal janela pode ser descrita, basicamente por duas propriedades, a largura e a localização em relação à dica, e uma versão tipicamente adotada na literatura é apresentada na Figura 16.

Observa-se que a janela na Figura 16 possui uma largura de 2 segundos e está localizada estrategicamente próxima à dica de modo a representar o segmento de EEG coletado enquanto espera-se o máximo do engajamento do usuário. A janela é usada para extrair uma época de EEG a cada ensaio do protocolo experimental, com a quantidade de amostras por canal sendo múltipla da taxa de amostragem, F_s .

Dada a disposição matricial bidimensional dos sinais de EEG, uma única época de EEG pode ser denotada de forma genérica pela matriz $\mathbf{Z} \in \mathbb{R}^{P \times Q}$, cujas dimensões referem-se aos P canais de EEG e às Q amostras por canal, observada a taxa F_s . Para identificar a classe de IM associada à determinada época \mathbf{Z} , um rótulo alfabético ρ pode ser definido conforme a dica no ensaio correspondente.

Figura 16. Janela temporal iniciada 0,5 segundo após a dica visual e com largura de 2 segundos a qual é tipicamente adotada na extração de épocas de EEG em sistemas de ICM-IM



Fonte: Silva (2017)

3.2.2 Pré-processamento e aprimoramento dos sinais

Em suma, a discussão anterior acerca das fases de operação em uma ICM-IM, pretendia esclarecer que o reconhecimento de padrões em sinais de EEG coletados em tempo real, depende do treinamento dos algoritmos na cadeia de processamento e do ajuste dos parâmetros de um modelo de classificação.

Isto posto, independente da fase de operação, o processamento típico de sinais de EEG em sistemas de ICM-IM pode ser essencialmente segregado nas três etapas sequenciais apresentadas tanto na Figura 11 quanto na Figura 15, tais quais: pré-processamento, extração de características e classificação.

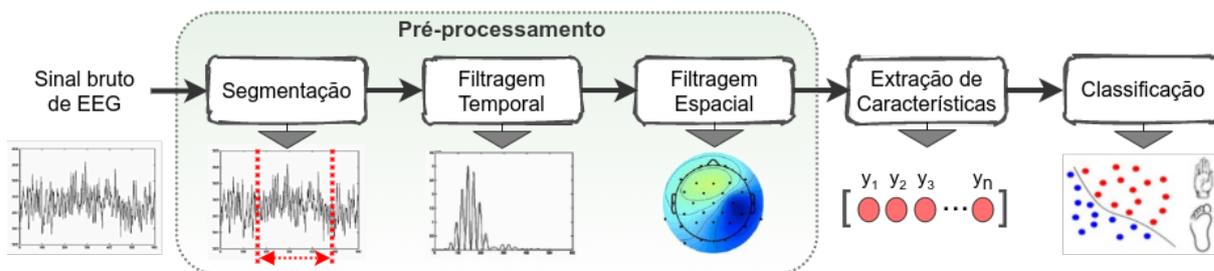
Em se tratando da primeira destas etapas, especificamente, o pré-processamento tem como objetivo primordial o tratamento dos sinais de EEG de forma a possibilitar a caracterização de informações relevantes que descrevam a intenção motora do indivíduo (BLANKERTZ et al., 2008a).

Ao anteceder qualquer uso significativo da informação contida nos sinais, para fins de discriminação entre as classes de IM, as transformações realizadas no pré-processamento buscam detectar, atenuar e remover ruídos indesejáveis com potencial de prejudicar a qualidade dos registros da atividade sináptica bem como destacar características úteis nos sinais (SILVA, 2017).

De maneira a evidenciar os passos no pré-processamento, a Figura 17 apresenta uma versão expandida da sequência apresentada nas figuras anteriores, na qual é possível

observar que esta etapa corresponde à uma série de sub-etapas, cada qual responsável por uma função bem definida na cadeia e que serão abordadas na sequência.

Figura 17. Diagrama funcional expandido de um sistema ICM-IM. A etapa de pré-processamento compreende sub-etapas sequenciais que visam o aprimoramento dos sinais de entrada para auxiliar no processo de extração das características descritivas e classificação das intenções cognitivas



Fonte: Autoria própria

Além do tratamento dos sinais nas etapas de filtragem temporal e espacial, dentre as ações realizadas durante o pré-processamento está incluída a própria etapa de segmentação, que compreende tanto o processo de extração de épocas do conjunto completo de dados de EEG na fase de treinamento bem como a extração do segmento de sinal a ser processado pelo sistema a partir do fluxo contínuo fornecido pelo amplificador na fase de execução.

Uma vez que o conjunto de sinais esteja devidamente segmentado, as etapas subsequentes realizam a filtragem dos sinais nesses segmentos a fim de tornar seu conteúdo mais discriminativo do ponto de vista de IM. Duas fontes de informação adicionais, para além da informação temporal dos eventos na coleta, ainda podem ser encontradas: variações do potencial elétrico em determinadas faixas do espectro de frequência (informação espectral) e variações nos efeitos de propagação no cérebro a partir da tarefa motora realizada (informação espacial) (LOTTE, 2014).

Para extrair tais informações, duas fases de filtragem são comumente empregadas, a filtragem temporal (ou espectral) e a filtragem espacial, sequenciadas conforme a Figura 17. Primeiramente, filtros temporais buscam remover ou atenuar ruídos provenientes de diversas fontes e isolar a informação relevante nos sinais de EEG. Em seguida, transformações matemáticas baseadas na variância dos sinais em cada sensor de EEG são realizadas para captura da informação espacial contida, de modo a possibilitar a identificação de características que descrevam cada classe de IM de acordo com a localização no escalpo (GRAIMANN; ALLISON; PFURTSCHELLER, 2010; CLERC; BOUGRAIN; LOTTE, 2016b).

Ambas as etapas de filtragem desempenham papéis fundamentais no contexto de sistemas de ICM-IM, haja vista que coexistem para caracterizar nos sinais o fenômeno provocado pela intenção motora do indivíduo, em especial no âmbito espectral e espacial.

Devido à uma representação mais clara do sinal resultante desses processos, um vetor de características pode ser extraído e submetido à classificação da tarefa motora representada.

Para uma análise mais aprofundada das funções exercidas, as sub-seções a seguir descrevem as particularidades acerca dos processos de filtragem temporal e espacial. Vale destacar que as etapas de filtragem podem ser projetadas com base em uma abordagem mais simples (DUARTE, 2017), usando um único filtro temporal e um único filtro espacial ou com base em uma abordagem mais robusta usando um banco de filtros (NOVI et al., 2007).

A fim de tornar mais clara a descrição das etapas de filtragem, as sub-seções a seguir consideram a abordagem mais clássica, de banda única. Os detalhes em torno da abordagem baseada em banco de filtros são introduzidos futuramente na seção 3.2.5, após a discussão de todas as etapas típicas de processamento ICM-IM.

3.2.2.1 Filtragem temporal

A atividade elétrica registrada na superfície do couro cabeludo via EEG contém, além dos biopotenciais úteis, ruídos indesejáveis do ponto de vista de sistemas de ICM-IM. Um ruído comum e inerente à amplificadores de EEG, por exemplo, é gerado pela própria rede de eletrodos e pode ser identificado no espectro de frequência a uma faixa que varia entre 50 e 60Hz.

Por ser de fácil caracterização espectral e por ter origem técnica, este tipo de ruído, frequentemente intitulado ruído de circuito elétrico ou simplesmente ruído de rede, é comumente removido pela maioria dos amplificadores profissionais por meio de filtros do tipo *notch* ou rejeita faixa (TEPLAN, 2002). Interferências causadas pela oscilação da impedância, conforme abordado na seção 3.1, também apresentam-se como uma fonte de ruído recorrente.

Além dos ruídos de natureza técnica, biopotenciais indesejados, oriundos da atividade elétrica em outras partes do corpo humano, podem interferir significativamente na leitura do potencial elétrico que descreve a atividade neuronal no EEG (NIDAL; MALIK, 2014). Esses ruídos, usualmente referenciados como artefatos, são originados de fontes diversas como: piscadas ou movimento do globo ocular (eletrooculografia - EOG); atividade muscular da cabeça, especialmente pescoço e mandíbula (eletromiografia - EMG); atividade cardíaca (eletrocardiografia - ECG); entre outros (FATOURECHI et al., 2007; URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Ademais, como os sinais de EEG descrevem a diferença de potencial entre um eletrodo posicionado em um ponto específico do escalpo e um eletrodo de referência, a própria estrutura de tecidos presentes entre os eletrodos e o córtex cerebral (couro cabeludo,

ossos e membrana cortical) também gera interferências importantes na mensuração da atividade sináptica por EEG (SANEI; CHAMBERS, 2007). Em geral, artefatos biológicos no sinal de EEG, estão representados em amplitudes e frequências mais altas em relação aos ritmos da atividade elétrica cerebral, o que define a baixa SNR (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Conforme discutido na seção 2.4, o fenômeno de (des)sincronização de energia representativo da realização de tarefas de imagética motora é tipicamente observado em baixas frequências, especialmente as faixas que correspondem aos ritmos μ_r e β_r da atividade cerebral. Uma vez que a mudança de potencial nessas faixas define os sinais de controle em sistemas ICM-IM, faz-se necessário explorar as informações espectrais do sinal (BASHASHATI et al., 2007; PFURTSCHELLER; NEUPER; BIRBAUMER, 2005).

Nesse sentido, diferentes ferramentas tem sido propostas com intuito de atenuar ruídos e extrair as informações relevantes dos sinais de EEG aplicados à sistemas de ICM-IM (CHAUMON; BISHOP; BUSCH, 2015; ISLAM; RASTEGARNIA; YANG, 2016; KHAN; ISLAM; MOLLA, 2016; JAS et al., 2017). Métodos de filtragem temporal, também chamada de filtragem espectral, como filtros digitais clássicos de resposta impulsiva finita (FIR, do inglês *Finite Impulse Response*) e os de resposta impulsiva infinita (IIR, do inglês *Infinite Impulse Response*) são amplamente utilizados no escopo de ICM (URIGÜEN; GARCIA-ZAPIRAIN, 2015; WIDMANN; SCHRÖGER; MAESS, 2015; CHEN; HE; PENG, 2014).

Abordagens baseadas em decomposição em frequência usando Transformada Discreta de *Fourier* (DFT, do inglês *Discrete Fourier Transform*), Transformada de *Fourier* de Tempo Curto (STFT, do inglês *Short Time Fourier Transform*) ou Transformadas *Wavelet*, por exemplo, também são frequentemente empregadas a fim de melhorar a qualidade do sinal e limitar a informação contida nos sinais de EEG aplicados à sistemas ICM-IM (BASHAR; BHUIYAN, 2016; LU et al., 2017; KEVRIC; SUBASI, 2017).

As seções subsequentes apresentam uma breve descrição dos métodos de filtragem temporal/espectral adotados neste trabalho com o objetivo de atenuar ruídos e selecionar faixas de frequências relevantes do ponto de vista de classificação de tarefas motoras.

3.2.2.1.1 Filtros digitais de resposta impulsiva

O principal objetivo de um filtro no processamento de sinais é atenuar ruídos de forma a preservar o sinal de interesse. Dentre outras formas, filtros digitais podem ser classificados como: passa-baixa (ao atenuar frequências altas), passa-alta (ao atenuar baixas frequências), passa-faixa (ao atenuar frequências altas e baixas) e rejeita faixa (ou *notch*) (ao atenuar bandas específicas de frequência) (SANEI; CHAMBERS, 2007).

Filtros digitais podem ser caracterizados pela resposta ao impulso e pela fase. Os filtros IIR e FIR são filtros digitais que se diferenciam principalmente pela duração da resposta a um determinado impulso (WIDMANN; SCHRÖGER; MAESS, 2015). Ambos representam sistemas lineares e invariantes no tempo que utilizam um número finito de amostras no sinal não filtrado para determinar o sinal filtrado (IFEACHOR; JERVIS, 2002; SILVA, 2017).

No escopo de sistemas de ICM, ao assumir a matriz de posto completo $\mathbf{Z} \in \mathbb{R}^{P \times Q}$ para representar uma única época de EEG com P canais e Q amostras por canal, cujo segmento de sinal supõe-se não ter recebido nenhum processamento (i.e. sinal bruto), o processo de filtragem do p -ésimo sinal em \mathbf{Z} usando um filtro digital do tipo IIR, por exemplo, pode ser descrito na forma de:

$$\tilde{x}_{pq} = \frac{1}{a_0} \left(\sum_{i=0}^{\Theta} a_i z_{p(q-i)} - \sum_{j=0}^{\Theta} b_j z_{p(q-j)} \right), \quad \forall q = 0, 1, 2, \dots, Q, \quad (3.1)$$

em que $p \in \{1, 2, \dots, P\}$, z_{pq} representa a q -ésima amostra do p -ésimo sinal em \mathbf{Z} enquanto que a_i e b_j são os coeficientes do filtro cujas dimensões são definidas pela ordem Θ . Nota-se que as ordens do filtro correspondem às últimas amostras do p -ésimo sinal bruto de EEG utilizadas na obtenção do sinal filtrado $\tilde{\mathbf{x}}_p$.

Quanto ao processo de filtragem por meio de um filtro do tipo FIR aplicado ao p -ésimo sinal referente ao mesmo segmento de sinal bruto de EEG, este por sua vez, pode ser descrito conforme a equação:

$$\tilde{x}_{pq} = \sum_{j=0}^{\Theta} b_j z_{p(q-j)}, \quad \forall q = 0, 1, 2, \dots, Q, \quad (3.2)$$

onde a_i é um dos coeficientes do filtro que definem a convolução do sinal \mathbf{z}_p (WIDMANN; SCHRÖGER; MAESS, 2015).

Observa-se que, no caso de filtros FIR, os coeficientes em \mathbf{a} são nulos, e portanto, a Eq. 3.2 é, basicamente, a Eq. 3.1 com o primeiro termo cancelado. Apesar deste fato produzir uma representação mais estável, filtros FIR requerem valores elevados de ordem Θ e com isso mais coeficientes em relação aos filtros IIR, o que denota maior complexidade (DUARTE, 2017).

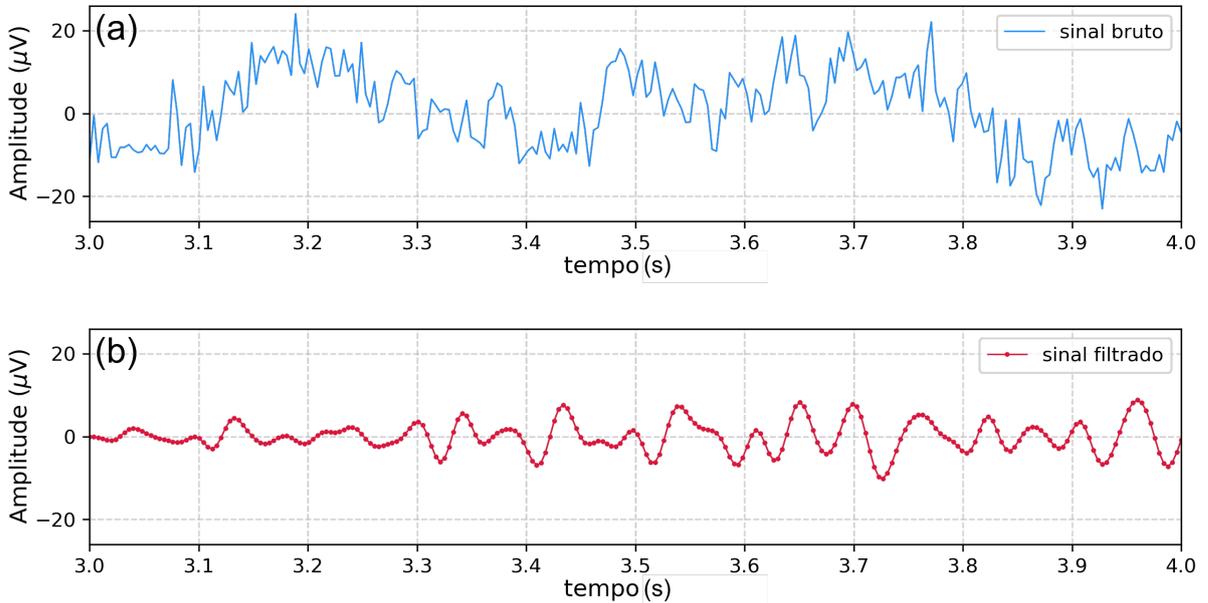
Para ambos os filtros, os coeficientes são determinados em função da resposta impulsiva desejada que pode ser obtida a partir de projetos de filtros consolidados na literatura (SANEI; CHAMBERS, 2007; IFEACHOR; JERVIS, 2002). O filtro *Butterworth*, por exemplo, é um dos projeto de filtro IIR mais difundidos no campo da filtragem de sinais biomédicos (ACUNZO; MACKENZIE; van Rossum, 2012).

A aplicação de técnicas de filtragem temporal ao sinal, as amostras adquiridas em função do tempo são combinadas para gerar uma nova versão do sinal de entrada, com a representação dos ruídos reduzida (DUARTE, 2017).

A fim de possibilitar a identificação da informação espectral nos sinais, de forma a preservar o conteúdo espectral em uma faixa de interesse e atenuar ruídos, a aplicação de filtros passa-faixa requer parâmetros que definem a faixa de frequências de interesse. Isto posto, seja $\Delta_f \triangleq [F_l, F_u]$, o intervalo cujos extremos F_l e F_u representam, respectivamente, as frequências de corte inferior e superior em *Hertz*, o processo de filtragem temporal se dá em função da ordem do filtro passa-faixa, Θ , e das frequências compreendidas por Δ_f .

Como forma de ilustrar a atenuação de ruído na filtragem temporal, um segmento de sinal bruto z_p , correspondente ao p -ésimo canal em uma única época de EEG $\mathbf{Z} \in \mathbb{R}^{P \times Q}$, foi utilizado para gerar as curvas na Figura 18. No gráfico 18-a o segmento de sinal é apresentado em função do tempo ao passo que 18-b representa o sinal filtrado por um filtro passa-faixa IIR considerando uma faixa de frequência específica.

Figura 18. (a) Segmento de sinal bruto de EEG referente ao canal localizado em C3 (hemisfério esquerdo) com $Q = 250$ amostras; (b) mesmo segmento de sinal, filtrado usando um filtro passa-faixa butterworth de 5ª ordem com Δ_f definido entre as frequências de corte $F_l = 8$ e $F_u = 30Hz$.



Fonte: Autoria própria

Vale ressaltar que a dimensão do sinal resultante \tilde{x}_p não se altera em relação ao sinal bruto z_p , mantendo-se igual à Q . Logo, define-se a matriz de posto completo $\tilde{\mathbf{X}} \in \mathbb{R}^{P \times Q}$ para representar genericamente os sinais filtrados de uma dada época de EEG.

3.2.2.1.2 Transformada Discreta de *Fourier* (DFT)

Dada a caracterização espectral do fenômeno de IM, representações no domínio da frequência também tem sido amplamente utilizadas como estratégias de filtragem de sinais de EEG em sistemas de ICM, dentre as quais destaca-se a DFT (BUENO, 2017; LU et al., 2017). Ao assumir que todo sinal é resultante de uma combinação de sinais senoidais de diferentes amplitudes e frequências, a DFT altera a representação de um sinal de seu domínio original, geralmente tempo ou espaço, em uma representação no domínio da frequência. A ferramenta possui notória importância em diversas áreas e é amplamente utilizada para extração de informação espectral em sinais discretos (OPPENHEIM; WILLSKY; NAWAD, 2010; BERNARDI, 2018).

Uma das formas de obtenção da DFT de um sinal se dá através do algoritmo da transformada rápida de *Fourier* (FFT, da sigla em inglês para *Fast Fourier Transform*). O algoritmo obtém, de forma eficiente, a representação do sinal ao decompô-lo nas bases senoidais a partir de suas harmônicas, transformando-o em um conjunto de coeficientes associados à diferentes frequências (OPPENHEIM; WILLSKY; NAWAD, 2010).

A transformação realizada pela FFT possibilita que o conteúdo espectral do sinal seja analisado a partir dos coeficientes de *Fourier* os quais aferem a contribuição de cada componente em frequência das funções seno e cosseno (GRAPS, 1995). No contexto deste trabalho, a FFT é utilizada para representação dos sinais de EEG em uma matriz de coeficientes cujos componentes mantém o conteúdo espectral dos sinais em uma faixa de frequência específica.

Nesse sentido, seja $\mathbf{Z} \in \mathbb{R}^{P \times Q}$ uma única época de EEG com P canais e Q amostras por canal, ao aplicar o algoritmo da FFT aos sinais em cada um dos P canais representados, obtém-se a informação espectral contida em \mathbf{Z} na forma da matriz $\ddot{\mathbf{X}} \in \mathbb{C}^{P \times Q}$ cujos elementos da p -ésima linha são definidos por,

$$\ddot{x}_{pc} = \sum_{q=0}^{Q-1} z_{pq} e^{-j \frac{2\pi}{Q} cq}, \quad \forall c = 0, 1, 2, \dots, Q-1 \quad , \quad (3.3)$$

onde $p \in \{1, 2, \dots, P\}$, z_{pq} representa a q -ésima amostra do p -ésimo sinal em \mathbf{Z} e os termos nos c -ésimos coeficientes complexos correspondem à decomposição do sinal na base de *Fourier*. Tais coeficientes equivalem à projeção do p -ésimo sinal nas bases cossenoidal e senoidal, respectivamente, podendo ainda ser representados conforme a identidade de *Euler* na forma:

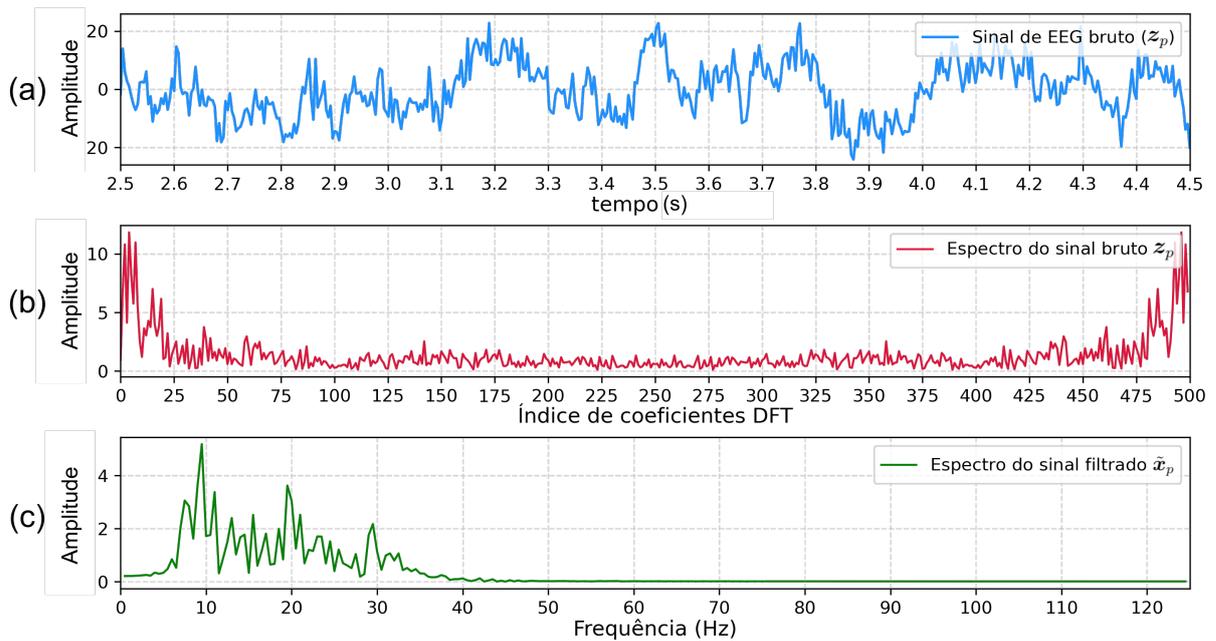
$$\ddot{x}_{pc} = \sum_{q=0}^{Q-1} z_{pq} \left[\cos \left(\frac{2\pi}{Q} cq \right) - j \sin \left(\frac{2\pi}{Q} cq \right) \right] \quad , \quad (3.4)$$

em que $\cos(\cdot)$ e $\sin(\cdot)$ representam, respectivamente, as funções cosseno e seno do argumento, enquanto que o operador imaginário j corresponde à $\sqrt{-1}$.

Cada coeficiente $\ddot{x}_{pc} \in \mathbb{C}$ está associado a um *bin* de frequência discreta ω_c no intervalo entre $[0, \frac{2\pi(Q-1)}{Q}]$, com espaçamento entre *bins* de frequências consecutivas em radianos dado por $\delta_{rad} \triangleq \frac{2\pi}{Q}$. Como a FFT apresenta simetria par, apenas os $\frac{Q}{2}$ primeiros coeficientes são diferentes e π representa a maior frequência presente no sinal conforme critério de *Nyquist*.

A Figura 19 ilustra a saída obtida com a aplicação da DFT em um segmento de sinal unitário. O quadro 19-b apresenta as amplitudes no espectro obtidas com a FFT no sinal bruto z_p plotado no quadro 19-a em função do número total de coeficientes. Já a curva em 19-c representa o espectro do sinal \tilde{x}_p , o qual denota o sinal z_p após ser filtrado usando um filtro passa-faixa com frequências de corte $F_l = 8\text{Hz}$ e $F_u = 30\text{Hz}$. Nota-se que a propriedade de simetria da FFT foi mantida em 19-b.

Figura 19. (a) Segmento de sinal bruto de EEG z_p referente ao canal localizado em C4 (hemisfério direito) com $Q = 500$ amostras ($F_s = 250\text{Hz}$). (b) Amplitude dos coeficiente DFT obtidos com a aplicação do algoritmo da FFT no sinal bruto z_p . (c) Espectro do sinal z_p após ser filtrado usando um filtro passa-faixa IIR de 5ª ordem com frequências de corte $F_l = 8\text{Hz}$ e $F_u = 30\text{Hz}$.



Fonte: Autoria própria

Posto que em sistemas ICM-IM uma faixa de baixas frequências é suficiente para descrever o fenômeno de IM através dos sinais, da mesma forma que delimita-se as frequências em uma faixa de interesse ao usar filtros digitais, a matriz $\ddot{\mathbf{X}}$ também pode ser delimitada de modo a contemplar apenas as frequências em Δ_f selecionando apenas os coeficientes correspondentes aos *bins* de frequência entre F_l e F_u .

3.2.2.2 Filtragem espacial

Além requer uma etapa de filtragem temporal devido à baixa SNR, o EEG caracteriza-se por apresentar baixa resolução espacial, principalmente ao medir a atividade sináptica a partir de populações relativamente pequenas de neurônios se comparada com toda a área do cérebro (LOTTE et al., 2018; CLERC; BOUGRAIN; LOTTE, 2016a). De acordo com Blankertz et al. (2007), isso pode produzir sinais de interesse (i.e. relacionados aos SMR) fracos em relação a outras fontes de sinais na mesma faixa de frequência, como os originados de artefatos musculares.

Além disso, devido ao efeito *smearing* do crânio (também conhecido como efeito de condução de volume), a atividade elétrica cerebral se espalha por regiões subjacentes à origem, o que provoca a captação redundante dos sinais nos múltiplos canais de EEG no escalpo, o que gera uma imagem bastante turva da atividade cerebral (LOTTE, 2014).

Todos esses fatores corroboram para que os filtros espaciais sejam ferramentas extremamente úteis para melhorar a SNR e a identificação das informações espaciais que descrevem a intenção motora do indivíduo (BLANKERTZ et al., 2007). Afinal, conforme citado previamente, a distribuição espacial do potencial elétrico no couro cabeludo observada no sinal de EEG também fornece informações cruciais sobre a origem da atividade elétrica útil para a ICM-IM (CLERC; BOUGRAIN; LOTTE, 2016a).

Além da importância neurofisiológica da filtragem espacial ao proporcionar uma forma de recuperar as informações relevantes do sinal original espalhadas pelo cérebro, ela também é útil para redução da dimensionalidade causada pela utilização de múltiplos canais de EEG (LOTTE, 2014).

Estudos sugerem que sistemas de ICM-IM passam a apresentar desempenhos razoáveis quando utilizam no mínimo 8 canais de EEG (SANNELLI et al., 2010; ARVANEH et al., 2011). Ou seja, a utilização de múltiplos canais de EEG em projetos de ICM-IM mostra-se inevitável para coleta de informações relevantes para a classificação da intenção do indivíduo.

Contudo, a simples adição de canais não garante melhoria de desempenho, na verdade, apesar de propiciar a extração de um número maior de características, em geral, tal prática aumenta a dimensionalidade dos dados e pode provocar a redução de desempenho em caso de uma calibração inadequada do sistema (LOTTE, 2014).

Ao aplicar técnicas de filtragem espacial, as amostras de diferentes canais são combinadas a fim de gerar uma versão melhorada do sinal (SILVA et al., 2016). Estes filtros realizam uma ponderação entre o sinal de um eletrodo e o sinal dos eletrodos vizinhos, de acordo com a sua posição no escalpo, objetivando eliminar potenciais comuns a um determinado grupo de sensores (BARROS, 2018).

Em suma, essa etapa de filtragem compreende métodos que geram novos canais a partir de combinações lineares ponderadas de vários canais originais e, portanto, normalmente utiliza-se uma quantidade menor de canais, já filtrados espacialmente, em comparação ao número inicial de canais para extração das características úteis no sinal (LOTTE, 2014).

Considerando que $\tilde{\mathbf{X}} \in \mathbb{R}^{P \times Q}$ é uma matriz de posto completo que representa uma única época de EEG com P canais e Q amostras por canal, já filtrada por um filtro passa-banda em determinada faixa de frequência Δ_f , genericamente, a transformação linear utilizada para filtrar o sinal no domínio espacial, pode ser definida como,

$$\mathbf{R} = \mathbf{W}^T \tilde{\mathbf{X}} \quad , \quad (3.5)$$

em que $\mathbf{W} \in \mathbb{R}^{P \times P}$ é a matriz de transformação cujas colunas são filtros espaciais, o sobrescrito T indica transposição matricial e \mathbf{R} é o sinal espacialmente filtrado.

Bashashati et al. (2007) e Lotte et al. (2018) elencam várias técnicas diferentes para melhorar as características espaciais nos sinais de EEG baseadas tanto em abordagens não-supervisionadas, por exemplo, pela Análise de Componentes Independentes (ICA, do inglês *Independent Component Analysis*), Referência Laplaciana (LAR, do inglês *Laplacian Reference*), Referência Média Comum (CAR, do inglês *Common Average Reference*) e Análise de Componentes Principais (PCA, do inglês *Principals Component Alalysis*), quanto em abordagens supervisionadas, como os Padrões Espaciais Comuns (CSP, do inglês *Common Spatial Patterns*, modelos auto-regressivos e redes neurais artificiais (ANN, do inglês *Artificial Neural Networks*) (RAMOSER; MULLER-GERKING; PFURTSCHHELLER, 2000; BLANKERTZ et al., 2008b).

Segundo Lotte et al. (2018), a definição do filtro espacial a ser utilizado está intrinsecamente ligada ao tipo de resposta gerada pela tarefa cognitiva. O CSP é um método amplamente utilizado no contexto de ICM-IM para determinação da matriz \mathbf{W} especialmente por ter se mostrado eficiente em evidenciar as características que descrevem o fenômeno ERS/ERD associado à tarefas motoras em sinais de EEG para problemas de duas classes de IM (ANG et al., 2012b; ALSHBATAT; DONG; VIAL, 2016; CLERC; BOUGRAIN; LOTTE, 2016a).

Além disso, o CSP é conhecido por sua eficiência computacional por possuir uma implementação relativamente simples (BLANKERTZ et al., 2008b). Esses fatores explicam a escolha do CSP como método padrão para a etapa de filtragem espacial dos sinais de EEG neste trabalho, com seus detalhes sendo descritos a seguir.

3.2.2.2.1 Padrões Espaciais Comuns (CSP)

O CSP é um método estatístico de aprimoramento de sinais multicanal utilizado para o projeto de filtros espaciais que aumentam a separabilidade entre duas classes distintas de tarefas motoras nos sinais de EEG com o intuito de discriminá-las de forma ótima (BASHASHATI et al., 2007; ANG et al., 2012b). A partir dos sinais filtrados, o método busca uma projeção linear no espaço em que as características de cada classe são destacadas e melhor distinguíveis (LOTTE; GUAN, 2011).

O método parte do princípio de que, durante a realização de uma tarefa motora específica, os sinais registrados por canais em um dos hemisférios do cérebro apresentam uma variância de energia significativamente diferente em relação à energia dos sinais registrados por canais no hemisfério oposto (contralateralidade) (WANG; GAO; GAO, 2005).

Uma vez que a variância dos sinais filtrados representa a energia dos sinais em determinada banda de frequência, na prática, o algoritmo CSP busca filtros espaciais $\mathbf{w} \in \mathbf{W}$ que maximizam a variância dos sinais de uma classe em contraste à minimização da variância de outra classe (LOTTE, 2014; BLANKERTZ et al., 2007), ou seja, o CSP tenta distanciar a dispersão média entre duas classes de IM tanto quanto possível a fim de ressaltar suas características e facilitar a classificação (WANG, 2011).

Ao assumir a matriz $\tilde{\mathbf{X}} \in \mathbb{R}^{P \times Q}$ como sendo uma única época de EEG com P canais e Q amostras por canal após filtragem temporal passa-faixa, os elementos no vetor coluna $\mathbf{w} = [w_1 \ w_2 \ \dots \ w_P]^T$, considerados os coeficientes de um dos P filtros espaciais de dimensão $P \times 1$ em \mathbf{W} , podem ser aplicados à cada instante de tempo $q = 1, 2, \dots, Q$ nos P sinais em $\tilde{\mathbf{X}}$, como forma de se obter uma combinação linear,

$$\mathbf{r} = \mathbf{w}^T \tilde{\mathbf{X}} \quad , \quad (3.6)$$

em que $\mathbf{r} \in \mathbb{R}^{1 \times Q}$ representa os sinais espacialmente filtrados em cada instante amostral q .

Em geral, a quantificação da energia dos sinais associada à cada uma das duas classes envolvidas, obtida pelas respectivas matrizes de covariância média, é usada para encontrar os coeficientes lineares em diferentes vetores de transformação \mathbf{w} que maximizam a separabilidade entre as dispersões das energias resultantes (LOTTE; GUAN, 2011).

Conforme discutido na seção 3.2.1, a fase de treinamento na arquitetura de sistema ICM-IM existe para que os parâmetros livres que definem o modelo de classificação sejam ajustados a partir de um conjunto de exemplos rotulados. Dentre esses parâmetros, estão inseridos os coeficientes lineares que compõem a matriz de filtros espaciais, \mathbf{W} . Isso implica no cálculo das matrizes de covariância média a partir de um conjunto de épocas de treinamento.

Assim, sejam $N_{\mathcal{A}}$ e $N_{\mathcal{B}}$ épocas de duas classes de IM distintas (e.g. mão esquerda e mão direita) agrupadas no conjunto de treinamento cada qual associada a um rótulo $\rho \in \{\mathcal{A}, \mathcal{B}\}$, a matriz de covariância média considerando todas as N_{ρ} épocas da classe ρ é dada por:

$$\mathbf{C}_{\rho} = \frac{1}{N_{\rho}} \sum_{n=1}^{N_{\rho}} \tilde{\mathbf{X}}_{\rho_n} \tilde{\mathbf{X}}_{\rho_n}^{\text{T}} \quad , \quad (3.7)$$

em que $\tilde{\mathbf{X}}_{\rho_n}$ corresponde à n -ésima época de treinamento associada à classe ρ e \mathbf{C}_{ρ} é a matriz simétrica e positiva semi-definida, a qual define a covariância média da classe ρ e representa a potência média dos sinais inter e intra-eletrodos.

Uma vez obtidas ambas as matrizes de covariância, i.e. $\mathbf{C}_{\mathcal{A}}$ e $\mathbf{C}_{\mathcal{B}}$, obter os coeficientes ótimos de um filtro espacial \mathbf{w} , corresponde à extremar o quociente de *Rayleigh* na forma:

$$J_{csp}(\mathbf{w}) = \frac{\mathbf{w}^{\text{T}} \mathbf{C}_{\mathcal{A}} \mathbf{w}}{\mathbf{w}^{\text{T}} \mathbf{C}_{\mathcal{B}} \mathbf{w}} \quad . \quad (3.8)$$

Uma possível solução para a equação Eq. (3.8) consiste em observar que $J_{csp}(\mathbf{w}) = J_{csp}(k\mathbf{w})$ para qualquer k real, o que significa que extremar Eq. (3.8) é equivalente à extremar $\mathbf{w}^{\text{T}} \mathbf{C}_{\mathcal{A}} \mathbf{w}$ sujeito à restrição $\mathbf{w}^{\text{T}} \mathbf{C}_{\mathcal{B}} \mathbf{w} = 1$.

Portanto, ao reescrever a equação Eq. (3.8) a partir da restrição mencionada e do método de multiplicadores de *Lagrange* obtém-se:

$$L(\lambda, \mathbf{w}) = \mathbf{w}^{\text{T}} \mathbf{C}_{\mathcal{A}} \mathbf{w} + \lambda(\mathbf{w}^{\text{T}} \mathbf{C}_{\mathcal{B}} \mathbf{w} - 1) \quad . \quad (3.9)$$

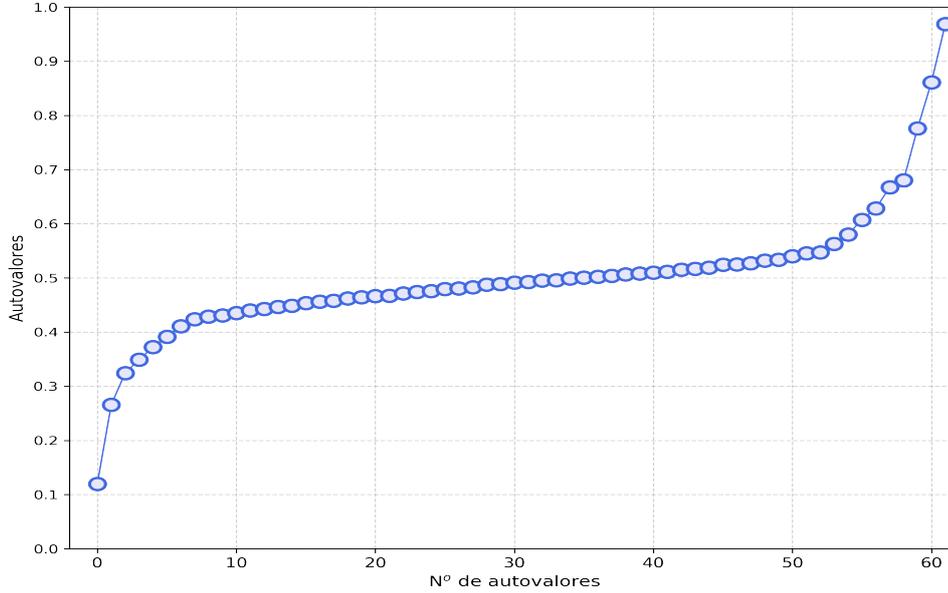
Ao igualar a zero a derivada da equação Eq. (3.9) em relação à \mathbf{w} , têm-se a Eq. (3.10) correspondendo ao problema de autovalores e autovetores generalizados (LOTTE; GUAN, 2011):

$$\mathbf{C}_{\mathcal{B}}^{-1} \mathbf{C}_{\mathcal{A}} \mathbf{w} = \lambda \mathbf{w} \quad , \quad (3.10)$$

Assim, o conjunto de filtros espaciais para compor a matriz de transformação \mathbf{W} é dado pelos vetores \mathbf{w}_p com $p = 1, 2, \dots, P$, os quais, correspondem aos autovetores da matriz $\mathbf{C}_{\mathcal{B}}^{-1} \mathbf{C}_{\mathcal{A}}$ associados aos respectivos autovalores λ_p .

As direções dos P autovetores (i.e. filtros espaciais \mathbf{w}) obtidos na equação 3.10 projetam os sinais a um subespaço diferente do original, contudo, nem todas as direções produzem máxima separabilidade entre as classes (LOTTE; GUAN, 2011). Posto que as matrizes de covariância média normalizadas, $\mathbf{C}_{\mathcal{A}}$ e $\mathbf{C}_{\mathcal{B}}$ produzem autovalores λ entre 0 e 1, em geral, os autovetores associados aos autovalores medianos ou próximos à 0.5 tendem a contribuir menos para a discriminação entre as classes em relação aos extremos (BLANKERTZ et al., 2007; VAZ, 2016). Como forma de ilustrar essa característica, a Figura 20 apresenta em ordem crescente os autovalores obtidos para matrizes de covariância média de épocas associadas à tentativas de tarefas motoras das mãos.

Figura 20. Disposição em ordem crescente de $P = 62$ autovalores λ associados aos autovetores correspondentes aos filtros espaciais CSP que maximizam a separabilidade entre duas classes de IM ($\mathcal{A} = \text{IM}$ mão esquerda, $\mathcal{B} = \text{IM}$ mão direita). As matrizes $\mathbf{C}_{\mathcal{A}}$ e $\mathbf{C}_{\mathcal{B}}$ são obtidas de épocas extraídas dos sinais do 54º sujeito no conjunto de dados público de EEG denotado por LE (ver seção 5.2.4.3).



Fonte: Autoria própria

Os autovetores na Figura 20 evidenciam que as projeções que, de fato, maximizam a variância de uma classe em contraposição à minimização de outra, correspondem aos autovetores associados aos pares de maiores e menores autovalores (LOTTE, 2014). Isto posto, é comum que somente os autovetores \mathbf{w} correspondentes aos $\frac{N_r}{2}$ pares de maiores e menores autovalores λ provenientes da equação Eq. (3.10) sejam escolhidos para compor as colunas da matriz de transformação espacial, sendo $\mathbf{W} \in \mathbb{R}^{P \times N_r}$. Vale ressaltar que a definição de N_r está restrita à um valor inteiro, positivo e par, além de $N_r \leq P$.

Assim, os N_r filtros definidos representam as colunas da matriz de transformação $\mathbf{W} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \cdots \ \mathbf{w}_{N_r}]$, que ao ser aplicada à uma única época de EEG, $\tilde{\mathbf{X}}$, na forma de equação (3.5), produz o sinal espacialmente filtrado $\mathbf{R} \in \mathbb{R}^{N_r \times Q}$.

Embora seja reconhecido por sua eficiência computacional e por apresentar boa aderência à projetos ICM-IM (BLANKERTZ et al., 2008b), o CSP não apresenta robustez à sinais excessivamente ruidosos o que o torna, em grande medida, dependente da etapa anterior de filtragem temporal quanto à eficácia na identificação das informações espaciais relevantes (LOTTE, 2014).

Essa característica, faz com que a faixa de frequência utilizada na filtragem temporal, a qual define a transformação do sinal de entrada no CSP, esteja altamente correlacionada à capacidade do método em encontrar direções de máxima separabilidade entre as classes (ANG et al., 2012b; BLANKERTZ et al., 2007).

Além da versão clássica do método CSP, algumas variações tem sido propostas ao longo dos anos, como versões regularizadas (LOTTE; GUAN, 2011) e versões que combinam filtros espaciais e temporais (GUBERT, 2019). Variações como a Decomposição Espacial de Subespaços Comuns (CSSD, do inglês *Common Spatial Subspace Decomposition*), também são métodos comumente utilizados para filtragem baseada na localização espacial dos sinais, conforme acrescentam Vaz (2016) e Nicolas-Alonso e Gomez-Gil (2012)

Como forma de explorar a faixa de frequência discriminativa do sujeito, uma abordagem CSP comumente efetiva no contexto de ICM, consiste no uso de sub-bandas (SBCSP, do inglês *Sub-Band Common Spatial Patterns*) (NOVI et al., 2007; ANG et al., 2008). Em suma, a abordagem considera um banco de filtros para decompor uma faixa de frequência de interesse em múltiplas sub-bandas e posteriormente ressaltar os padrões espaciais que descrevem as tarefas motoras em cada uma delas.

3.2.3 Extração de características

Consequente à filtragem espacial, o próximo passo consiste na extração das características que descrevem o estado cognitivo presente nos sinais de EEG (LOTTE, 2014; BASHASHATI et al., 2007). Espera-se que, após as etapas de pré-processamento, o sinal resultante mantenha as informações temporais, espectrais e espaciais que distinguem a intenção motora do indivíduo.

Conforme mencionado na seção anterior, em se tratando da aplicação do CSP para ressaltar as características de tarefas de IM, a variância dos sinais filtrados no âmbito temporal-espectral para um dado intervalo de frequência Δ_f tem interpretação de energia (LOTTE, 2014). Pode-se dizer, em suma, que o algoritmo CSP maximiza a diferença de energia entre as classes de IM.

Para além dessa maior separabilidade, uma das contribuições do CSP é propiciar a redução de dimensionalidade dos sinais espacialmente filtrados, ao possibilitar a seleção dos $N_r \leq P$ filtros espaciais mais discriminantes.

Contudo, como a atividade elétrica cerebral caracteriza-se pela alta variabilidade inter sujeitos, a definição de um valor universal para N_r nem sempre produz transformações espaciais satisfatórias do ponto de vista de separabilidade dependendo do sujeito (CLERC; BOUGRAIN; LOTTE, 2016a; LOTTE, 2014).

De fato, deve-se levar em consideração um problema típico do escopo de aprendizado de máquina, conhecido como *trade-off bias-variance* (BISHOP, 2006), em que, neste caso, valores muito pequenos para N_r , podem levar à uma discriminação pouco efetiva entre as classes, ao passo que, valores elevados de N_r podem resultar em *overfitting* e em uma consequente baixa capacidade de generalização (BLANKERTZ et al., 2008a).

Ademais, além da definição do número de filtros CSP para compor a matriz \mathbf{W} , a eficácia do CSP depende das propriedades da janela J utilizada na extração das épocas de calibração bem como do intervalo de frequência Δ_f definida na filtragem temporal (ANG et al., 2012b; BLANKERTZ et al., 2007).

Observa-se que, esses hiperparâmetros definem as épocas utilizadas na obtenção das matrizes de covariância média que por sua vez definem a eficiência dos filtros CSP pela sua representatividade das classes envolvidas (SILVA, 2017). Embora a configurações desses hiperparâmetros referentes à etapas anteriores no sistema, de acordo com os padrões cognitivos de cada sujeito, possa contribuir para o desempenho do CSP, é frequentemente realizada manualmente (BLANKERTZ et al., 2008b). Uma abordagem comum, por exemplo, é a escolha direta de três pares de filtros espaciais associados aos maiores e menores autovalores Lotte e Guan (2011).

De todo modo, ao definir $N_r \leq P$, têm-se a seleção de um número menor de filtros espaciais o que reduz a dimensionalidade dos componentes em \mathbf{R}_n , com $n = 1, 2, \dots, N_A + N_B$. Esse processo é convenientemente denominado de *seleção de características*, uma vez que a variância das componentes de \mathbf{R}_n podem ser usadas para extrair um vetor de características \mathbf{x}_n de dimensão N_r , conforme a transformação não-linear:

$$\mathbf{x}_n = \log(\text{var}(\mathbf{R}_n)) \quad , \quad (3.11)$$

em que, $\log(\cdot)$ é a função logarítmica do argumento e $\text{var}(\mathbf{R}_n)$ resulta em um vetor coluna cujo j -ésimo elemento, r_j , corresponde à variância (i.e. energia) da respectiva componente do sinal espacialmente filtrado dada por $r_j = \frac{1}{Q} \sum_{k=1}^Q (r_{jk} - \mu_j)^2$, onde $\mu_j = \frac{1}{Q} \sum_{k=1}^Q (r_{jk})$, por sua vez, é a média da j -ésima linha em $\text{var}(\mathbf{R}_n)$.

De acordo com Ramoser, Muller-Gerking e Pfurtscheller (2000) o objetivo da transformação logarítmica é tornar a função de densidade de probabilidade das componentes do vetor de características próxima à uma distribuição normal, contribuindo com o mapeamento realizado na etapa de classificação subsequente.

3.2.4 Classificação

Com o agrupamento dos padrões que descrevem a intenção motora do indivíduo nos vetores de características, uma etapa fundamental no processamento dos sinais de EEG em sistemas de ICM-IM consiste na classificação desses vetores de modo a associá-los à rótulos de classes de IM (NAM; NIJHOLT; LOTTE, 2018).

Em geral, os algoritmos de classificação podem basear sua abordagem em aprendizado supervisionado ou não supervisionado (MCFARLAND; SARNACKI; WOLPAW, 2010; ANG; GUAN, 2016). Na classificação supervisionada, especificamente, a distinção entre as classes depende do ajuste prévio de um modelo (ou função) a partir de um conjunto

de padrões de treinamento cujos rótulos de classe são conhecidos (NICOLAS-ALONSO; GOMEZ-GIL, 2012; MARSLAND, 2014).

Seja $\mathbf{X} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \cdots \ \mathbf{x}_n \ \cdots \ \mathbf{x}_{N_{\mathcal{T}}}] \in \mathbb{R}^{N_{\mathcal{T}} \times N_r}$ a matriz cujas colunas correspondem aos vetor de características, $\mathbf{x}_n \in \mathbb{R}^{N_r}$, obtidos na etapa anterior, i.e. Eq. (3.11), a partir de $N_{\mathcal{T}} = N_{\mathcal{A}} + N_{\mathcal{B}}$ épocas, têm-se um conjunto de exemplos de treinamento com $N_{\mathcal{A}}$ elementos associados à classe \mathcal{A} e $N_{\mathcal{B}}$ à classe \mathcal{B} . Por consequência, $\mathbf{X}_{\rho} \in \mathbf{X}$ denota a porção dos vetores de entrada associados à classe $\rho \in \{\mathcal{A}, \mathcal{B}\}$.

Ao assumir uma representação numérica para as classes \mathcal{A} e \mathcal{B} , define-se $y_n \in \{-1, +1\}$ como o rótulo numérico da classe a qual o n -ésimo vetor de características em \mathbf{X} está associado, de tal modo que $y_n = -1$ para exemplos da classe \mathcal{A} e $y_n = 1$ para exemplos da classe \mathcal{B} .

Ante o exposto, no escopo típico de ICM-IM, o problema de classificação consiste em estimar um modelo matemático $f(\mathbf{x}_n)$ adequado para mapear os vetores de entrada, \mathbf{x}_n , do espaço de características para um novo espaço onde a decisão quanto ao rótulo (classe) y_n é tomada. O objetivo é encontrar uma função f que forneça boa generalização, ou seja, que apresente desempenho satisfatório na classificação de exemplos pertencentes tanto aos dados de treinamento quanto de novos exemplo nunca apresentados ao modelo (LOTTE et al., 2007).

Dentre os principais desafios na classificação dos padrões de IM extraídos dos sinais de EEG está o fato de esses dados serem não estacionários, ruidosos e, apesar de o EEG fornecer alta resolução temporal, a obtenção de um conjunto de exemplos de treinamento suficientemente grande a ponto de abarcar todas as variações nos padrões de cada classe é uma tarefa difícil e onerosa (LI et al., 2013; XU et al., 2011). Os algoritmos de classificação, portanto, devem ser capazes de lidar com este cenário adverso (BASHASHATI et al., 2015).

Há uma grande variedade de algoritmos de classificação disponíveis, cada qual com uma abordagem distinta na estimação da função de mapeamento f (FACELI et al., 2011). Revisões abrangentes sobre as técnicas de classificação frequentemente adotadas no contexto de ICM foram realizadas ao longo dos últimos anos. Dentre os tipos de classificadores empregados estão: técnicas lineares; abordagens de aprendizado estatístico; modelos *Bayesianos*; modelos baseados em instâncias; redes neurais, dentre outros (BASHASHATI et al., 2007; LOTTE et al., 2007; NICOLAS-ALONSO; GOMEZ-GIL, 2012; LOTTE et al., 2018).

Alguns dos algoritmos têm mostrado eficácia no reconhecimento de padrões de IM em diferentes aplicações de ICM (LOTTE et al., 2018; BASHASHATI et al., 2015). As seções subsequentes descrevem brevemente cinco dessas técnicas, as quais foram conside-

radas no desenvolvimento do sistema proposto neste trabalho, nomeadamente: Análise de Discriminantes Lineares (LDA, do inglês *Linear Discriminant Analysis*), Regressão Logística (LR, do inglês *Logistic Regression*), Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machines*), K-ésimos Vizinhos mais Próximos (KNN, do inglês *K-nearest Neighbors*) e ANN Perceptron de Múltiplas Camadas (MLP, do inglês *Multilayer Perceptron*).

3.2.4.1 Análise de Discriminantes Lineares (LDA)

Devido à sua simplicidade estrutural, desempenho competitivo e treinamento eficiente, os classificadores lineares são um dos algoritmos mais populares usados para projetar sistemas de ICM (NAM; NIJHOLT; LOTTE, 2018). O LDA é uma das técnicas lineares, em especial, mais difundidas neste contexto (WOLPAW; WOLPAW, 2012).

O método, baseado no aprendizado supervisionado, é reconhecido por ser eficaz na discriminação entre duas classes de exemplos, especialmente quando os dados estão normalmente distribuídos e são linearmente separáveis, mesmo possuindo uma baixa complexidade matemática e requerendo recursos computacionais relativamente baixos (LOTTE et al., 2007). A baixa exigência computacional, inclusive, o torna especialmente atraente em aplicações *on-line* de ICM (LOTTE, 2014)

Ao assumir a separabilidade linear entre as classes, o algoritmo LDA define uma função discriminante que mapeia o espaço de características para um espaço de decisão onde um hiperplano de separação define à qual classe um vetor de características pertence (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Ao considerar o problema de classificação binária, o método busca por uma direção ótima $\bar{\mathbf{w}}^*$ que maximize o critério de *Fisher*, para projetar os vetores de características de entrada em um espaço de máxima separabilidade entre as classes (NAM; NIJHOLT; LOTTE, 2018; BISHOP, 2006).

O vetor de pesos $\bar{\mathbf{w}}^* \in \mathbb{R}^{N_r}$ é determinado de tal forma a maximizar a dispersão interclasses e minimizar a dispersão intraclasse no conjunto de treinamento (LOTTE et al., 2007; BISHOP, 2006). Para tanto, o cálculo dos componentes de $\bar{\mathbf{w}}^*$ depende do afastamento dos pontos médios entre os vetores de cada classe $\rho \in \{\mathcal{A}, \mathcal{B}\}$, os quais são denotados genericamente por $\boldsymbol{\mu}_\rho$ e definidos conforme:

$$\boldsymbol{\mu}_\rho = \frac{1}{N_\rho} \sum_{n=1}^{N_\rho} \mathbf{x}_{\rho_n} , \quad (3.12)$$

em que \mathbf{x}_{ρ_n} é o n -ésimo vetor de características associado à classe ρ . Definidas as médias $\boldsymbol{\mu}_\mathcal{A}$ e $\boldsymbol{\mu}_\mathcal{B}$, o espalhamento nos vetores de características da classe genérica ρ é dado pelas

matrizes de covariância calculadas como:

$$\mathbf{S}_\rho = \frac{1}{N_\rho} \sum_{n=1}^{N_\rho} (\mathbf{x}_{\rho_n} - \boldsymbol{\mu}_{\rho_n})(\mathbf{x}_{\rho_n}^\top - \boldsymbol{\mu}_{\rho_n}^\top) . \quad (3.13)$$

A partir dos centroides e das matrizes de covariância nos N_ρ vetores de características do conjunto de treinamento associados à cada classe $\rho \in \{\mathcal{A}, \mathcal{B}\}$, um vetor de pesos $\bar{\mathbf{w}}$ é obtido por:

$$\bar{\mathbf{w}} = (\mathbf{S}_\omega)^{-1}(\boldsymbol{\mu}_\mathcal{A} - \boldsymbol{\mu}_\mathcal{B}) , \quad (3.14)$$

em que $\mathbf{S}_\omega = \mathbf{S}_\mathcal{A} + \mathbf{S}_\mathcal{B}$ define a matriz de espalhamento intraclasse. A solução ótima para (3.14) é obtida ao extremar ao extremar a função custo na forma:

$$\arg_{\bar{\mathbf{w}}} \max \frac{\bar{\mathbf{w}}^\top \mathbf{S}_\mathcal{E} \bar{\mathbf{w}}}{\bar{\mathbf{w}}^\top \mathbf{S}_\omega \bar{\mathbf{w}}} , \quad (3.15)$$

onde $\mathbf{S}_\mathcal{E} = (\boldsymbol{\mu}_\mathcal{A} - \boldsymbol{\mu}_\mathcal{B})(\boldsymbol{\mu}_\mathcal{A} - \boldsymbol{\mu}_\mathcal{B})^\top$ é a matriz de espalhamento interclasses a qual representa a distância entre os pontos médios das classes \mathcal{A} e \mathcal{B} e que pretende-se maximizar tanto quanto espera-se minimizar o espalhamento intraclasse a partir do vetor $\bar{\mathbf{w}}$ (SILVA, 2017).

A classificação de um padrão \mathbf{x}_n é obtida em um hiperplano de separação determinado com base no vetor resultante de Eq. (3.14) e um limiar de decisão $b \in \mathbb{R}$ definido por:

$$b = \frac{1}{2} \bar{\mathbf{w}}^* (\boldsymbol{\mu}_\mathcal{A} + \boldsymbol{\mu}_\mathcal{B}) . \quad (3.16)$$

Com isso, a saída contínua do LDA para um dado vetor de entrada \mathbf{x}_n é definida como:

$$f(\mathbf{x}_n) = \bar{\mathbf{w}}^{*\top} \mathbf{x}_n - b , \quad (3.17)$$

em que, para se determinar o rótulo numérico, y_n , da classe à qual \mathbf{x}_n pertence, utiliza-se:

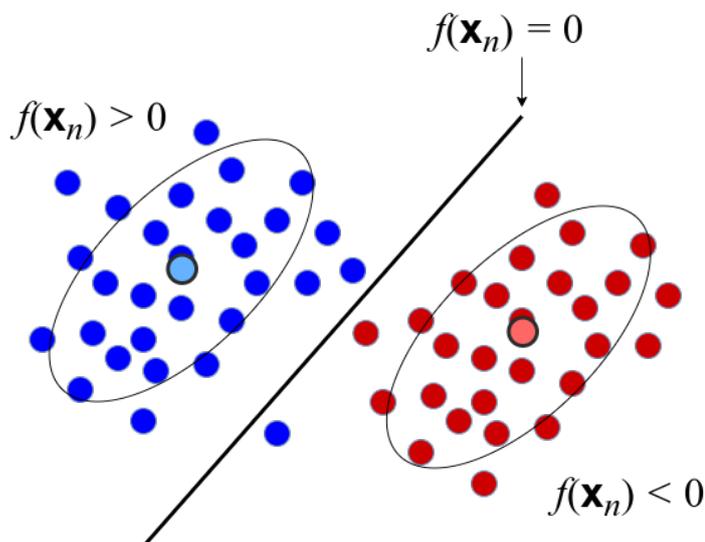
$$y_n = \begin{cases} -1, & f(\mathbf{x}_n) \geq b \\ 1, & f(\mathbf{x}_n) < b \end{cases} , \quad (3.18)$$

para $y_n = -1$ representando a classe \mathcal{A} e $y_n = 1$ a classe \mathcal{B} .

Uma ilustração do hiperplano linear de separação entre duas classes de IM via LDA é apresentada na Figura 21. Os eixos representam duas características extraídas dos sinais de EEG e cada ponto está associado à um vetor de características. A classe de uma nova entrada submetida ao LDA depende de qual lado do hiperplano (linha sólida) será projetada. Nota-se que, em problemas bidimensionais ($N_r = 2$) o hiperplano de separação corresponde à equação da reta.

Conforme dito anteriormente, o LDA é uma das técnicas mais comuns no contexto de ICM possivelmente por ser simples e computacionalmente barata se comparada à outras técnicas lineares e não lineares. Apesar de ser recomendado à problemas binários de

Figura 21. Hiperplano de separação entre classes definido pela função de discriminação linear do método LDA. Nesse caso, o sinal da função define a classe à qual o vetor de entrada pertence



Fonte: Adaptado de Lotte et al. (2007)

classificação, o método também pode ser empregado para classificar padrões em múltiplas classes à partir de uma estratégia *um contra todos*, por exemplo (CLERC; BOUGRAIN; LOTTE, 2016a; ANG et al., 2012a).

Contudo, vale destacar que, de acordo com Nam, Nijholt e Lotte (2018) e Bishop (2006), o desempenho do LDA é sensível a *outliers* e altamente dependente da suposição de linearidade entre as classes, de forma a sofrer com baixa capacidade de generalização a medida que a sobreposição entre os dados aumenta.

Ademais, Duda, Hart e Stork (2012) e Bashashati et al. (2015) lembram que, apesar de funcionar bem as densidades de probabilidade condicional das duas classes têm uma distribuição *Gaussiana* com matrizes de covariâncias iguais, o LDA tende a falhar nos casos em que a informação discriminativa não está na média e sim na variância dos dados, gerando classificações incorretas quando os vetores que definem os pontos médios são iguais e as matrizes de covariância são diferentes.

3.2.4.2 Regressão Logística (LR)

Outra técnica linear usada na discriminação entre classes de IM em sistemas de ICM é regressão logística (LR) (BASHASHATI; WARD; BASHASHATI, 2016a). Apesar de sua denominação, a LR está contida em uma categoria de modelos probabilístico de classificação e assim como o LDA é um método popular considerado relativamente robusto para problemas binários, é fácil de implementar e tende a funcionar bem quando as classes são linearmente separáveis (BISHOP, 2006).

No entanto, diferentemente do LDA, a LR não apresenta tanta dependência da suposição de distribuição *Gaussiana* nos dados de treinamento, o que a torna uma alternativa ao método anterior quando as premissas de normalidade não são atendidas (POHAR; BLAS; TURK, 2004).

Em suma, o propósito da LR é encontrar o modelo de melhor ajuste e maior parcimônia que descreva a relação entre as saídas, que no caso problematizado nas seções anteriores representa um certo $y_n \in \mathbf{y}$, e os padrões de entrada, $\mathbf{x}_n \in \mathbf{X}$, também chamados de variáveis preditoras ou explicativas (POHAR; BLAS; TURK, 2004).

Para explicar a ideia da LR como um modelo probabilístico no caso binário, seja $\mathbf{P}(y|\mathbf{x})$ a probabilidade condicional de um vetor de características \mathbf{x} em particular corresponder à classe $y \in \{-1, 1\}$, define-se a função *logit* na forma de Eq. (3.19) para representar o logaritmo da razão de chances (do inglês *odds*) de que o evento $\mathbf{P}(y|\mathbf{x})$ ocorra.

$$\text{logit}(\mathbf{P}(y|\mathbf{x})) = \log\left(\frac{\mathbf{P}(y|\mathbf{x})}{1 - \mathbf{P}(y|\mathbf{x})}\right) \quad . \quad (3.19)$$

A saída em Eq. (3.19) assume quaisquer valores reais que, quando próximos a 0 ou ∞ , indicam chances muito baixas ou muito altas de o evento $\mathbf{P}(y|\mathbf{x})$ no argumento ocorrer, respectivamente (JAMES et al., 2013). A transformação logarítmica pode ser expressada como uma relação linear entre os padrões, \mathbf{x} , e os coeficientes de regressão de tal forma que:

$$\text{logit}(\mathbf{P}(y|\mathbf{x})) = \sum_{j=0}^{N_r} \bar{w}_j x_j = \bar{\mathbf{w}}^T \mathbf{x} \quad . \quad (3.20)$$

Contudo, as saídas reais de Eq. (3.20) não são adequadas no sentido de se prever a chance de um vetor de características pertencer a uma classe específica, haja vista o sentido probabilístico das quantidades resultantes. Diante disso, a probabilidade $\mathbf{P}(y|\mathbf{x})$ deve ser estimada usando uma função capaz de fornecer saídas restritas ao intervalo $[0, 1]$ (JAMES et al., 2013). Uma função tipicamente adotada é a *função logística*, cuja forma corresponde à inversa da função *logit* e é definida por:

$$f(\mathbf{x}, \bar{\mathbf{w}}) = \mathbf{P}(y|\mathbf{x}) = \frac{e^{\bar{\mathbf{w}}^T \mathbf{x}}}{1 + e^{\bar{\mathbf{w}}^T \mathbf{x}}} \quad , \quad (3.21)$$

em que $f(\mathbf{x}, \bar{\mathbf{w}})$ aproxima-se de 1 a medida que a combinação linear $\bar{\mathbf{w}}^T \mathbf{x}$ tende a ∞ ao mesmo tempo em que aproxima-se de 0 quando $\bar{\mathbf{w}}^T \mathbf{x}$ tende a $-\infty$.

A partir de então, a saída em Eq. (3.21) pode ser interpretada como a probabilidade do vetor de entrada \mathbf{x} , parametrizado pelos pesos em $\bar{\mathbf{w}}$, pertencer à classe rotulada por y . Por exemplo, sendo $f(\mathbf{x}, \bar{\mathbf{w}}) = \mathbf{P}(y = 1 | \mathbf{x}) = 0.7$, diz-se que a chance do vetor de características denotado por \mathbf{x} pertencer à classe \mathcal{B} é de 70%, sendo a probabilidade para a classe \mathcal{A} definida por $f(\mathbf{x}, \bar{\mathbf{w}}) = \mathbf{P}(y = -1 | \mathbf{x}) = 1 - \mathbf{P}(y = 1 | \mathbf{x}) = 0,3$, ou 30%.

A probabilidade prevista pode então ser simplesmente convertida em um resultado discreto por meio de um quantizador, usando um limiar de decisão comumente definido em 0,5 (RASCHKA, 2015):

$$y = \begin{cases} -1, & \text{se } f(\mathbf{x}, \bar{\mathbf{w}}) \geq 0,5 \\ 1, & \text{se } f(\mathbf{x}, \bar{\mathbf{w}}) < 0,5 \end{cases} . \quad (3.22)$$

Ante o exposto, o problema de aprendizado na LR, aplicado ao contexto de ICM-IM consiste em estimar os coeficientes $\bar{\mathbf{w}} \in \mathbb{R}^{N_r}$ com base nos dados de treinamento disponíveis. O objetivo é encontrar coeficientes que produzam valores da função f próximos a 0 para todos os exemplos associados à classe \mathcal{A} e próximos a 1 para todos os exemplos associados à classe \mathcal{B} . Para tal, o uso das propriedades estatísticas da função de *máxima verossimilhança* é a abordagem mais comum e detalhes sobre sua formulação matemática e aplicação no escopo da LR são fornecidos em Bishop (2006), Raschka (2015), James et al. (2013) e Hastie, Tibshirani e Friedman (2017).

Uma forma frequentemente adotada para se referir à função logística em Eq. (3.21) no contexto de classificação binária é chamá-la de função *sigmóide* devido à sua curva característica em forma de "S" (RASCHKA, 2015). Assim como o LDA, a Regressão Logística também pode ser aplicada a um problema de múltiplas classes, a partir da estratégia *um contra todos*, por exemplo (POHAR; BLAS; TURK, 2004). Neste caso, uma forma de generalização da função *sigmóide* conhecida como *softmax* é usada (JAMES et al., 2013).

O algoritmo LR é considerado mais flexível que o LDA, por ser aplicável à problemas em que o foco de interesse não está somente nos rótulos de classe como também na estimativa de probabilidade de associação com as classes. Ou seja, a LR pode ser usada tanto em problemas de classificação quanto de regressão, razão que explica sua popularidade (RASCHKA, 2015).

Entretanto, um aspecto interessante é que quando a separação entre as classes é demasiadamente grande, as estimativas do modelo LR tendem a ser instáveis, o que não ocorre com o LDA (JAMES et al., 2013). Ademais, o LDA também tende a performar melhor quando as condições de normalidade dos dados são satisfeitas bem como quando se têm poucos exemplos de treinamento e quando esses exemplos possuem alta dimensionalidade, propriedades típicas das épocas de sinais de EEG no contexto de ICM-IM (BASHASHATI et al., 2015).

3.2.4.3 Máquina de Vetores de Suporte (SVM)

Essencialmente, classificadores lineares encontram um hiperplano de separação para distinguir grupos de dados mutuamente exclusivos (NAM; NIJHOLT; LOTTE, 2018). Um

outro exemplo de algoritmo de discriminação binária entre classes que usa funções lineares é conhecido como Máquinas de Vetores de Suporte (SVM) (BURGES, 1998).

Uma vez que, múltiplas soluções poderiam ser encontrados em diferentes dimensões do espaço de decisão de forma a estabelecer a separação entre duas classes, a ideia central do SVM, para além de encontrar os parâmetros do modelo de separação entre duas classes, é encontrá-los para um hiperplano em particular cuja margem para os padrões de treinamento mais próximos é a máxima possível (LAL et al., 2004).

Embora, possuam uma implementação mais complexa em relação à contra-partes lineares como o LDA por exemplo, principalmente devido à formulação matemática mais sofisticada e por requererem soluções de otimização quadrática, algumas das características notáveis das SVM consistem na capacidade de generalizar bem através de dados de alta dimensionalidade e distribuição desconhecida e por serem flexíveis ao assumirem tanto formas lineares quanto não lineares (BURGES, 1998).

Partindo do caso mais simples, as SVMs lineares são aplicáveis quando os padrões associados às duas classes de dados são linearmente separáveis. De acordo com Belizario (2017), uma forma de encontrar o hiperplano em problemas linearmente é através das envoltórias convexas (do inglês *convex hulls*) de cada grupo de dados de treinamento, com as quais é possível determinar os pontos mais próximos entre as classes.

Os pontos mais próximos seriam suficientes para determinar um hiperplano de separação ideal, e portanto, são comumente chamados de *vetores de suporte* (NAM; NIJHOLT; LOTTE, 2018). O hiperplano ideal é o que mantém as maiores margens para os vetores suporte de ambas as classes e os pontos situados no hiperplano de separação são os que satisfazem a relação $\bar{\mathbf{w}}^T \mathbf{x} + b = 0$, em que $\bar{\mathbf{w}}$ e b são os parâmetros que descrevem o hiperplano e \mathbf{x} é um vetor de características que atende à condição.

As margens nas SVMs lineares podem ser diferenciadas entre rígidas ou suaves. A distinção entre elas consiste na suavização das restrições de máxima margem (rígida) para margens que tratam distribuições aproximadamente lineares com uma certa sobreposição entre exemplos de classes diferentes (FACELI et al., 2011). Para permitir que as restrições de margem rígida sejam violadas, as margens suaves introduzem uma variável de folga, ξ , de modo que o problema em uma SVM linear seja minimizar a função custo na forma de:

$$\min_{\bar{\mathbf{w}}, b, \xi} \frac{1}{2} \|\bar{\mathbf{w}}\|^2 + C \left(\sum_{n=1}^{N_{\mathcal{T}}} \xi_n \right) \quad , \quad (3.23)$$

sujeito a:

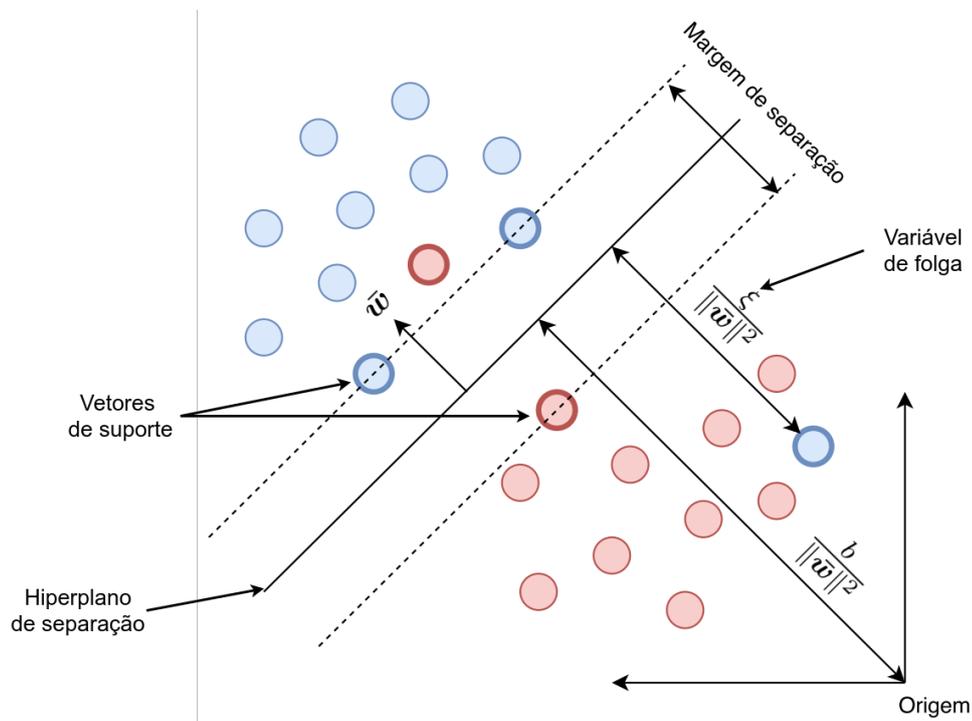
$$\begin{aligned} y_n (\bar{\mathbf{w}}^T \mathbf{x}_n + b) &\geq 1 - \xi_n, \forall n = 1, 2, \dots, N_{\mathcal{T}} \quad , \\ \xi_n &\geq 0 \end{aligned} \quad (3.24)$$

em que $y_n \in \{-1, 1\}$ são as possíveis classes discretas para o n -ésimo exemplo de treina-

mento e C é um termo de regularização usado para penalizar a minimização dos erros nos dados de treinamento em função da minimização da complexidade do modelo (balanço viés-variâncias). A definição de C representa um hiperparâmetro do modelo.

Naturalmente, as margens suaves adicionam flexibilidade e robustez ao modelo de classificação SVM (GUBERT, 2019). A motivação para ξ_n foi permitir a presença de erros de classificação na convergência do modelo sob a penalização de custo escalada por C , de tal maneira que valores altos de C geram altas penalidade ao erro e vice-versa (RASCHKA, 2015). A Figura 22 representa graficamente uma SVM de margem suave regida pela variável de folga ξ .

Figura 22. Representação de uma SVM linear com margem suave em problema não separável linearmente



Fonte: Adaptado de Belizario (2017)

Para resolver o problema de otimização restrita em Eq. (3.23), a restrição em Eq. (3.24) pode ser incorporada na função de custo principal usando multiplicadores de Lagrange, conforme formulado em Bishop (2006), com a otimização Lagrangiana podendo ser resolvida matematicamente usando algoritmos de programação quadrática (BELIZARIO, 2017).

Para além da classificação usando um plano linear, o SVM pode aplicar funções não lineares a fim de mapear padrões de um espaço de entrada, ξ , onde não são linearmente separáveis para um novo espaço de características, \mathbf{f} , de dimensão alta o suficiente para a separação usando uma SVM linear (GE; WANG; YU, 2014). O referido mapeamento,

$\psi : \chi \rightarrow \mathfrak{f}$, é conhecido na literatura como truque de Kernel (do inglês *Kernel trick*), e depende de uma transformação necessariamente não linear regida pela função de Kernel,

$$\mathcal{K}(\mathbf{x}_n, \mathbf{x}_m) = \psi(\mathbf{x}_n)\psi(\mathbf{x}_m) \quad , \quad (3.25)$$

sendo \mathbf{x}_n e \mathbf{x}_m dois vetores do espaço de entrada cujo produto interno no espaço de características é dado pela função \mathcal{K} .

A definição do Kernel, \mathcal{K} , assim como do parâmetro de regularização, C , representam hiperparâmetros na SVM e, portanto devem ser definidos previamente à construção do modelo. Algumas formas não lineares comumente assumidas pela função de Kernel são descritas em Faceli et al. (2011) e Bishop (2006). Conforme elencam Gubert (2019) e Belizario (2017), dentre os Kernels principais estão as funções polinomiais, as funções de base radial (*Gaussiano*) e as funções sigmóides.

O classificador SVM é um dos mais populares no contexto de ICM e referido como um dos padrões ouro na literatura por apresentar desempenho satisfatório na classificações de sinais de EEG em diferentes paradigmas (NICOLAS-ALONSO; GOMEZ-GIL, 2012; LOTTE et al., 2018; RAKOTOMAMONJY; GUIGUE, 2008; LAL et al., 2004; RIBE; KROHN, 2018). Além de problemas binários, as SVMs também se mostraram eficazes na classificação de múltiplas classes no contexto de ICM a partir da estratégia conhecida como *um contra um* (GE; WANG; YU, 2014).

Além da versatilidade com problemas lineares e não lineares, as vantagens do SVM incluem a boa capacidade de generalização mesmo quando a dimensionalidade dos dados é alta e quando há um ponderação não uniforme entre as características. Além disso, também performam bem em problemas de convergência não convexa (BELIZARIO, 2017; FACELI et al., 2011). No entanto, apesar da relativa insensibilidade ao *overfitting* e à dimensionalidade dos dados, as SVMs são sensíveis às definições dos hiperparâmetros (regularização e Kernel) (FACELI et al., 2011).

Embora a otimização quadrática eleve a exigência computacional do algoritmo, este ponto é de certa forma compensado pela construção de hiperplanos simples devido aos recursos de Kernel (BURGES, 1998; FACELI et al., 2011). Outro ponto a se destacar é que as SVMs tendem a apresentar baixo desempenho quando o número de exemplos de treinamento é limitado, o que eventualmente o torna menos eficaz que outras técnicas de classificação em sistemas de ICM-IM em específico (BASHASHATI et al., 2015; NAM; NIJHOLT; LOTTE, 2018).

3.2.4.4 K-ésimos vizinhos mais próximos (KNN)

Em problemas de classificação, é comum que as funções de densidade condicional de cada classe não sejam completamente conhecidas do ponto de vista estatístico e nesses

casos uma solução em potencial é classificar cada novo padrão de entrada conforme a evidência de observação dos exemplos mais próximos no espaço de características dos exemplos de treinamento (DENOEU, 2008).

Nesse contexto, a técnica baseada em distâncias conhecida como KNN é considerada uma das mais simples no campo do aprendizado de máquina (FACELI et al., 2011). Em suma, o classificador atribui uma classe à um novo vetor de características, \mathbf{x} , de acordo com a classe dominante (votação) entre os K vizinhos mais próximos dentro do conjunto de treinamento (LOTTE et al., 2018; DUDA; HART; STORK, 2012). A hipótese é de que dados similares tendem a estar concentrados em uma mesma região no espaço de entrada enquanto que dados não similares estão distantes entre si (FACELI et al., 2011).

O KNN é frequentemente referenciado na literatura como um método preguiçoso (*lazy*) por ser não paramétrico, ou seja, não gerar um modelo de aprendizado compacto a partir dos dados como nas técnicas lineares apresentadas anteriormente. A decisão sobre as classes é tomada apenas com base na memória dos exemplos de treinamento e seus respectivos rótulos (FACELI et al., 2011; RASCHKA, 2015). Ao contrário das contrapartes paramétricas, a técnica faz poucas suposições sobre a forma da distribuição dos dados de treinamento (BISHOP, 2006).

A proximidade entre os K pontos vizinhos no espaço de características CSP já definido, pode ser obtida com base em uma métrica de distância $d(\hat{\mathbf{x}}, \mathbf{x}_n)$, em que $\hat{\mathbf{x}}$ representa um novo vetor de características de teste e \mathbf{x}_n é o n -ésimo exemplo no conjunto de treinamento com $n = 1, 2, \dots, N_T$. As distâncias são uma medida da similaridade entre as características do vetor de teste e as características dos múltiplos vetores do conjunto de treinamento associados à cada classe (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Diferentes funções de métrica podem ser aplicadas, sendo a distância euclidiana a forma mais comum (RASCHKA, 2015). Dadas as N_r características nos vetores de teste e treinamento supracitados, o cálculo da distância entre eles na forma euclidiana é definido por:

$$d(\hat{\mathbf{x}}, \mathbf{x}_n) = \sqrt{\sum_{j=1}^{N_r} (\hat{x}^{(j)} - x_n^{(j)})^2} \quad (3.26)$$

em que, $\hat{x}^{(j)}$ e $x_n^{(j)}$ representam o j -ésimo elemento (característica) do vetor de teste e do n -ésimo vetor de treinamento, respectivamente. Além da distância euclidiana típica, outras métricas podem ser aplicadas no cálculo de similaridade entre os vetores de características no KNN.

Uma vez que a escolha da função de distância é considerada um hiperparâmetro do algoritmo, duas métricas alternativas à euclidiana são usadas no escopo deste trabalho, tais quais: Manhattan e Chebyshev. Por serem apropriadas à vetores de entrada cujos

elementos são estritamente numéricos, o que é o caso dos vetores que detêm as energias de sub-bandas dos sinais de EEG, todas as métricas adotadas são baseadas em variações da métrica de Minkowski, e suas formulações matemáticas são fornecidas em Faceli et al. (2011).

Na classificação de múltiplos exemplos, para cada vetor de teste $\hat{\mathbf{x}}$ são obtidos K vizinhos, cada qual votando em uma classe \mathcal{A} \mathcal{B} . A classificação $f(\hat{\mathbf{x}})$ corresponde à classe mais votada pelos seus K vizinhos, i.e. $f(\hat{\mathbf{x}}) = \text{moda}\left(f(\mathbf{x}_1), f(\mathbf{x}_2), \dots, f(\mathbf{x}_K)\right)$.

A quantidade K é um hiperparâmetro do KNN e frequentemente definida de maneira empírica pelo usuário. Em geral são atribuídos valores relativamente pequenos e ímpares para evitar empates, porém, a escolha do valor apropriado não é trivial e depende principalmente da dispersão e da sobreposição entre os grupos de dados (FACELI et al., 2011; BISHOP, 2006).

De acordo com Nicolas-Alonso e Gomez-Gil (2012), como alguns exemplos do conjunto de treinamento podem ser afetados por ruído e representar *outliers* de classe, ao elencar os K vizinhos para tomada de decisão, a probabilidade do erro na classificação é diminuída. Com um valor adequado para K e um conjunto de treinamento suficientemente grande, o KNN tem potencial para resolver problemas não lineares (LOTTE et al., 2007).

Uma desvantagem da regra de votação para escolha da classe no KNN é suposição implícita de que os K vizinhos mais próximos estão contidos em uma região relativamente homogênea. No entanto, a distância entre um dado $\hat{\mathbf{x}}$ e a maioria de seus vizinhos pode ser grande ao ponto de se induzir classificações incoerentes com as regiões de alta densidade (NICOLAS-ALONSO; GOMEZ-GIL, 2012; DENOEU, 2008).

Nesse sentido, uma estratégia relatada na literatura consiste em aplicar um vetor de pesos às K distâncias calculadas de tal maneira que a contribuição dos vizinhos mais próximos seja inversamente proporcional ao valor das respectivas distâncias (NICOLAS-ALONSO; GOMEZ-GIL, 2012), sendo:

$$\bar{\mathbf{w}} = \begin{cases} \frac{d_k - d_n}{d_k - d_1}, & \text{se } d_k \neq d_1 \\ 1, & \text{se } d_k = d_1 \end{cases}, \quad (3.27)$$

onde, d_k denota a distância do k -ésimo vizinho mais próximo e d_1 corresponde ao vizinho com menor valor de distância e d_K o mais distante. A decisão quanto à classe é tomada com base na maior soma de pesos entre os K vizinhos mais próximos.

Os algoritmos KNN não são muito populares na comunidade BCI por alguns motivos, primeiro por toda a computação até a fase de execução sem construir um modelo explícito a partir dos dados, o que o torna computacionalmente caro especialmente em aplicações *on-line*, depois por serem sensíveis à maldição da dimensionalidade (LOTTE et al., 2007).

No entanto, quando usado em sistemas de ICM cujos vetores de características

possuem baixa dimensionalidade bem como quando se tem poucos exemplos de treinamento, o KNN têm se mostrado eficiente, para além de se apresentar como uma alternativa potencial para problemas multi-classe (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Além disso, o fato de ser naturalmente incremental, onde novos exemplos de treinamento podem ser adicionados facilmente à memória do algoritmo, o KNN pode ser atraente à aplicações adaptativas de ICM.

Um ponto a se ressaltar sobre os cálculos de proximidade realizados no KNN é que a escala dos elementos nos vetores de característica é importante e pode impactar negativamente na medida de distância. Uma solução comum consiste na normalização dos dados (FACELI et al., 2011).

3.2.4.5 ANN Perceptron de Múltiplas Camadas (MLP)

As ANNs são modelos inspirados por redes neurais biológicas visando simular o processamento de informações nas interações sinápticas entre os neurônios no cérebro humano (NAM; NIJHOLT; LOTTE, 2018). A estrutura complexa composta por bilhões de neurônios interconectados por atividades sinápticas dão ao cérebro uma grande capacidade de processamento simultâneo de informações possibilitando o reconhecimento de padrões de forma rápida e natural no cotidiano (HAYKIN et al., 2009).

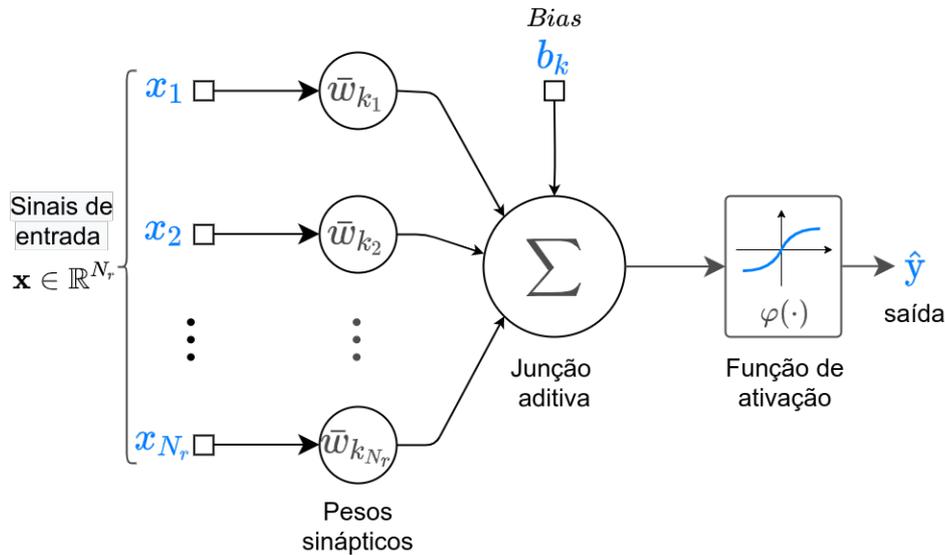
De forma análoga, ainda que longe de reproduzir as complexidades de redes cerebrais reais, uma ANN constrói um modelo de aprendizado mais simples a partir de uma rede interconectada de neurônios artificiais, os chamados *perceptrons*, cada qual responsável por ponderar e combinar múltiplos sinais de entrada a fim de produzir uma saída única, contínua ou discretizada, que, em regra, servirá de entrada para os neurônios seguintes, tomando como exemplo uma rede de fluxo único (*feedforward*) (HAYKIN et al., 2009).

A Figura 23 representa a forma geral de um perceptron, a unidade fundamental em uma ANN para problemas supervisionados de classificação, modelada originalmente por Rosenblatt (1958).

O perceptron na Figura 23 representa uma rede de camada única em que cada um dos sinais de entrada são associados à pesos sinápticos pelo combinador linear. A soma ponderada das entradas, aumentada por uma constante b de denominação *bias*, é submetida à uma função de ativação que delimita a amplitude da saída do neurônio à um intervalo finito. O mesmo neurônio artificial pode ser representado matematicamente, já no contexto de ICM-IM em que os sinais de entrada correspondem aos componentes de um vetor de características, \mathbf{x} , na forma da equação:

$$\hat{y} = \varphi \left(\sum_{j=1}^{N_r} \bar{w}_{kj} x_j + b_k \right) = \varphi(\bar{\mathbf{w}}_k^T \mathbf{x} + b_k) , \quad (3.28)$$

Figura 23. Modelo de um perceptron (neurônio artificial k) para processamento dos elementos em um vetor de características \mathbf{x} , composto por pesos sinápticos, um combinador linear e uma função de ativação não linear (tangente hiperbólica).



Fonte: Autoria própria, inspirado em Haykin et al. (2009) e Raschka (2015)

em que \hat{y}_n é a saída para o vetor de entrada composto por N_r características. A combinação linear entre esses elementos e os respectivos pesos em $\bar{\mathbf{w}}_k$, adicionada do bias b_k , é submetido à função de ativação $\varphi(\cdot)$. Nota-se a equivalência nas formulações de um perceptron e do classificador LDA (LOTTE et al., 2007).

Normalmente, o intervalo normalizado pela função de ativação está entre $[0, 1]$ ou $[-1, 1]$, a depender do tipo de função empregada (HAYKIN et al., 2009). Há diferentes formulações possíveis para $\varphi(\cdot)$, sendo duas funções sigmóides as mais comumente adotadas para classificação, tais quais: logística e tangente hiperbólica (RASCHKA, 2015).

Funções sigmoide apresentam uma razão de equilíbrio interessante entre os comportamentos linear e não linear o que explica ser o tipo de função mais comumente adotado para ANNs projetadas para classificação (HAYKIN et al., 2009). Uma de suas especializações mais comuns, a função logística, já citada na seção 3.2.4.2 é diferenciável e assume valores contínuos no intervalo $[0, 1]$. A flexibilidade nessa função é definida por um parâmetro de inclinação, o qual, à medida que se aproxima de $+\infty$, estabelece uma variante discretizada (0 ou 1) e não diferenciável, conhecida como função limiar (*Step function* ou *Heaviside function*) (RASCHKA, 2015).

Por conveniência, o intervalo normalizado pela função de ativação pode estar entre -1 e 1. Para tanto, outra formulação sigmoide possível é a tangente hiperbólica que, ao ampliar o espectro de saída do neurônio em relação à função logística, pode melhorar a convergência do algoritmo de otimização usado no ajuste dos pesos da ANN (RASCHKA, 2015; BISHOP et al., 1995). A função correspondente à função limiar derivada da tangente

hiperbólica é conhecida como função *signum* e, por óbvio, assume valores -1 ou 1.

Enquanto que o perceptron único representado na Figura 23 devidamente treinado é capaz de classificar exemplos linearmente separáveis, para problemas não lineares surge a necessidade de uma estrutura mais complexa formada por uma rede de neurônios interconectados por camadas sobrepostas, similar às redes neuronais reais (BUENO, 2017). Essa rede definida por uma série de perceptrons altamente interconectados e dispostos em diferentes camadas é conhecida como MLP, a arquitetura ANN mais comum em aplicações práticas (FACELI et al., 2011; NAM; NIJHOLT; LOTTE, 2018; LOTTE et al., 2018).

De acordo com Bishop et al. (1995), uma MLP típica é composta de múltiplas camadas de neurônios, sendo: uma camada de entrada; uma ou várias camadas ocultas e; uma camada de saída compreendida pelos neurônios mais distantes da entrada. Em geral, os neurônios em cada camada da rede têm como entradas os sinais de saída apenas da camada anterior, enquanto os neurônios da camada de saída determinam a classe dos padrões de entrada (HAYKIN et al., 2009).

Diferentemente do perceptron de uma camada (sem camadas ocultas), nas redes MLP cada neurônio está associado a uma função de ativação não-linear, o que adiciona flexibilidade ao modelo que passa a estar apto à problemas resolução de problemas não lineares e de multiplas classes (ROCHA, 2020; NICOLAS-ALONSO; GOMEZ-GIL, 2012). O gráfico na Figura 24 ilustra uma ANN MLP *feedforward*⁶ de duas camadas ocultas e dois neurônios na camada de saída.

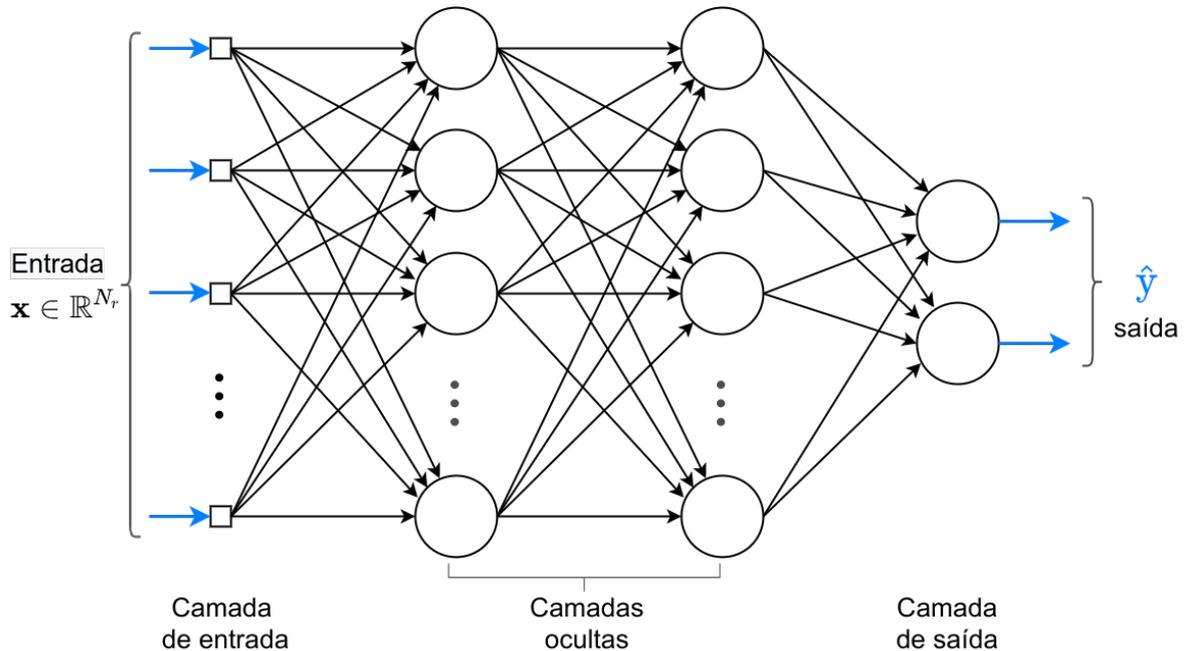
Os nós da camada de entrada fornecem os padrões de entrada em \mathbf{x} à primeira camada oculta, cujos neurônios realizam a soma ponderada e aplicam a função não linear para obter saídas que serão submetidas à segunda camada oculta, e esse processamento se repete até a camada final. Os neurônios na camada de saída constituem estados mutualmente exclusivos que indicam a classe do respectivo vetor de entrada (BISHOP, 2006).

Conforme salienta Rocha (2020), para saídas discretas, o esquema 1-de- K , é comumente adotado, em que K representa o número de classes do problema de classificação e a representação da saída é tida por um vetor onde um dos elementos é igual a 1 enquanto os elementos restantes são iguais a 0. No caso ilustrado na Figura 24 onde $K = 2$, há duas composições possíveis para o vetor de saída, $\hat{y} = [1 \ 0]$ ou $\hat{y} = [0 \ 1]$, indicando, por exemplo, as classes de IM \mathcal{A} e \mathcal{B} , respectivamente.

A maior parte do processamento nas redes MLP está nas camadas ocultas, haja vista que seus neurônios funcionam como extratores progressivos de características por meio das funções de ativação não lineares individuais (HAYKIN et al., 2009). Isso faz

⁶ Os sinais são propagados em sentido único, da saída de um neurônio para os neurônios da camada seguinte

Figura 24. Estrutura de uma rede MLP com duas camadas ocultas e a camada de saída para problema de classificação binária



Fonte: Adaptada de Haykin et al. (2009)

desses neurônios atuadores fundamentais no processo de aprendizagem das MLP, ou seja, no ajuste dos pesos da rede (ROCHA, 2020).

Os métodos de aprendizado diferem para diferentes tipos de ANN, mas consistem em processos iterativos para a determinação dos pesos internos da rede (DEMUTH et al., 2014). Assim como o classificador SVM, uma ANN MLP também recorre a um processo de otimização para ajuste supervisionado de um modelo de classificação, ou seja, o aprendizado consiste em extremar uma função custo considerando as saídas conhecidas nos dados de treinamento (FACELI et al., 2011).

A retropropagação do erro (do inglês, *backpropagation*), foi introduzida por (RUMELHART; HINTON; WILLIAMS, 1986) e representa o algoritmo de aprendizado mais popular nas MLP. Nele, o método de otimização do gradiente descendente é usado para minimizar o erro quadrático entre os rótulos conhecidos nos dados de treinamento e os rótulos produzidos pela rede à cada iteração (ou época) (FACELI et al., 2011).

Em suma, no processo de treinamento, um conjunto de exemplos de treinamento são submetidos à rede e a cada época o algoritmo *backpropagation* busca minimizar os erros entre as saídas obtidas e as saídas esperadas (rótulos de treinamento) ao longo de um número finito de épocas (DEMUTH et al., 2014). Assim, têm-se duas etapas em que, primeiro, na etapa intitulada *forward*, os pesos das interconexões são geralmente iniciados de forma estocástica e o fluxo de execução ocorre da esquerda para direita na Figura 24. Posteriormente, na etapa de *backward* os erros calculados são propagados para os pesos

internos da rede a fim de atualizá-los no sentido contrário da etapa anterior.

A função de mapeamento é uma combinação de múltiplos mapeamentos individuais não lineares, e o treinamento persiste até que uma das condições a seguir seja satisfeita (NICOLAS-ALONSO; GOMEZ-GIL, 2012):

- i. estado estacionário: com erro mínimo, onde não há melhoria significativa entre épocas consecutivas;
- ii. gradiente mínimo de saída: com convergência para um valor específico diferente do valor esperado;
- iii. número máximo de épocas (iterações): caso a rede ainda não tenha convergido ou atendido às condições.

O valor do erro mínimo, conhecido como *tolerância*, é um hiperparâmetro da rede e, portanto, deve ser definido antes do treinamento. Aliás, a definição cuidadosa de outros hiperparâmetros fundamentais que vão além do algoritmo de otimização dos pesos sinápticos também é necessária. Dentre esses hiperparâmetros estão, por exemplo: número de camadas ocultas, número de neurônios em cada camada oculta, função de ativação e número máximo de épocas (ISHFAQUE et al., 2013).

Assim como todo modelo de classificação que aprende com exemplos em modo supervisionado, espera-se que uma rede MLP corretamente treinada possa generalizar bem para dados que não foram utilizados durante o treinamento, de forma a reconhecer novos padrões de entrada (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Para além das características de entrada, a eficácia do método também depende da definição adequada desses hiperparâmetros (DEMUTH et al., 2014).

A principal vantagem das ANNs em geral e, conseqüentemente, das MLPs é que estas são estimadores universais, ou seja, podem aproximar qualquer função não linear (LOTTE et al., 2018). Além disso são altamente tolerantes á falhas (NAM; NIJHOLT; LOTTE, 2018). Por serem muito flexíveis, os classificadores ANN têm sido aplicados a uma ampla variedade de problemas binários e de multiplas classes em diferentes áreas do conhecimento (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Essas vantagens, também fazem com que as redes MLP sejam amplamente empregadas na classificação de sinais de EEG em ICM de diferentes paradigmas, complexidades e aplicações (LOTTE et al., 2007). As MLPs foram aplicadas em problemas de ICM binários (PALANIAPPAN, 2005), múltiplas classes (SINGH et al., 2007), ICMs síncronas (HASELSTEINER; PFURTSCHELLER, 2000) e baseadas em IM (AGUILAR; CASTILLO; ELIAS, 2015).

Ishfaque et al. (2013), por exemplo compararam o desempenho do LDA e Árvores de Decisão no contexto de múltiplas classes de IM com o desempenho de classificação de uma ANN MLP de camada oculta única com 20 neurônios treinada com um total de 1000 épocas. (BALAKRISHNAN; PUTHUSSERYPADY, 2005), por sua vez, utilizou um classificador MLP binário para distinguir classes de IM dos dedos nas mãos esquerda e direita em um contexto de redução de canais de EEG.

Além disso, a MLP tem sido usada no pré-processamento de EEG, antes mesmo da etapa de classificação, a fim de melhorar a separabilidade das características (COYLE; MCGINNITY; PRASAD, 2010). Jung et al. (1997) utiliza ANN na análise das alterações no espectro de potência do EEG em função do estado de alerta do indivíduo.

Vale ressaltar porém, que a capacidade de aproximação universal das MLP torna esses classificadores sensíveis ao *overfitting*, especialmente com dados ruidosos e não estacionários como o EEG (BALAKRISHNAN; PUTHUSSERYPADY, 2005). Para esse problema o uso de regularização é uma alternativa possível (LOTTE et al., 2007). No estudo de Bashashati et al. (2015) por exemplo, em que o desempenho médio de uma ANN MLP *feedforward* projetada com uma camada oculta superou o de outros 7 classificadores na classificação de padrões de IM associados à energia em sub-bandas de frequência foi comparada, os autores usaram regularização L1 e L2 para evitar *overfitting*.

Lotte et al. (2007) cita várias outras arquiteturas de ANN, além da MLP, que tem sido usadas para aplicações ICM. Em destaque, está a ANN Gaussiana foi aplicada com sucesso a imagens motoras (LEEB et al., 2014) e em paradigmas assíncronos de ICM (CINCOTTI et al., 2003), por exemplo. Já Bueno (2017), implementou uma ICM-IM utilizando ANNs auto-organizadas (SOM, do inglês *Self Organizing Maps*).

Um aspecto que, eventualmente, pesa contra o uso das MLPs, em relação à outros classificadores consiste no fato de que a função de custo a ser otimizada é, normalmente, uma função não convexa (BASHASHATI et al., 2015). Isso significa que, diferentemente do SVM, onde o problema de otimização quadrática apresenta uma única solução global, no caso das MLP o método gradiente pode convergir para mínimos locais dependendo dos valores atribuídos aos hiperparâmetros citados anteriormente bem como dos valores dos pesos iniciais (FACELI et al., 2011). Em virtude disso, é comum que a rede seja aplicada à dados de testes várias vezes, usando um processo de validação cruzada por exemplo, tomando-se a média entre as execuções como desempenho final.

Por fim, e não menos importante, tanto o SVM quanto as ANN MLP são consideradas técnicas de difícil interpretação (caixas-pretas), haja vista que o conhecimento extraído das entradas é armazenado na forma de um grande volume de parâmetros, o que torna a compreensão de como e por que essas técnicas tomam decisões não trivial (FACELI et al.,

2011).

3.2.5 Processamento baseado em Sub-bandas

Nas seções anteriores foram descritas cada uma das etapas da arquitetura clássica de sistemas de ICM-IM, tradicionalmente composta pela cadeia de processamento ilustrada na Figura 11 e expandida pela Figura 17. Na arquitetura apresentada observa-se que o aprimoramento dos sinais é caracterizado essencialmente pela filtragem dos sinais em banda única, representada pelo intervalo de interesse em Δ_f , o qual, em geral, compreende frequências associadas aos ritmos SMR, conforme descrito na seção 3.2.2.1.

Nesta seção, uma cadeia de processamento alternativa baseada em sub-bandas será discutida e as principais variações em relação à cadeia de banda única serão apresentadas. Diferentemente da arquitetura clássica, a arquitetura SBCSP utiliza um banco de filtros para decompor e filtrar os sinais considerando múltiplas faixas de frequências (NOVI et al., 2007).

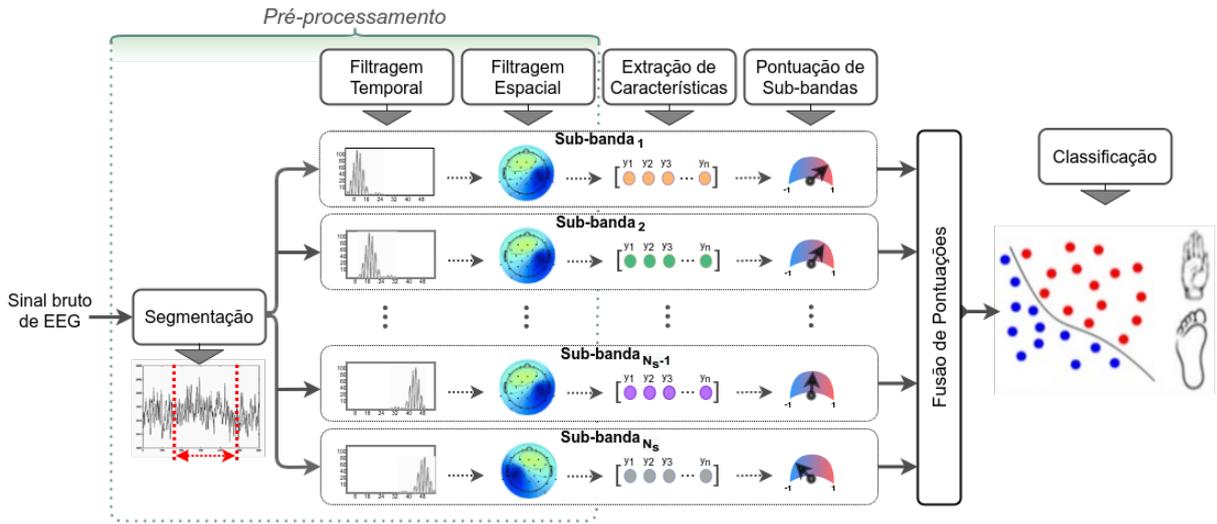
De acordo com Ang et al. (2012a) e Wei e Wei (2016), a alta variabilidade da atividade elétrica cerebral, faz com que os padrões oscilatórios associados às tarefas motoras sofram uma importante variação espectral de indivíduo para indivíduo. Nesse sentido, o método SBCSP foi proposto a fim de maximizar o desempenho do CSP clássico na medida em que explora as frequências discriminativas de cada sujeito e destaca a informação espectral útil enquanto minimiza a influência de frequências que pouco contribuem para discriminação entre classes de IM (LOTTE, 2014; NOVI et al., 2007).

Por usar informações espectrais mais precisas para descrever o estado mental do indivíduo do ponto de vista de sua intenção motora em relação ao uso de uma faixa larga e única de frequências, a cadeia SBCSP destaca-se na literatura como uma abordagem eficaz na decodificação e classificação dos padrões de IM em sinais de EEG (ANG et al., 2012a; KUMAR; INBARANI, 2017). A fim de ilustrar genericamente a cadeia de processamento baseada em sub-bandas a Figura 25 é apresentada.

Nota-se na proposição original de Novi et al. (2007) apresentada na Figura 25 que para satisfazer os propósitos finais em sistemas de ICM-IM a implementação de uma estrutura mais sofisticada de filtragem faz com que a arquitetura SBCSP apresente algumas particularidades em relação à arquitetura baseada em banda única e requeira etapas adicionais de processamento.

Na prática, a aplicação da abordagem SBCSP consiste em decompor o intervalo de frequências inicial, definido em Δ_f , em um conjunto de N_s sub-bandas, cada qual com um sub-conjunto de frequências consecutivas, e utilizar um banco de filtros para filtrar os sinais em cada sub-banda. O intervalo em Δ_f é comumente segmentado de forma a definir

Figura 25. Diagrama funcional da cadeia de processamento baseada em sub-bandas (SBCSP), caracterizada pela decomposição dos sinais de entrada em N_s sub-bandas as quais são processadas paralelamente usando o método CSP como referência



Fonte: Autoria própria com base em Novi et al. (2007) e Kumar e Inbarani (2017)

as N_s sub-bandas por intervalos uniformes, podendo haver ou não uma sobreposição entre frequências de sub-bandas consecutivas (ANG et al., 2008; ANG et al., 2012a).

Essencialmente, após a filtragem dos sinais em cada sub-banda o processamento ocorre em paralelo conforme as etapas de uma cadeia clássica de banda única. Nesse sentido, as etapas discutidas anteriormente em cada são aplicáveis à cada ramo da arquitetura de sub-bandas ilustrada na Figura 25. Este ponto fica evidente ao comparar o fluxo individual em cada uma das N_s sub-bandas com as etapas ilustradas no diagrama da Figura 17.

Múltiplas instâncias das matrizes de transformação CSP, $\mathbf{W}^{(\ell)}$, obtidas a partir das N_T épocas de treinamento já filtradas por um banco de filtros, são usadas para processar paralelamente os sinais em cada sub-banda conforme o procedimento descrito nas sessões 3.2.2.2 e 3.2.3, em que $\ell = 1, 2, \dots, N_s$.

Assim, à cada segmento de sinal submetido à cadeia de sub-bandas, são gerados N_s vetores de características, $\mathbf{x}^{(\ell)}$, cada qual proveniente do ℓ -ésimo sinal espacialmente filtrado, $\mathbf{R}^{(\ell)} \in \mathbb{R}^{N_r \times Q}$.

Uma etapa adicional, identificada como *pontuações de sub-bandas* é aplicada a fim de se pontuar as características em cada uma das N_s sub-bandas e obter uma saída única. Para tanto, a técnica de *Fisher* descrita na seção 3.2.4.1, é comumente empregada devido à sua notória eficácia no contexto de ICM-IM bem como seu baixo custo computacional e sua simplicidade (LOTTE; GUAN, 2011).

O LDA atua na cadeia SBCSP como um meta-classificador de sub-banda, ao produzir uma saída contínua $s^{(\ell)} = f(\mathbf{x}_n^{(\ell)})$, conhecida como pontuação de sub-banda, a

partir da aplicação do vetor de parâmetros $\bar{\mathbf{w}}^* \in \mathbb{R}^{N_r}$, no respectivo vetor de características de entrada $\mathbf{x}^{(\ell)}$, na forma da equação (3.17). Vale ressaltar que, os parâmetros no vetor $\bar{\mathbf{w}}^*$, os quais definem o ℓ -ésimo modelo LDA, são calculados a partir dos $N_{\mathcal{T}}$ vetores de características associados à ℓ -ésima sub-banda na fase de treinamento.

Naturalmente, etapas adicionais são necessárias a fim de possibilitar uma classificação discreta global quanto ao tipo de tarefa mental a partir das saídas contínuas individuais, para tanto após a obtenção das obtidas N_s pontuações LDA, cada uma representando uma característica de sub-banda, essas são agrupadas de modo a compor um vetor único de meta-classificações para enfim serem enviadas para classificação final.

Ang et al. (2012a) e Olivas-Padilla e Chacon-Murguia (2019), por exemplo, propõem diferentes estratégias para a etapa denominada fusão de pontuações. Uma estratégia típica considerada por Novi et al. (2007) baseia-se no treinamento de um meta-classificador *Bayesiano* usando as pontuações de sub-bandas obtidas para os $N_{\mathcal{T}}$ exemplos do conjunto de treinamento.

A abordagem assume que a distribuição das pontuações LDA em cada sub-banda, obtidas das épocas associadas à cada classe de IM, $\rho \in \{\mathcal{A}, \mathcal{B}\}$, corresponde a uma distribuição normal, i. e.:

$$\mathcal{L}(\rho | s^{(\ell)}) = \frac{1}{\sigma_{\rho}^{(\ell)} \sqrt{2\pi}} \exp\left(-\frac{(s^{(\ell)} - \mu_{\rho}^{(\ell)})^2}{2(\sigma_{\rho}^{(\ell)})^2}\right), \quad (3.29)$$

em que,

$$\mu_{\rho}^{(\ell)} = \frac{1}{N_{\rho}} \sum_{n=1}^{N_{\rho}} s_n^{(\ell)} \quad \text{e} \quad \sigma_{\rho}^{(\ell)} = \sqrt{\frac{1}{N_{\rho}} \sum_{n=1}^{N_{\rho}} (\mu_{\rho}^{(\ell)} - s_n^{(\ell)})^2}, \quad (3.30)$$

são, respectivamente, a média e o desvio padrão das pontuações LDA atribuídas às N_{ρ} épocas de cada classe ρ .

Com isso, pode-se avaliar a densidade de probabilidade das distribuições obtidas em função da razão de verossimilhança entre as classes e obter uma meta-pontuação *Bayesiana* conforme transformação não linear na forma,

$$\mathbf{v}^{(\ell)} = \log\left(\frac{\mathcal{L}(\mathcal{A} | s^{(\ell)})}{\mathcal{L}(\mathcal{B} | s^{(\ell)})}\right), \quad (3.31)$$

em que $\log(\cdot)$ calcula a função logarítmica do argumento. As meta-pontuações nas N_s sub-bandas podem ser agregadas por um vetor de características $\mathbf{v} = [\mathbf{v}^{(1)}, \mathbf{v}^{(2)}, \dots, \mathbf{v}^{(N_s)}]^T$.

Como forma de compensar os erros produzidos pelos meta-classificadores individuais, um classificador final $f(\mathbf{V}^T)$ é ajustado com base nos vetores $\mathbf{v}_n \in \mathbf{V}^{N_s \times N_{\mathcal{T}}}$ obtidos a partir das épocas no conjunto de treinamento, juntamente com seus respectivos rótulos $\mathbf{y}_n \in \mathbf{y}^{1 \times N_{\mathcal{T}}}$. Assume-se a forma genérica $f(\mathbf{V}^T)$ de modo a manter livre a definição da

técnica de classificação definitiva, podendo inclusive, ser uma das técnicas descritas nas seções 3.2.4.1 a 3.2.4.5. Novi et al. (2007), por exemplo, projetou a arquitetura SBCSP usando um classificador SVM linear, baseado na implementação fornecida por Chang e Lin (2011), na última etapa do processamento .

Independentemente da forma de f , espera-se obter um modelo de classificação capaz de distinguir padrões correspondentes às duas classes de IM, \mathcal{A} e \mathcal{B} , tanto a partir dos próprios dados de treinamento quanto em novos dados coletados previamente em um conjunto de teste ou coletados em tempo real. De maneira prática, seja $\hat{\mathbf{v}}$ um novo vetor de meta-pontuações provenientes das transformações nas etapas anteriores da cadeia de sub-bandas, ao aplicar o modelo f , têm-se uma saída discreta $\hat{y} \in \{-1, 1\}$ de modo que $\hat{y} = -1$ indica MI da classe \mathcal{A} e $\hat{y} = 1$ indica MI da classe \mathcal{B} .

3.3 Avaliação de desempenho em ICM-IM

Na mesma medida que o processo de desenvolvimento, a avaliação de desempenho em sistemas de ICM-IM também é relevante. Mensurar aspectos técnicos como taxa de sucesso de classificação e tempo de processamento e comunicação, bem como aspectos mais subjetivos como a usabilidade e versatilidade dos sistemas são fundamentais para avaliar o estado da arte e nortear trabalhos futuros (HONG; KHAN, 2017).

Contudo, fatores como variabilidade dos padrões de IM, diversidade de métodos de aquisição e protocolos experimentais contextualizados métricas de avaliação próprias contribuem para a inexistência de uma forma fechada de se avaliar sistemas de ICM (ALLISON; NEUPER, 2010; SCHLÖGL et al., 2007). As métricas de desempenho podem variar conforme a aplicação, os objetivos e o paradigma utilizado no projeto (THOMAS; DYSON; CLERC, 2013).

Diante das diversas possibilidades de medir o desempenho de ICM-IM sugeridas na literatura, três se destacam como as mais frequentes, a acurácia de classificação, a matriz de confusão e a taxa de transferência de informação (ITR, do inglês *Information Transfer Rate*) (THOMPSON; BLAIN-MORAES; HUGGINS, 2013).

Enquanto a acurácia e a matriz de confusão propiciam a análise do desempenho no nível lógico, avaliando a seção da cadeia de processamento ICM-IM desde a aquisição de dados até a classificação de estados mentais, a ITR permite uma análise de desempenho em nível semântico e voltada para a usabilidade prática ao quantificar a velocidade da comunicação entre o sistema e a aplicação (CLERC; BOUGRAIN; LOTTE, 2016b).

3.3.1 Acurácia de classificação

Em se tratando do desempenho da etapa de processamento, a capacidade do sistema em discriminar com sucesso as tarefas mentais de IM é tradicionalmente medida por meio da acurácia de classificação (CLERC; BOUGRAIN; LOTTE, 2016a; THOMPSON; BLAIN-MORAES; HUGGINS, 2013). O desempenho de classificação depende de diversos fatores como: volume de dados, do número de características selecionadas, da complexidade do algoritmo, da quantidade de classes envolvidas, dentre outros (LOTTE et al., 2007; LOTTE et al., 2018).

A acurácia é uma medida efetiva da taxa de acerto na classificação ao relacionar o número de exemplos corretamente classificados, p_c , com o número total de exemplos realizados, p_t , durante um experimento (SILVA, 2017). Logo, o cálculo de acurácia em porcentagem (%) é dado pela expressão:

$$Acc(\%) = \frac{p_c}{p_t} \times 100 . \quad (3.32)$$

Nota-se que, ao desconsiderar o termo para obtenção da porcentagem, a acurácia também pode ser interpretada em relação à taxa de erro de *Bayes*, ou seja, $Erro = 1 - \frac{p_c}{p_t}$. Vale ressaltar que por ser uma métrica universal, além da avaliação do classificador, a acurácia pode ser usada para medir a taxa de acerto em decisões em geral.

3.3.2 Matriz de confusão

Apesar de ser amplamente utilizada no contexto de ICM, a acurácia de classificação nem sempre é tida como um método ideal por não considerar aspectos como sensibilidade, especificidade e seletividade na aferição da performance além de ser dependente da estratificação entre as classes (CLERC; BOUGRAIN; LOTTE, 2016a). Nesse sentido, uma análise estatística mais completa do desempenho de classificação pode ser feita a partir da matriz de confusão.

No contexto de classificação, especificamente, uma matriz de confusão expressa as saídas esperadas do classificador como linhas, as saídas preditas como colunas e o número de ocorrências nas intersecções (THOMPSON; BLAIN-MORAES; HUGGINS, 2013). A Figura 26 apresenta uma matriz de confusão considerando um problema de duas classes.

No problema apresentado, a matriz indica quatro possibilidades entre acertos e erros de classificação. Nota-se que a diagonal principal representa o número de eventos classificados corretamente em contraste com as demais células que expressam as classificações incorretas. Ademais as somas relativas das linhas revelam a frequência de cada saída esperada e podem ser usadas para calcular padrões na distribuição de erros, como mencionado anteriormente e demonstrado por Faceli et al. (2011) e Gubert (2019).

Figura 26. Matriz de confusão para um problema de decisão binária, em que denomina-se uma classe como positiva e outra como negativa

		Classe Preditada	
		Positivo	Negativo
Classe Verdadeira	Positivo	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Negativo	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: Autoria própria com base em Marsland (2014)

No cenário em que as duas classes na Figura 26 são representadas pelas classes de \mathcal{IM} , \mathcal{A} e \mathcal{B} , respectivamente, VP refere-se às épocas associadas à classe \mathcal{A} classificadas como \mathcal{A} , VN às épocas de \mathcal{B} classificadas como \mathcal{B} , FP às épocas da classe \mathcal{B} classificadas como \mathcal{A} e FN às épocas de \mathcal{A} classificadas como \mathcal{B} .

Ao considerar os termos na matriz de confusão para cálculo da acurácia de classificação neste cenário, têm-se:

$$Acc = \frac{VP - VN}{VP + FP + VN + FN} . \quad (3.33)$$

A correlação entre Eq. (3.32) e Eq. (3.33), denota que, de fato, a acurácia expressa a taxa de acerto global pela proporção de classificações verdadeiras em relação ao todo, sendo que seu máximo, $Acc = 1$, implica em uma matriz de confusão diagonal.

Outros aspectos relevantes que podem ser analisados a partir da matriz de confusão referem-se à seletividade (*selet*), à especificidade (*espec*) e à sensibilidade (*sens*) (GUBERT, 2019). As duas primeiras, medem a taxa de acerto na classe positiva e a taxa de acerto na classe negativa, respectivamente, enquanto que a sensibilidade expressa a capacidade do classificador em identificar a ocorrência de um evento, isto é:

$$selet = \frac{VP}{VP + FN} , \quad espec = \frac{VN}{VN + FP} \quad \text{e} \quad sens = \frac{VP}{VP + FN} . \quad (3.34)$$

Mesmo sendo considerada uma ferramenta estatística efetiva na medição do desempenho do classificador, a matriz de confusão, no entanto, não é capaz de expressar a performance da ICM-IM como um todo por não levar em conta o tempo em que a informação trafega pelo sistema e chega até a aplicação (THOMPSON; BLAIN-MORAES; HUGGINS, 2013; NOURMOHAMMADI; JAFARI; ZANDER, 2018). Afinal, tanto a acurácia como a análise completa da matriz de confusão, se pautam exclusivamente na

quantificação da eficácia de detecção dos padrões de IM no sinal de EEG, desconsiderando critérios de usabilidade e integração (THOMAS; DYSON; CLERC, 2013).

A análise de desempenho geral deve considerar aspectos mais abrangentes que contemplem, inclusive, o processo de tradução da saída do classificador em comandos confiáveis (CLERC; BOUGRAIN; LOTTE, 2016a; SCHLÖGL et al., 2007). Para tanto, uma métrica derivada da teoria da informação que mostra-se útil neste aspecto é a ITR, também conhecida como taxa de bits, a qual pode ser usada em complementação à acurácia de classificação no contexto de ICM-IM (WOLPAW et al., 1998; KRONEGG; VOLOSHYNOVSKYY; PUN, 2005).

3.3.3 Taxa de transferência de informação (ITR)

A ITR foi proposta para integrar o fator tempo à métrica de desempenho e é usada para medir a velocidade em que sinais de comandos efetivos, ou seja, que representam de fato a intenção motora do indivíduo, são enviados à aplicação (WOLPAW et al., 2002). Em outras palavras, a ITR corresponde à quantidade de informação útil processada pelo sistema ICM-IM e enviada à aplicação em um determinado período de tempo, i.e. a taxa de bits por segundo produzidos pelo sistema (LEE et al., 2019).

No cálculo da ITR, o tempo necessário para que o estado mental do usuário se manifeste em comando efetivo depende diretamente do desempenho de classificação, uma vez que este interfere na probabilidade de o comando representar a intenção motora do usuário (GRAIMANN; ALLISON; PFURTSCHHELLER, 2010). Assim, além da taxa de sucessos nas tentativas de controle, a métrica considera o tempo decorrido durante as tentativas e o número de tarefas mentais possíveis equivalente ao grau de liberdade da aplicação. Tais variáveis, definem uma expressão fechada na forma:

$$\bar{ITR} = \bar{M} \left[\log_2(\bar{N}) + \bar{P} \log_2(\bar{P}) + (1 - \bar{P}) \log_2 \left(\frac{(1 - \bar{P})}{(\bar{N} - 1)} \right) \right], \quad (3.35)$$

onde \bar{P} assume valores entre 0 e 1 e representa a acurácia na tomada de decisões entre \bar{N} possíveis escolhas ou alvos ao longo das tentativas, com cada escolha tendo uma probabilidade igual de ser selecionada pelo usuário. Como exemplo, para o caso em que a aplicação é controlada exclusivamente em 1 dimensão (1D) a partir de comandos associados à duas classes de IM, $\bar{N} = 2$. A inclusão da velocidade de decisão no cálculo de ITR é dada ao definirmos \bar{M} como o número de comandos por segundo (ou minutos, a depender da aplicação). Note que Acc e \bar{P} se equivalem no contexto de medição do rendimento da ICM usando a ITR.

A relevância da ITR no contexto de ICM está no fato de que essa métrica leva em consideração a capacidade do usuário de operar o sistema e ao mesmo tempo considera

a capacidade efetiva da cadeia de processamento em identificar corretamente a intenção do usuário (KRONEGG; VOLOSHYNOVSKYY; PUN, 2005). De acordo com Graimann, Allison e Pfurtscheller (2010), mesmo em cenários controlados de laboratório, o canal de comunicação fornecido por esses sistemas de ICM-IM é lento se comparado à saída natural do cérebro, sendo improvável a manutenção de um ITR alto ao longo do tempo de execução.

A operação do sistema por um período muito longo pode causar exaustão ao usuário, diminuindo seu grau de engajamento. Por outro lado, interfaces que não ofereçam *feedback* adequado podem levar à perda da concentração ou ao tédio. Ambas as circunstâncias podem levar o usuário à perda da capacidade em modular os fenômenos voluntários de IM e conseqüentemente à uma queda substancial de desempenho (ŠKOLA; LIAROKAPIS, 2018; WU et al., 2017; SCHERER et al., 2013).

Nesse cenário, a importância da fase de treinamento e da calibração do sistema fica evidente, tanto no que diz respeito ao aprendizado do indivíduo por meio de *feedback* quanto no aprendizado do sistema através do reconhecimento de padrões cognitivos (NOURMOHAMMADI; JAFARI; ZANDER, 2018; CLERC; BOUGRAIN; LOTTE, 2016a).

3.3.4 Outras formas de avaliação

O funcionamento de uma ICM-IM depende de diversos fatores e a escolha dos procedimentos de avaliação é uma etapa chave na representação de desempenho desses sistemas (RIBE; KROHN, 2018). Além das métricas apresentadas, outras formas de mensurar o desempenho de sistemas estão relacionadas com o contexto ao qual o sistema está inserido.

Observações acerca da carga de trabalho e do grau de engajamento, por exemplo, como forma de medir as condições de usabilidade fazem parte do domínio de avaliação de ICM (NOURMOHAMMADI; JAFARI; ZANDER, 2018). Além disso, avaliar a habilidade do indivíduo em operar a aplicação em cenários pré-definidos, através do cálculo de erro de operação, também é uma forma possível de se verificar a usabilidade (DUARTE, 2017; VISHWANATH; KUMAAR; OMKAR, 2018).

Como uma métrica estatística alternativa, o coeficiente *Kappa* também é amplamente utilizado no contexto de ICM-IM, especialmente para medir o grau de concordância entre diferentes classificadores ou em validações cruzadas (CARLETTA, 1996; CLERC; BOUGRAIN; LOTTE, 2016a). De acordo com Thompson, Blain-Moraes e Huggins (2013), o coeficiente *Kappa* pode ser obtido a partir da taxa de sucesso de decisão, hora representada pela acurácia de classificação, *Acc*, hora representada pela acurácia de decisão durante o controle, \bar{P} , de modo que $Kappa = \frac{\bar{P}-1/N}{1-1/N}$.

Dentre os estudos ICM-IM que adotam o coeficiente *Kappa* como métrica de desempenho, podem ser citados, por exemplo: Blankertz et al. (2006), Ang et al. (2012a), Vaz (2016), Jafarifarmand et al. (2018), Billinger, Brunner e Müller-Putz (2013).

Outra métrica frequentemente adotada na avaliação do modelo de classificação, desta vez com base em critérios de especificidade e sensibilidade, é a análise da curva ROC, (do inglês, *Receiver Operating Characteristic curve*) (LOTTE et al., 2018; HASTIE; TIBSHIRANI; FRIEDMAN, 2017). De maneira mais específica, neste caso o desempenho é aferido pela área abaixo da curva (AUC, da sigla em inglês, *Area Under Curve*), em que o valor 1 é considerado ideal (máximas sensibilidade e especificidade), enquanto que valores abaixo de 0,5 caracterizam um desempenho inadequado, similar ao de um classificador aleatório (FACELI et al., 2011; GUBERT, 2019). Kumar e Inbarani (2017) e Yang et al. (2017) por exemplo, podem ser citados entre os estudos que utilizam a curva ROC na análise do desempenho em ICM.

4 CONFIGURAÇÃO DE HIPERPARÂMETROS

Até aqui, foram discutidas as etapas típicas do processamento de sinais de EEG em sistemas de ICM-IM e descritas as principais técnicas comumente empregadas em cada etapa. Ao longo do Capítulo 3, foi discutido que durante a fase de treinamento, o modelo de classificação é obtido a partir do ajuste dos algoritmos na cadeia de processamento que, por sua vez, ocorre com base em um conjunto de épocas de EEG cujas respectivas classes de IM são conhecidas.

Adicionalmente, uma série de variáveis devem ser definidas antes mesmo do início do treinamento, de forma a direcionar a convergência do ajuste dos parâmetros que definem o modelo. Tais variáveis, conhecidas como hiperparâmetros, cumprem um papel fundamental na construção do modelo de classificação e tendem a influenciar diretamente sua capacidade preditiva (ALVARENGA JÚNIOR, 2018).

No âmbito de sistemas de ICM-IM os hiperparâmetros representam o conjunto de argumentos cuja configuração prévia é necessária para preparar cada etapa de processamento e cada algoritmo utilizado desde o pré-processamento dos sinais até a obtenção do modelo de classificação (CLERC; BOUGRAIN; LOTTE, 2016a; BASHASHATI; WARD; BASHASHATI, 2016b). Em outras palavras, a configuração dos hiperparâmetros equivale à configuração do sistema propriamente dito e, possibilita a obtenção de um modelo de classificação conforme as especificações definidas em cada etapa do processamento.

É comum que esses hiperparâmetros sejam definidos de forma universal e manual pelo projetista ou técnico responsável pelo experimento, contudo, estudos apontam que a configuração empírica tende a resultar em modelos de classificação pouco generalistas uma vez que, por vezes, são incapazes de reconhecer de maneira satisfatória os padrões que definem a intenção motora de cada usuário (FENG et al., 2018; BASHASHATI; WARD; BASHASHATI, 2016a).

Ante o exposto, estratégias baseadas na estimativa de hiperparâmetros apresentam-se como uma alternativa em potencial para otimizar o processo de configuração de sistemas de aprendizado em geral, incluindo sistemas de ICM-IM. Nesse sentido, a otimização hiperparamétrica (HPO, do inglês *Hyperparameter Optimization*) compreende uma área de estudo em constante ascensão (FEURER; HUTTER, 2019).

A fim de elucidar os tópicos teóricos que envolvem a estimativa de hiperparâmetros, as seções subsequentes apresentam uma visão geral acerca da otimização de hiperparâmetros em algoritmos de aprendizado de máquina. Os aspectos teóricos abordados a seguir são considerados fundamentais para a proposição de sistemas de ICM-IM com configuração automática de modelo.

4.1 Otimização hiperparamétrica (HPO)

Uma das etapas inerentes ao uso de ferramentas de aprendizado de máquina para resolução de problemas reais é a escolha de valores para os hiperparâmetros que compõem o modelo a ser treinado (HUTTER; LÜCKE; SCHMIDT-THIEME, 2015). A definição dos hiperparâmetros é tipicamente realizada antes do treinamento do modelo e os valores atribuídos têm relação direta com o desempenho final de predição (ALVARENGA JÚNIOR, 2018; SNOEK; LAROCHELLE; ADAMS, 2012). Além disso, é comum que sistemas recentes de aprendizado de máquina compreendam um espaço de hiperparâmetros com alta dimensionalidade o que implica uma grande variedade de possibilidades para o ajuste (HUTTER; HOOS; LEYTON-BROWN, 2011).

Nesse sentido, a otimização de hiperparâmetros (HPO) é um campo da computação em constante evolução que visa justamente o ajuste otimizado de parâmetros não ordinários em algoritmos de aprendizado de máquina (FEURER; HUTTER, 2019). Estratégias HPO têm sido de fundamental importância para a tarefa de estimar valores que maximizem o desempenho de um modelo em função de seus hiperparâmetros (SNOEK; LAROCHELLE; ADAMS, 2012).

De acordo com Feurer e Hutter (2019), a HPO possibilita reduzir o esforço humano necessário na configuração do modelo, melhorar o desempenho dos algoritmos adaptando-os à análise corrente bem como melhorar a reprodutibilidade dos estudos, dentre outras vantagens. A título de demonstração, o problema discutido em HPO pode ser sintetizado com base numa construção genérica.

Seja \mathcal{M} um modelo de aprendizado de máquina contendo N_h hiperparâmetros, em que \mathcal{H}_j denota o domínio do j -ésimo hiperparâmetro, h_j , com $j = 1, 2, \dots, N_h$. O espaço contendo todos os N_h domínios, denominado de *espaço de configuração*, é definido por $\mathcal{H} = \mathcal{H}_1 \times \mathcal{H}_2 \times \dots \times \mathcal{H}_{N_h}$, e cada instância do vetor de hiperparâmetros $\mathbf{h} \in \mathcal{H}$ representa uma possível configuração hiperparamétrica para o modelo, ou seja $\mathcal{M}_{\mathbf{h}}$.

Seja ainda $\mathcal{D}_{\mathcal{T}}$ e $\mathcal{D}_{\mathcal{V}}$ dois conjuntos de dados de treinamento e validação, respectivamente, ao considerar uma função custo $\bar{\mathcal{L}}$ para medir o erro do modelo $\mathcal{M}_{\mathbf{h}}$ gerado a partir do conjunto $\mathcal{D}_{\mathcal{T}}$ e validado usando $\mathcal{D}_{\mathcal{V}}$, o problema HPO pode ser definido como a busca pela configuração hiperparamétrica ótima \mathbf{h}^* na forma:

$$\mathbf{h}^* = \arg_{\mathbf{h} \in \mathcal{H}} \min \bar{\mathcal{L}}(g(\mathbf{h}), \mathcal{M}_{\mathbf{h}}, \mathcal{D}_{\mathcal{T}}, \mathcal{D}_{\mathcal{V}}), \quad (4.1)$$

onde $g(\mathbf{h})$ representa a função que mapeia os hiperparâmetros ao valor da função custo e não possui forma matemática fechada.

Dependendo do contexto de aplicação é desejável que a função $\bar{\mathcal{L}}(\cdot)$ represente o acerto do modelo e, portanto, deve ser maximizada e não minimizada. É o caso deste

trabalho, especificamente, em que o desempenho de classificação é usado como parâmetro para o ajuste do modelo de forma a buscar máxima performance do sistema ICM-IM, e para tanto $\mathbf{h}^* = \arg_{\mathbf{h} \in \mathcal{H}} \max \bar{\mathcal{L}}(\cdot)$.

Quando o ajuste dos hiperparâmetros estende uma técnica de classificação ou de regressão específica, compreendendo a otimização de uma cadeia de processamento, ou *pipeline*, com diferentes possíveis algoritmos de aprendizado, o processo de otimização de hiperparâmetros passa a ser reconhecido como *seleção de modelos* (HASTIE; TIBSHIRANI; FRIEDMAN, 2017), em que o desejável é a escolha do melhor entre os possíveis algoritmos na cadeia. Este também é o caso representado neste trabalho, a partir da escolha das técnicas de processamento para compor a arquitetura ICM-IM.

Diversos métodos HPO estão disponíveis na literatura, dentre os quais a busca em grade, a busca aleatória e a otimização *Bayesiana* (BO, do inglês *Bayesian Optimization*) são alguns dos mais populares (FEURER; HUTTER, 2019). Algoritmos baseados em pesquisa aleatória e em grade ou em pesquisa guiada são amplamente utilizados no contexto de HPO para encontrar soluções ótimas em espaços complexos, contudo, em geral requerem muito tempo para avaliação das múltiplas hipóteses disponíveis (HSU et al., 2003; BERGSTRA; BENGIO, 2012).

Recentemente, os modelos *Bayesianos* tem ganhado popularidade ao demonstrarem maior eficiência na tarefa de otimização hiperparamétrica em relação aos outros dois métodos de *benchmark* supracitados (BERGSTRA et al., 2011; JONES, 2001). Dada a eficiência dos modelos *Bayesianos* na otimização de hiperparâmetros (FEURER; HUTTER, 2019; ALVARENGA JÚNIOR, 2018; BROCHU; CORA; FREITAS, 2010), o método foi adotado como estratégia para automatizar e personalizar o ajuste de hiperparâmetros no contexto de sistemas de ICM-IM. As especificidades acerca da BO são abordadas nas seções a seguir.

4.2 Otimização *Bayesiana* (BO)

A BO é uma estratégia de otimização iterativa, guiada por um modelo probabilístico substituto, capaz de encontrar extremos globais de funções que, em geral, não são convexas, não possuem uma expressão de forma fechada e são computacionalmente caras de serem avaliadas (BROCHU; CORA; FREITAS, 2010). Modelos *Bayesianos* caracterizam-se por incorporar conhecimento prévio sobre a tarefa de otimização, o que os projeta como uma estratégia eficiente para estimativa de hiperparâmetros, especialmente em termos de número de iterações necessárias para a convergência (BASHASHATI; WARD; BASHASHATI, 2016b).

No contexto de HPO, o objetivo final da abordagem *Bayesiana* é otimizar a função

desconhecida $g(\mathbf{h})$ da Eq. 4.2, denominada função objetivo, cuja expressão sobre um dado conjunto \mathcal{H} é indefinida e portanto possui derivada desconhecida em relação a esse conjunto. Assim, no sentido de maximização global da função objetivo $g(\mathbf{h})$ especificamente, têm-se:

$$\mathbf{h}^* = \arg_{\mathbf{h} \in \mathcal{H}} \max g(\mathbf{h}), \quad (4.2)$$

O que permite extremar a função desconhecida $g(\mathbf{h})$ com relativas poucas avaliações, é a ideia por trás da otimização baseada em modelo sequencial (SMBO, do inglês *Sequential Model-Based Optimization*), a qual a BO é fundamentada (HUTTER; HOOS; LEYTON-BROWN, 2011).

A abordagem SMBO propõe a criação de um modelo de regressão substituto, também conhecido como Modelo de Superfície de Resposta, para representar o desempenho de $\mathcal{M}_{\mathbf{h}}$ por meio de avaliações prévias da função $g(\mathbf{h})$ diferentemente de muitas abordagens baseadas apenas na aplicação de um gradiente local (SNOEK; LAROCHELLE; ADAMS, 2012; BROCHU; CORA; FREITAS, 2010).

O processo de otimização SMBO e, conseqüentemente de BO, ocorre de forma iterativa e cíclica, alternando entre a obtenção de novos pares de observações $(\mathbf{h}, g(\mathbf{h}))$ e a própria otimização a partir das observações (ALVARENGA JÚNIOR, 2018). Conforme Brochu, Cora e Freitas (2010), a abordagem é chamada *Bayesiana* por incorporar a lógica do teorema de *Bayes* para descrever propriedades sobre a função objetivo, como suavidade, e direcionar a próxima iteração no espaço com base em um máximo ou mínimo esperado.

Em linhas gerais, o teorema de *Bayes* considera que a probabilidade condicional de um evento dadas as evidências (i.e. probabilidade *a posteriori*) é proporcional ao produto entre a probabilidade das evidências dada a hipótese e a probabilidade *à priori* do evento. Nesse sentido, a abordagem BO típica considera que a amostragem das observações de $g(\mathbf{h})$ possui distribuição normal e, com isso, uma distribuição *a posteriori* é mantida conforme novas observações para novos valores de hiperparâmetros são avaliadas (JONES, 2001).

Ao assumir um processo iterativo em que na iteração τ , $\tau - 1$ avaliações da função objetivo $g(\mathbf{h})$ foram realizadas, produzindo a sequencia de observações

$$\mathcal{O}_{1:\tau-1} = \{(\mathbf{h}_1, g(\mathbf{h}_1)), (\mathbf{h}_2, g(\mathbf{h}_2)), \dots, (\mathbf{h}_{\tau-1}, g(\mathbf{h}_{\tau-1}))\}.$$

Para otimizar a função objetivo a abordagem *Bayesiana* cria uma distribuição *a posteriori* sobre $g(\mathbf{h})$ dadas as observações *à priori*, o que pode ser expressado como:

$$\mathbf{P}(g(\mathbf{h}) | \mathcal{O}_{1:\tau-1}) \propto \mathbf{P}(\mathcal{O}_{1:\tau-1} | g(\mathbf{h})) \mathbf{P}(g(\mathbf{h})), \quad (4.3)$$

em que $\mathbf{P}(g(\mathbf{h}) | \mathcal{O}_{1:\tau-1})$ é a distribuição *a posteriori*, $\mathbf{P}(\mathcal{O}_{1:\tau-1} | g(\mathbf{h}))$ é a função de verossimilhança e $\mathbf{P}(g(\mathbf{h}))$ expressa a esperança sobre o espaço de possibilidades para $g(\mathbf{h})$.

Essencialmente, a cada iteração, o algoritmo BO projeta uma distribuição condicional para $g(\mathbf{h})$ dadas as observações anteriores e o utiliza para selecionar um novo candidato, \mathbf{h}_τ , para o processo de otimização. Sendo assim, a BO depende basicamente de dois componentes principais: o primeiro corresponde à abordagem utilizada na construção da distribuição *a posteriori* que dispõe a Eq. 4.3; o segundo é a definição da função auxiliar, cuja forma é conhecida, usada na determinação da próxima instância \mathbf{h} candidata, a qual denomina-se função de aquisição (SNOEK; LAROCHELLE; ADAMS, 2012; FEURER; HUTTER, 2019).

4.2.1 Modelo probabilístico substituto

Para modelar a distribuição à posteriori $\mathbf{P}(g(\mathbf{h})|\mathcal{O}_{1:\tau-1})$ e expressar as hipóteses para $g(\mathbf{h})$, uma variedade de métodos têm sido propostos (BERGSTRA; YAMINS; COX, 2013b). Processos *Gaussianos* (GP, da sigla em inglês para *Gaussian Processes*), por exemplo, é um dos métodos mais populares para representar o modelo probabilístico substituto em BO (RASMUSSEN; WILLIAMS, 2006; SNOEK; LAROCHELLE; ADAMS, 2012).

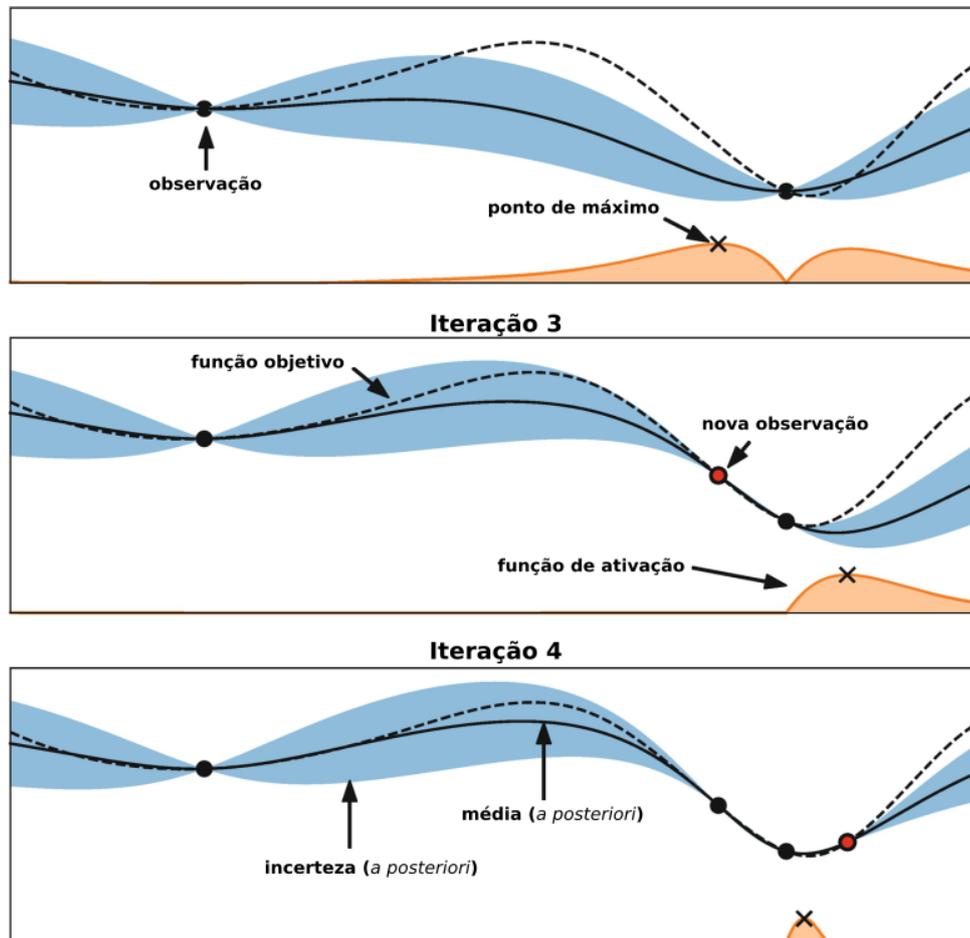
Uma breve definição de GP o descreve como uma generalização da distribuição Gaussiana multivariada em variáveis aleatórias de um processo estocástico, para o caso em que o comportamento de uma função é, da mesma forma, totalmente descrito por uma função de média $\mu(\mathbf{h})$ e uma função de covariância (ou kernel) $\bar{\kappa}(\mathbf{h}, \mathbf{h}^T)$ (BROCHU; CORA; FREITAS, 2010; SNOEK; LAROCHELLE; ADAMS, 2012).

Comumente, define-se a constante 0 para a média da distribuição Gaussiana *à priori* (i.e. das observações) e, neste caso, a função kernel é o único componente que define o modelo GP na prática (BASHASHATI; WARD; BASHASHATI, 2016a). Diferentes funções de kernel podem ser adotadas em GP para controlar a suavidade da função a ser otimizada, conforme listam Rasmussen e Williams (2006) e Shahriari et al. (2016).

Em síntese, um GP modela a incerteza sobre as predições posteriores da função objetivo $g(\mathbf{h})$ com base nas observações anteriores \mathcal{O} . Para ilustrar, a Figura 27 mostra uma simulação da abordagem *Bayesiana* frente à um problema de otimização de dimensão única, ou seja $N_h = 1$, usando o modelo GP.

No caso de GP, a função de aquisição considera as propriedades de média e variância das previsões no espaço para modelar a utilidade de cada hipótese, indicando à função objetivo um novo ponto candidato em potencial através do ponto de máximo da função de aquisição. GP foi abordado no contexto em diversos estudos para otimização de funções desconhecidas, por exemplo Nguyen et al. (2017), Bergstra et al. (2011), Shahriari et al. (2016), Swersky, Snoek e Adams (2014) e Bashashati, Ward e Bashashati (2016b), entre

Figura 27. Ciclo BO usando Processos *Gaussianos* em um problema \mathbb{R}^1 . A cada iteração a função de aquisição é maximizada para determinar o novo ponto candidato a ser avaliado pela função objetivo.



Fonte: Adaptada de Feurer e Hutter (2019)

outros.

Dentre as motivações mais relatadas para o uso de GP estão sua flexibilidade associada ao controle da suavização da função modelada, sua natural conveniência pela relação implícita com o contexto de BO e sua simplicidade ao depender exclusivamente da função kernel (SNOEK; LAROCHELLE; ADAMS, 2012). Por outro lado, conforme expõe Feurer e Hutter (2019) algumas desvantagens podem ser associadas ao uso de GP, em especial a baixa escalabilidade para espaços de configuração de altas dimensões.

Diante disso, outras abordagens de modelagem aplicada à SMBO e BO têm sido propostas, tais como: configuração baseada em modelo sequencial usando Florestas Aleatórias (SMAC, do inglês *Sequential Model-Based Algorithm Configuration*) (HUTTER; HOOS; LEYTON-BROWN, 2011), Otimização Global usando Redes Neurais Profundas (DGNO, do inglês *Deep Networks for Global Optimization*) (SNOEK et al., 2015) e Estimador de Parzen com Estrutura em Árvore (TPE, do inglês *Tree Parzen Estimators*) (BERGSTRÄ

et al., 2011), sendo este último adotado neste trabalho. Uma análise comparativa entre os principais modelos probabilísticos citados, a partir de execuções para diversos problemas práticos HPO, pode ser verificada em Eggenesperger et al. (2013).

4.2.2 Função de aquisição

Além do modelo substituto probabilístico, na Figura 27, a importância da função de aquisição na abordagem *Bayesiana* é evidenciada. Conforme mencionado anteriormente, o papel da função de aquisição é direcionar o processo de busca pelas próximas instâncias \mathbf{h} candidatas a serem avaliadas, $g(\mathbf{h})$.

Conforme (BROCHU; CORA; FREITAS, 2010), a função de ativação avalia o desempenho esperado em $g(\mathbf{h})$ para possíveis pontos no espaço \mathcal{H} e promove candidatos "úteis" à função objetivo. O mapeamento da função objetivo ao ponto ótimo é guiado pela função de ativação, ao explorar a distribuição posterior em busca de instâncias com menor incerteza (i.e variância), maior desempenho esperado, ou ambos.

Em suma, assume-se no processo que pontos de máximo ou de mínimo na função de aquisição correspondem à potenciais valores de máximo ou de mínimo da função objetivo, e o máximo local da função de aquisição é o novo candidato para função objetivo.

Logo, extremar a função de aquisição em cada uma das N_h iterações é, de fato, a tarefa prática na BO, uma vez que a definição das novas instâncias candidatas no espaço de configuração e a atualização da distribuição *a posteriori* conforme novas observações anteriores estão disponíveis, reflete na otimização da função objetivo $g(\mathbf{h})$. Desse modo, o problema de otimização hiperparamétrica pelo método *Bayesiano* pode ser expresso na forma de Eq. 4.1 onde $\bar{\mathcal{L}}(\cdot)$ equivale à função de aquisição genérica.

Um ponto a ser destacado, consiste no fato de que encontrar o máximo ou o mínimo da função de aquisição não é difícil, porém essa função ainda não é convexa (BASHASHATI; WARD; BASHASHATI, 2016b). Isso sugere que, se por um lado, o uso do modelo sequencial da BO simplifica o problema de otimização da função objetivo a partir das instâncias de hiperparâmetros observadas, a contraparte é que não é possível garantir soluções globais (BROCHU; CORA; FREITAS, 2010).

Isto posto, a definição do tipo de função de aquisição a ser otimizada por um dos modelos substitutos é, em geral, arbitrária e deve ser feita previamente à busca pelo ponto ótimo (ALVARENGA JÚNIOR, 2018). Atualmente, variadas vertentes de funções de aquisição têm sido usadas em BO, sendo três as escolhas típicas: Probabilidade de Melhoria (PI, do inglês *Probability of Improvement*), Esperança de Melhoria (EI, do inglês *Expected Improvement*) e Limite de Confiança Superior (UCB, do inglês *Upper Confidence Bound*) (JONES, 2001; BERGSTRA et al., 2011). Snoek, Larochelle e Adams (2012) descreve

matematicamente os três tipos de função de aquisição típicas na perspectiva de GP.

4.2.3 TPE para otimização de EI

Neste trabalho, a função de ativação baseada na esperança de melhoria (EI) foi adotada. A EI maximiza a melhoria esperada de um determinado ponto ótimo atual para projetar o próximo ponto candidato com base em duas distribuições: uma função de probabilidade normal e uma função acumulada normal (ALVARENGA JÚNIOR, 2018). A eficiência na otimização do critério de EI em relação ao número de iterações necessárias e o conseqüente menor custo para se definir o próximo candidato, justifica sua popularidade no contexto de HPO (BASHASHATI; WARD; BASHASHATI, 2016a; BERGSTRA et al., 2011; SNOEK; LAROCHELLE; ADAMS, 2012; HUTTER; HOOS; LEYTON-BROWN, 2011).

Em contraponto à abordagem GP que modela a distribuição $\mathbf{P}(g(\mathbf{h}) | \mathbf{h})$ diretamente, o método TPE modela $\mathbf{P}(\mathbf{h} | g(\mathbf{h}))$ e $\mathbf{P}(g(\mathbf{h}))$ fundamentado na característica do espaço de configuração \mathcal{H} que é descrito como um processo hierárquico estruturado, onde muitos dos N_h hiperparâmetros expressam condicionalidade entre si. O TPE atua nesse processo hierárquico de forma a substituir as distribuições *à priori* por densidades não paramétricas (BERGSTRA et al., 2011).

Duas funções de densidades são estimadas de uma fração do conjunto de instâncias candidatas pareadas com avaliações da função objetivo. Essas densidade definem a verossimilhança:

$$\mathbf{P}(\mathbf{h} | g(\mathbf{h})) = \begin{cases} \mathcal{I}(\mathbf{h}), & \text{se } g(\mathbf{h}) < \alpha \\ \mathcal{S}(\mathbf{h}), & \text{se } g(\mathbf{h}) \geq \alpha \end{cases}, \quad (4.4)$$

onde α é o limiar (geralmente um percentil definido em 15%) que separa as observações para as funções de densidade com base no valor da função objetivo, $\mathcal{I}(\mathbf{h})$ é a função de densidade modelada com base nas observações \mathbf{h}_τ em que a saída correspondente $g(\mathbf{h}_\tau) < \alpha$ e $\mathcal{S}(\mathbf{h})$ é a função de densidade formada pelas observações restantes.

As densidades segmentam as observações conforme a utilidade (i.e. predições boas e ruins) e são modeladas conforme o Estimador *Parzen* (BERGSTRA et al., 2011). A proporção $\frac{\mathcal{I}(\mathbf{h})}{\mathcal{S}(\mathbf{h})}$ corresponde à otimização da função de ativação baseada no critério de EI e é usada para propor novas configurações de hiperparâmetro a partir do candidato com maior EI na proporção. A formulação matemática da otimização da função EI na abordagem TPE é detalhada pelos autores em Bergstra et al. (2011).

5 METODOLOGIA

Este capítulo descreve os procedimentos metodológicos realizados no decorrer da pesquisa de modo a fornecer uma visão geral acerca dos materiais e métodos adotados para o seu desenvolvimento, com ênfase na apresentação da arquitetura e dos componentes do sistema de ICM-IM proposto, na descrição dos experimentos de teste e validação realizados bem como na identificação das principais ferramentas utilizadas.

Conforme problematizado ainda no Capítulo 1, este estudo parte da hipótese de que a adoção de estratégias de otimização para configuração automática de hiperparâmetros conforme os padrões particulares do usuário é capaz de potencializar o desempenho de classificação e consequentemente a usabilidade de sistemas ICM-IM. A ideia é individualizar e automatizar o ajuste de hiperparâmetros almejando descomplicar a tarefa de configuração e calibração dos algoritmos de aprendizagem.

Em linhas gerais, a pesquisa é conduzida tendo em vista a validação desta hipótese por meio da proposição, desenvolvimento e teste de uma plataforma ICM-IM que contempla a possibilidade de configuração automática de hiperparâmetros de modo a se obter modelos de classificação adequados às características cognitivas de cada usuário.

Neste contexto, os objetos traçados para o estudo buscam verificar os efeitos da configuração automática de hiperparâmetros na capacidade do sistema em discriminar as intenções motoras de diferentes indivíduos e traduzir os padrões reconhecidos em comandos confiáveis. Assim, de maneira a perseguir esses objetivos, a pesquisa foi conduzida com base em etapas sequenciais conforme a Figura 28.

Figura 28. Processo metodológico



Fonte: Autoria própria

No processo sequencial apresentado na Figura 28, o estudo bibliográfico compreende a primeira etapa realizada e levou em consideração as principais fontes de pesquisa sobre as questões teóricas e práticas que envolvem o desenvolvimento de sistemas de ICM-IM sintetizadas ao longo dos Capítulos 2, 3 e 4. A revisão da literatura permitiu a percepção do estado da arte bem como o reconhecimento das principais técnicas e abordagens de coleta, processamento e controle de dispositivos aplicado ao projeto de ICM-IM bem como as ferramentas comumente adotadas no desenvolvimento desses sistemas.

Nas seções subsequentes, são detalhadas as etapas que sucederam o estudo teórico, as quais compreendem, principalmente, o desenvolvimento do sistema de ICM-IM proposto propriamente dito bem como os procedimentos experimentais de teste, validação e análise de resultados. Os recursos e estratégias utilizadas na implementação e experimentação do sistema também são destacados.

5.1 Experimentação preliminar

Como extensão da revisão teórica e a fim de se obter uma impressão prática dos principais algoritmos e estratégias de processamento encontradas, foram realizados experimentos preliminares a partir da simulação de cenários pontuais e específicos para análise comparativa entre estratégias de processamento usando dados públicos de EEG.

Os experimentos incluem: (i) um comparativo entre métodos de classificação usando uma cadeia de processamento clássica de banda única; (ii) análise de desempenho de classificação em função da janela temporal usada na extração de épocas de EEG; (iii) análise comparativa de custo-desempenho entre o uso da DFT e de métodos digitais convencionais na filtragem dos sinais em ICM-IM de banda única e de sub-bandas; (iv) avaliação de desempenho da configuração automática de hiperparâmetros em sistemas ICM-IM de sub-bandas considerando múltiplos problemas de classificação binária a partir de quatro classes de MI distintas.

Alguns dos estudos preliminares, (i) e (iii), foram incorporados à plataforma no sentido de que seus resultados parametrizaram a escolha das técnicas adotadas na cadeia de processamento ICM-IM, enquanto que os demais estudos, (ii) e (iv), foram objetos de publicação em conferências qualificadas nas áreas de processamento de sinais e aprendizado de máquina conforme disposto no Capítulo 9.

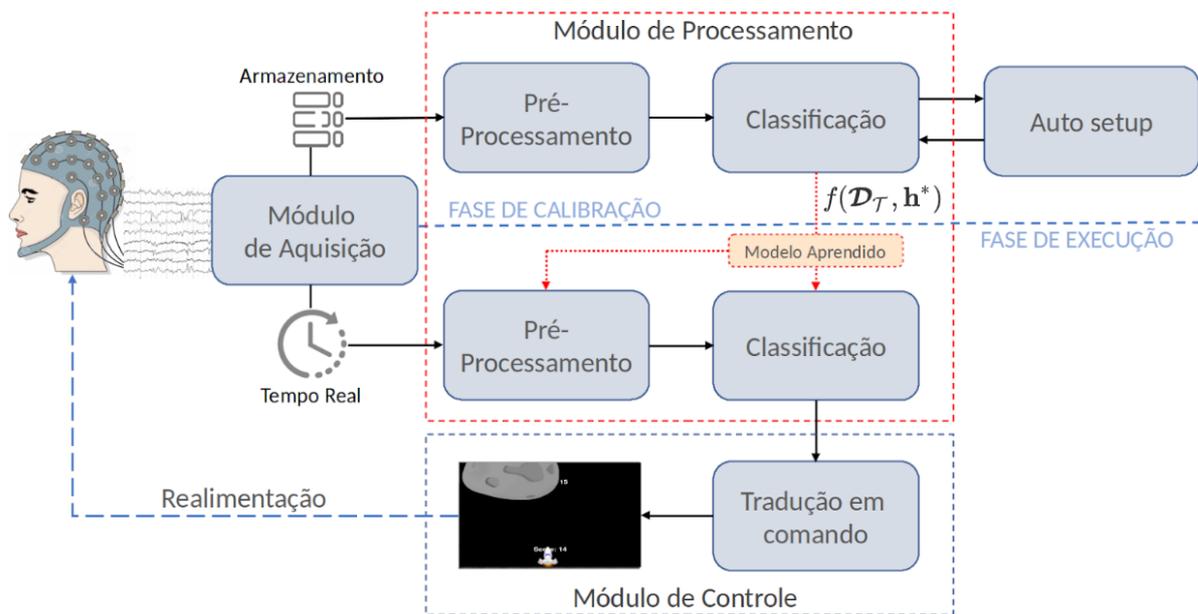
Ao relacionar os resultados da experimentação prática com o embasamento teórico da revisão bibliográfica foi possível identificar as ferramentas computacionais que implementam as técnicas de processamento de sinais e aprendizado de máquina apropriadas ao escopo deste trabalho e utilizá-las no projeto e desenvolvimento da arquitetura ICM-IM com seleção automática de modelo.

5.2 Desenvolvimento do sistema

Tendo como plano de fundo os conceitos discutidos nos capítulos anteriores, este trabalho propõe o desenvolvimento de uma plataforma ICM-IM completa e de código aberto cuja principal característica consiste na calibração de modelos de classificação decorrente da configuração automática de hiperparâmetros.

O projeto de software foi nomeado de AutoBCI e contempla todas as etapas da arquitetura de ICM-IM discutida ao longo do Capítulo 3 para fornecer aos usuários o arcabouço necessário para uma experimentação ICM-IM completa, ao incorporar em um só ambiente a interface gráfica e as ferramentas necessárias para aquisição, processamento e controle virtual a partir de sinais de EEG. Uma visão geral da arquitetura do AutoBCI é apresentada na Figura 29.

Figura 29. Visão geral do AutoBCI incluindo o gerenciamento do fluxo de amostras para utilização em duas fases sequenciais: calibração e execução. O modelo ajustado na calibração com ajuda do *auto setup* é aplicado na classificação de padrões de IM em sinais coletados em tempo real objetivando a tradução em comandos para controle de uma aplicação virtual.



Fonte: Autoria própria

Nota-se que o sistema incorpora todo o ciclo fechado de uma ICM-IM com o gerenciamento do fluxo de amostras de EEG provenientes do amplificador, o aprimoramento e processamento dos sinais e, finalmente, a tradução da saída do classificador em comandos úteis para o controle de uma aplicação virtual cuja operação em tempo real retorna ao usuário em forma de *feedback* visual, ajudando-o na modulação da atividade cognitiva no próximo ciclo.

As duas fases de operação típicas de uma ICM-IM também são representadas na Figura 29, com a nomenclatura da fase de treinamento sendo convenientemente alterada para fase de calibração para evidenciar a proposta do sistema. O modelo de classificação é ajustado em função do conjunto de épocas de treinamento, denotado por $\mathcal{D}_{\mathcal{T}}$, e da instância do conjunto de hiperparâmetros \mathbf{h} que por sua vez pode ser definida manualmente pelo experimentador ou estimada pelo próprio sistema através do método de configuração

automática, denominado *auto setup*.

O *auto setup* representa o principal diferencial do AutoBCI em relação à outros projetos de ICM-IM típicos e foi projetado para automatizar o processo de configuração e de sintonia dos hiperparâmetros no sistema de modo à calibrá-lo de maneira adequada aos padrões particulares do usuário corrente.

Vale destacar que, embora o esquema na Figura 29 não explicita a etapa de extração de características, esta também é compreendida na cadeia de processamento do AutoBCI. A decisão por agrupar esta etapa ao pré-processamento visa uma visualização mais clara dos componentes e do fluxo de dados. Além disso, é importante ressaltar que a versão atual do sistema foi projetada considerando exclusivamente o reconhecimento de padrões referentes às imagéticas motoras das mãos esquerda (ME) e direita (MD), com classificação binária entre essas duas classes de IM.

Na Figura 29 também é possível observar a aplicação virtual incorporada ao AutoBCI. Tal aplicação consiste em um jogo, denominado ICM Space Game, o qual é um produto de outro trabalho de mestrado em desenvolvimento por um dos membros do grupo de pesquisa ao qual este estudo está inserido. O jogo em questão possibilita que o usuário controle um cursor (nave), movimentando-o no eixo horizontal utilizando somente IM das mãos esquerda e direita.

Basicamente, o objetivo do usuário ao operar o cursor no ICM Space Game, é desviá-lo de um obstáculo (asteroide), que surge na tela enquanto o próprio cursor desloca-se no eixo vertical em velocidade constante. Conforme será apresentado no Capítulo 6, os parâmetros de controle como velocidade vertical, número de partidas e deslocamento horizontal por comando, por exemplo, são personalizáveis no AutoBCI.

A natureza sistêmica da plataforma proposta faz com que um módulo seja requisito para a implementação do módulo subsequente, o que justifica o desenvolvimento sequencial e iterativo de cada componente na Figura 29, respeitando o próprio ciclo genérico ICM-IM. De todo modo, todas as funcionalidades do sistema podem ser agrupadas em três módulos principais que se relacionam para formar a arquitetura do AutoBCI, tais quais: módulo de aquisição, módulo de processamento e módulo de controle.

As etapas do projeto exigiram a adoção de ferramentas de hardware e software específicas, a fim de possibilitar a coleta de dados, o processamento e o reconhecimento de padrões em sinais de EEG, o disparo de comandos para a aplicação virtual, o teste do sistema e a análise estatística de resultados, todos usando tecnologias de código aberto. Ademais, para cumprir os objetivos interpostos e compor uma ferramenta de uso descomplicado, o AutoBCI integra uma série de abordagens e técnicas de processamento de sinais, aprendizado de máquina, estatística e otimização que serão evidenciadas no

decorrer deste capítulo.

Como forma de oferecer uma melhor compreensão do processo metodológico, os detalhes acerca da operacionalização e das funcionalidades disponíveis em cada módulo do AutoBCI serão tratados à parte no Capítulo 6. O foco nas seções subsequentes é destinado à descrição do processo de desenvolvimento propriamente dito bem como à apresentação das estratégias e ferramentas que materializaram o projeto.

5.2.1 Ferramentas e ambiente de implementação

A escolha das ferramentas de desenvolvimento esteve apoiada na revisão de literatura que, juntamente com a reprodução de resultados de trabalhos correlatos, possibilitou a identificação dos requisitos e dos recursos computacionais de código aberto com suporte às diversas necessidades inerentes ao escopo do projeto, tais quais:

- integração com dispositivo de coleta de sinais de EEG
- implementação de algoritmos de aprendizado de máquina e processamento de sinais
- análise e experimentação estatística
- projeto e codificação de interface gráfica do usuário

Com base nesses requisitos, a plataforma *Anaconda*¹, uma distribuição *open-source* da linguagem de programação *Python*, idealizada especialmente para uso em aplicações relacionadas à análise científica de dados e ao aprendizado de máquina (ML, do inglês *Machine Learning*), é adotada como plano de fundo para o desenvolvimento do sistema. A plataforma *Anaconda* disponibiliza bibliotecas científicas específicas com métodos e modelos pré-definidos os quais foram fundamentais na construção das rotinas de processamento de sinais e de ML.

Bibliotecas como *numpy*, *pandas*, *keras*, *scipy*, *scikit-learn*, *matplotlib*, *mne* e *hyperopt*, dentre outras, são amplamente utilizadas neste trabalho para implementação dos múltiplos algoritmos que compõem toda a cadeia de processamento do AutoBCI. Ademais, a fim de simplificar a construção da interface gráfica do usuário (GUI, do inglês *Graphical User Interface*), tanto a biblioteca gráfica *Kivy* quanto a linguagem de projeto associada *Kv language*² foram adotadas.

O sistema operacional Linux Ubuntu versão 19.04 foi utilizado para o desenvolvimento da plataforma com todos os seus recursos, dada a comprovada eficiência de ambientes GNU Linux no gerenciamento dos recursos computacionais considerados cruciais

¹ <https://www.anaconda.com/>

² <https://kivy.org/doc/stable/guide/lang.html>

para a aplicação de algoritmos de aprendizado processamento no processamento em tempo real de fluxos de dados.

As especificações físicas relevantes do computador portátil utilizado tanto no desenvolvimento do projeto quanto nos testes de custo e desempenho incluem: processador Intel Core i7 7700HQ 7^a geração 2.8 GHz com 8 núcleos; memória RAM de 16GB DDR4 2133 MHz; drive de armazenamento primário SSD com 256GB; disco rígido secundário de 1TB; placa de vídeo NVIDIA Geforce GTX 1050 Ti 4GB GDDR5 e; tela de 15,6 polegadas Full HD com antirreflexo.

Além da codificação de novas rotinas, o projeto reproduz resultados e incorpora rotinas de trabalhos correlatos verificados durante a revisão da literatura. Duarte (2017), em especial, desenvolveu uma plataforma ICM-IM de baixo custo para controle de *drones* virtuais com base na dessincronização do ritmo μ_r . Dentre as contribuições do estudo, está a disponibilização de um protótipo ICM em ambiente público³, o qual é utilizado como ponto de partida para o desenvolvimento do AutoBCI.

A incorporação de estratégias devidamente validadas e disponíveis na literatura tem como objetivo reproduzir e adaptar as melhores práticas adotadas em trabalhos anteriores. Assim, do ponto de vista de codificação, os esforços são concentrados em rotinas que exprimem os pontos cruciais e particulares à ferramenta proposta.

5.2.2 Sistema de aquisição de dados

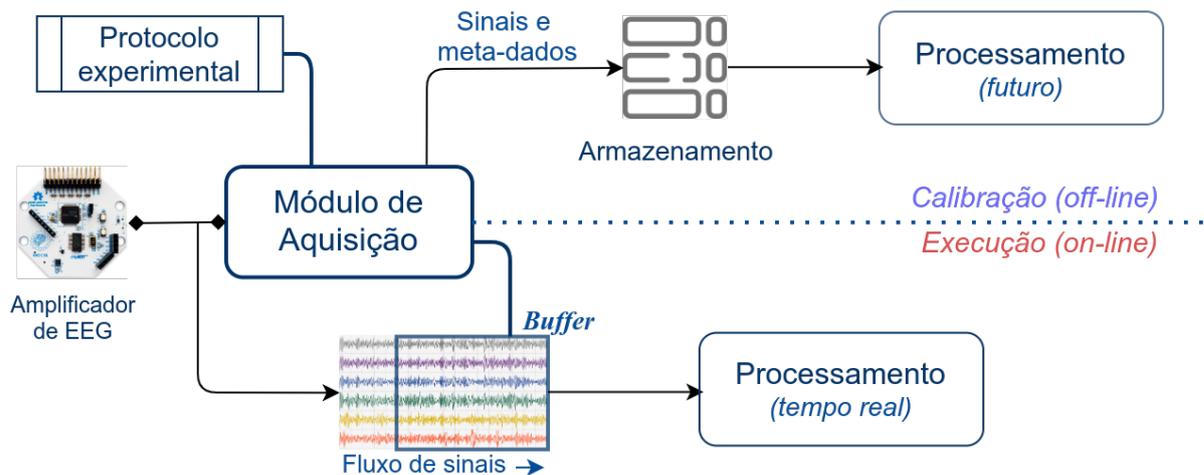
A coleta dos sinais de EEG é um passo fundamental, porém não trivial, na arquitetura de um sistema ICM-IM, haja vista que o esforço empregado para uma aquisição de sinais com menor incidência de ruídos é determinante para o projeto de ICM-IM com desempenho e usabilidade satisfatórios (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017). Para tanto, uma série de componentes devem ser considerados pelo ambiente de coleta, os quais, em grande parte, estão associados a duas funções principais, tais quais: (I) gerenciamento e destinação do fluxo de sinais obtidos de um amplificador de EEG e (II) gerenciamento e execução do protocolo experimental de coleta.

No escopo do AutoBCI, o módulo de aquisição é responsável por gerenciar a entrada de dados tanto para a fase de calibração *off-line* do sistema quanto para a fase de execução em tempo real conforme ilustra o esquema da Figura 30.

O diagrama implementa o que havia sido discutido na seção 3.2.1 sobre a coleta na fase de calibração coincidir com a execução de múltiplos ensaios experimentais cada qual com uma sequência de eventos bem definida. Enquanto instruções visuais são apresentadas ao usuário, o fluxo de sinais de EEG fornecido pelo amplificador a uma taxa de amostragem

³ <https://github.com/rafaelmendes/bcftp>

Figura 30. Diagrama esquemático do módulo de aquisição ao atuar no gerenciamento do fluxo de sinais e do protocolo experimental de coleta tanto na fase de calibração quanto na fase de execução



Fonte: Autoria própria

F_s é armazenado juntamente com as marcações que indicam o instante e os rótulos de cada evento realizado.

Em contraponto, o papel do protocolo experimental não se aplica à fase de execução *on-line* o que torna a recepção do fluxo de dados pelo sistema aquisição substancialmente distinta. Neste caso, o fluxo de sinais é enviado à um repositório temporário com capacidade finita de armazenamento, denominado *buffer*. As amostras correntes no *buffer* são enviadas periodicamente ao módulo de processamento para classificação.

Como sugere a Figura 30, a aquisição representa o primeiro estágio em ambas as fases de operação e depende, especialmente, de um conjunto de recursos de hardware que possibilite mensurar a variação da atividade elétrica cerebral em tempo real.

5.2.3 Hardware de aquisição integrado

Dentre os recursos necessários para coleta de sinais de EEG, um item imprescindível é o amplificador usado na captura dos biopotenciais elétricos em cada canal da matriz de eletrodos posicionada no escalpo do indivíduo. O módulo de aquisição do sistema proposto, integra um amplificador da família *OpenBCI* como ferramenta base para coleta desses sinais.

A *OpenBCI* é uma iniciativa privada especializada no projeto de biossensores de código aberto e baixo custo relativo. A missão da empresa é popularizar a pesquisa na área de neurociência e ICM (CLERC; BOUGRAIN; LOTTE, 2016b). Duas placas amplificadoras são divulgadas pela empresa que se diferenciam basicamente pela capacidade de conexões com eletrodos, tais quais: *Ganglion* e *Cyton*.

Por comportar mais canais de EEG em relação à sua contraparte e devido à disponibilidade de um exemplar desta versão no laboratório utilizado para desenvolvimento desta pesquisa, a placa *Cyton*⁴ foi escolhida como instrumento de coleta para integrar o AutoBCI. Suas especificações principais consistem em uma interface analógica ADS1299 fabricada pela *Texas Instruments*, um microcontrolador da família PIC de 32 bits e uma alimentação por baterias de 3 – 6 Volts.

Por padrão, a placa *Cyton* amostra os sinais de EEG a uma taxa $F_s = 250\text{Hz}$ ao usar o máximo de 8 canais disponíveis. Esse limite pode ser expandido para 16 canais com o acoplamento de um módulo adicional (*Daisy*), e nesse caso a taxa de amostragem passa a ser de $F_s = 125\text{Hz}$.

O *kit* que acompanha a placa *Cyton* inclui um *dongle* USB que se comunica com a placa via *Bluetooth* e é usado para conectá-la ao computador. Além disso, um capacitor rígido, intitulado *Ultracortex*, também foi projetado pela empresa para conexão de eletrodos à seco cujos nodos são baseados no sistema de posicionamento 10-20. O *Ultracortex* é fornecido em vários tamanhos, possui um suporte para posicionamento da placa *Cyton* e seu projeto está disponível publicamente para impressão 3D⁵.

Para ilustrar, os instrumentos eletrônicos de coleta de EEG integrados ao AutoBCI são apresentados na Figura 31. Os eletrodos são conectados aos pinos na placa *Cyton* e no módulo *Daisy* para o modo expandido, Figuras 31-a e 31-c respectivamente. Podem ser conectados sensores molhados (e.g. copos de ouro) ou à seco, neste último caso utilizando o *Ultracortex* da Figura 31-e. O *dongle* para comunicação serial com a placa principal e conexão USB com o computador é apresentado na Figura 31-d.

Conforme analisa Duarte (2017), a OpenBCI mantém documentação completa de todos os equipamentos fornecidos e promove o compartilhamento de conhecimento por meio de uma ampla comunidade de usuários mantida pela empresa, o que credencia suas tecnologias a estarem cada vez mais presentes em pesquisas relacionadas à sistemas ICM, incluindo este trabalho.

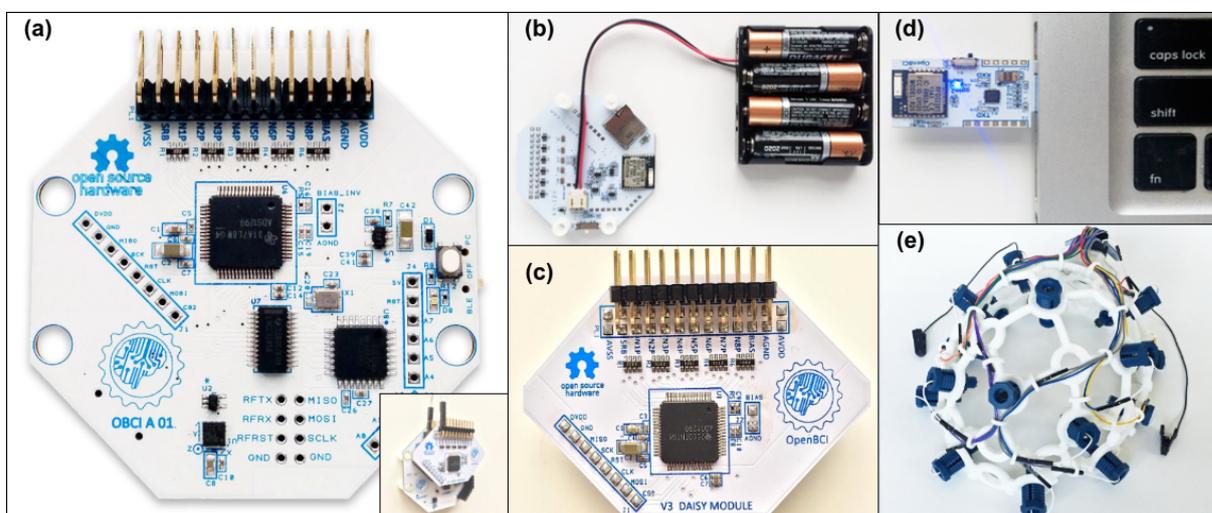
Para integração com a placa *Cyton*, uma versão do framework *pyOpenBCI*⁶, disponibilizada de forma gratuita pela fabricante, foi adaptada e incorporada ao módulo de aquisição da plataforma AutoBCI. A gravação de sinais de EEG em tempo real a partir da placa *Cyton* no sistema ocorre apoiada por um modelo do protocolo experimental *Graz*, proposto por Pfurtscheller e Silva (1999), bastante difundido em pesquisas ICM-IM e já descrito na seção 3.1.2.

⁴ <https://docs.openbci.com/Hardware/02-Cyton>

⁵ <https://docs.openbci.com/docs/04AddOns/01-Headwear/MarkIV>

⁶ <https://github.com/openbci-archive/pyOpenBCI>

Figura 31. Equipamentos eletrônicos para coleta de EEG integrados ao módulo de aquisição do AutoBCI: (a) visão ampliada da placa *Cyton*; (b) placa *Cyton* em dimensão padrão alimentada por um módulo de baterias; (c) módulo adicional *Daisy* em dimensão ampliada; (d) *dongle* USB para comunicação *bluetooth* e; (e) capacete *Ultracortex modelo Mark IV* com eletrodos a seco para posicionamento no escalpo



Fonte: Montado a partir de <https://docs.openbci.com> (2020)

5.2.4 Modo de aquisição simulada

Além da aquisição em tempo real usando a placa *Cyton*, a plataforma AutoBCI dispõe de um mecanismo capaz de emular a tarefa realizada pelo amplificador e simular artificialmente a entrada de sinais de EEG a partir da reprodução de dados gravados previamente. Tal opção possibilita a validação *off-line* dos algoritmos de ML e do modelo de classificação bem como habilita o controle *on-line* sem o uso do amplificador.

Como o processo de coleta real é normalmente dispendioso e desgastante especialmente para o usuário, exigindo uma estrutura de laboratório específica e tempo para planejamento e execução, a aquisição simulada torna-se uma alternativa interessante para dar praticidade à avaliação das funcionalidades do sistema, especialmente dos algoritmos na cadeia de processamento.

A ideia de utilizar uma aquisição simulada para simplificar a validação do sistema foi proposta originalmente por Duarte (2017), e sua essência foi mantida no escopo do AutoBCI. No entanto, ajustes significativos foram realizados e novas rotinas foram implementadas com o objetivo de adequar esta opção aos propósitos do AutoBCI tornando-a mais abrangente e automatizada.

A abordagem mais abrangente para o modo de aquisição simulada, habilita o teste do AutoBCI não somente com base em uma simulação compatível com o amplificador *OpenBCI*, como também inclui o suporte à conjuntos de sinais originados por outros sistemas de aquisição inclusive conjuntos de dados públicos amplamente empregados em pesquisas

ICM-IM (TANGERMANN et al., 2012; ANG et al., 2012a). Ademais, ao possibilitar o uso dessas bases públicas de dados de EEG na avaliação *off-line* do desempenho do sistema, esta opção contribui para a reprodutibilidade dos resultados e comparação com outros trabalhos.

Nesse sentido, os protocolos experimentais utilizados em três conjuntos de dados públicos de EEG foram considerados na implementação do modo de aquisição simulada do AutoBCI, de tal maneira que, já em sua primeira versão, o sistema é capaz de interpretar os dados e meta-dados de EEG coletados de um grupo de 72 sujeitos e reproduzi-los conforme a aquisição real. Como os sinais detêm propriedades específicas de aquisição e variabilidade significativa entre si o objetivo é adicionar confiabilidade e robustez ao processo de validação dos algoritmos.

Três critérios nortearam a escolha dos conjuntos de dados considerados, tais quais: (I) similaridade com a proposta do sistema, observada com a presença de ensaios associados à imagética motora das mãos e disposição dos canais de EEG compatível com o amplificador *OpenBCI*; (II) documentação disponível acerca do protocolo de coleta utilizado, possibilitando o desenvolvimento de um interpretador em conformidade com os meta-dados; (III) confiabilidade, mensurada através da percepção de uso frequente em pesquisas relacionadas à ICM-IM.

Apesar dos pontos em comum, que atendem aos propósitos da plataforma AutoBCI, os conjuntos de dados diferem em muitos aspectos, especialmente quanto ao número de ensaios realizados, número de participantes e número de canais de EEG utilizados. Diante disso, as sub-seções a seguir são dedicadas à fornecer uma breve descrição das particularidade dos três conjuntos de dados públicos considerados.

5.2.4.1 Base de dados *BCI Competition IV-2a* (2A)

O conjunto de dados 2A da Competição IV de BCI (BRUNNER et al., 2008), inclui sinais de EEG de 9 sujeitos que realizaram quatro tarefas motoras distintas: mão esquerda, mão direita, pés e língua. Os sinais foram amostrados a uma taxa $F_s = 250\text{Hz}$ e gravados de 25 canais no total, sendo $P = 22$ canais de EEG e 3 canais de EOG. O mastoide esquerdo foi adotado como referência e o direito como potencial de terra (GND).

Com os sujeitos sentados em uma cadeira confortável em frente à tela de um computador, o experimento de coleta se deu baseado no protocolo *Graz* padrão apresentado na seção 3.1. Cada tentativa foi iniciada com a apresentação de uma cruz fixa na tela concomitante a um sinal sonoro curto. Passados 2 segundos, uma dica correspondente à tarefa de IM esperada do indivíduo foi apresentada, permanecendo na tela por 1,25 segundos. Os sujeitos foram instruídos a realizar a tarefa motora até que a cruz fixa

desaparecesse da tela 4 segundos após o início da apresentação da dica. Nenhum *feedback* foi fornecido neste período. Uma pausa curta, com a tela totalmente preta, encerrou a tentativa.

Duas sessões de coleta por sujeito foram realizadas em dias distintos e disponibilizadas em dois subconjuntos de formato geral para dados e meta-dados de sinais biomédicos (GDF, da sigla em inglês para General Data Format for Biosignals), os quais estão disponíveis para *download* gratuito⁷. Cada sessão compreende 6 execuções de 48 ensaios (12 ensaios por tarefa motora), totalizando 288 ensaios por sessão, sendo 72 tentativas por tarefa. Durante as sessões, a sensibilidade do amplificador foi ajustada para 100 μV e ao final, um filtro rejeita faixas de $\pm 50\text{Hz}$ foi aplicado nos sinais para atenuar ruídos de rede.

5.2.4.2 Base de dados *BCI Competition IV-2b* (2B)

O conjunto de dados 2B (LEEB et al., 2008), também gerado para a competição IV de BCI e disponível publicamente no mesmo repositório do conjunto 2A, contém dados de EEG e EOG de 9 sujeitos, os quais, neste caso, realizaram tarefas motoras de apenas duas classes de IM: mão esquerda e mão direita. Os sinais de EEG são amostrados a uma taxa $F_s = 250\text{Hz}$ e provenientes de $P = 3$ canais, localizados no escalpo em posições pré-definidas (C3, Cz, e C4) conforme o protocolo internacional 10-20 (ver Figura 38-A). Novamente, os canais de EOG são desconsiderados no escopo do AutoBCI.

A cronologia do protocolo de coleta é similar à adotada para o conjunto 2A, com a diferença de que aqui um *feedback* visual foi fornecido ao usuário durante a aquisição de 3 das 5 sessões realizadas (LEEB et al., 2007). Em cada sessão, 6 execuções de 20 tentativas (10 por tarefa de IM) foram realizadas, totalizando 120 tentativas por sessão (60 por tarefa) para cada sujeito. A sensibilidade do amplificador também foi ajustada para 100 μV e um filtro rejeita faixas superiores foi aplicado nos sinais resultantes. Os dados e meta-dados de cada sujeito são disponibilizados em arquivos individuais no formato GDF para as 5 sessões de coleta.

5.2.4.3 Base de dados multi-paradigma (LE)

O terceiro conjunto público de dados provém do estudo publicado em Lee et al. (2019) e inclui os três principais paradigmas BCI mencionados na sessão 2.4, tais quais: IM, ERP P300 e SSVEP. Por conveniência, a implementação no AutoBCI considerou apenas os dados referentes ao paradigma de IM.

Um fator contribuinte para a escolha dos dados disponibilizados recentemente⁸, é a inclusão de um número expressivo de sujeitos e de ensaios, algo incomum em conjuntos de

⁷ <http://www.bbc.de/competition/iv/>

⁸ <http://gigadb.org/dataset/view/id/100542>

sinais públicos de EEG devido ao alto custo material e humano exigido em uma aquisição profissional. Outra vantagem, é o fornecimento de uma documentação detalhada dos experimentos de coleta, incluindo informações sobre o controle das condições psicológicas e fisiológicas dos participantes ao longo da aquisição (LEE et al., 2019).

Os dados associados à realização de tarefas motoras no conjunto, identificado pela sigla (LE), mantém sinais de EEG coletados de 54 sujeitos enquanto realizavam duas classes de IM: mão direita e mão esquerda. Os sinais foram amostrados a uma taxa de 1000Hz e registrados a partir de uma rede densa de eletrodos, 62 no total.

Assim como na aquisição dos conjunto públicos anteriores os sujeitos estavam confortavelmente em uma cadeira com braços em frente a um monitor enquanto realizaram o protocolo experimental *Graz* (PFURTSCHELLER; SILVA, 1999) em duas sessões de coleta ocorridas em dias diferentes. Em cada sessão 100 repetições foram realizadas por tarefa motora, totalizando 200 repetições por sessão para cada sujeito. Cada tentativa foi iniciada com a apresentação de uma cruz fixa na tela e após três segundos a dica foi apresentada para que o sujeito executasse a tarefa correspondente durante os 4 segundos subsequentes. Uma pausa de 6 segundos ($\pm 1,5$) foi definida entre as tentativas enquanto a tela permanecia em branco.

Durante o período definido para realização da IM na segunda sessão de coleta, exclusivamente, um *feedback* foi fornecido ao usuário a partir do uso de um *buffer* deslizante de largura fixa (1,5 segundos) classificado em tempo real usando um algoritmo LDA a cada deslocamento de 0,5 segundos. A saída obtida foi traduzida em movimento da cruz para direita ou para a esquerda da tela.

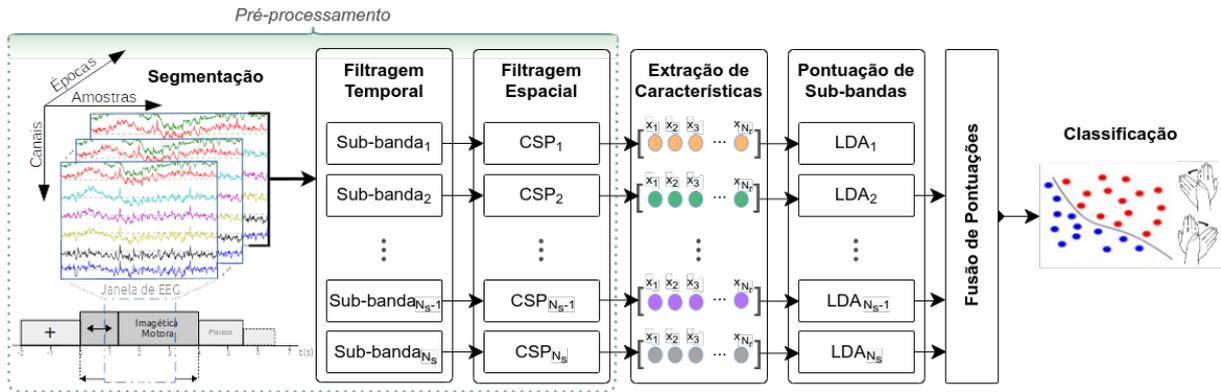
5.2.5 Cadeia de processamento

Em busca de melhorar a performance dos algoritmos da cadeia de processamento, especialmente do método CSP, cuja eficácia depende das frequências discriminativas particulares de cada sujeito, o módulo de processamento do AutoBCI foi implementado com base em uma cadeia baseada em sub-bandas, SBCSP (ANG et al., 2012a).

Conforme discutido na seção 3.2.5, a abordagem SBCSP utiliza um banco de filtros para filtrar os sinais de entrada em múltiplas faixas de frequência o que exige etapas adicionais em relação à uma cadeia clássica de processamento. Dentre as principais diferenças, está a necessidade de processamento paralelo dos sinais em cada sub-banda e posterior combinação das características individuais em direção à uma classificação única. A Figura 32 ilustra as etapas da cadeia de processamento SBCSP aplicada ao escopo do AutoBCI.

Nota-se a partir da etapa de segmentação que a cadeia na Figura 32 corresponde

Figura 32. Cadeia de processamento de sub-bandas (SBCSP) implementada no AutoBCI



Fonte: Elaborado pelo autor, inspirado em Novi et al. (2007)

ao fluxo executado durante a fase de calibração, e segue versão original da abordagem SBCSP proposta por Novi et al. (2007). Após a extração das épocas de treinamento, os sinais em cada uma delas são filtrados em N_s sub-bandas e processados em paralelo.

Durante o processo em cada um dos N_s ramos de execução (*threads*), as características de energia dos sinais filtrados são extraídas usando o CSP e pontuações (*scores*) são atribuídas usando um meta-classificador LDA. As pontuações resultantes de cada sub-banda são agrupadas para formar um novo vetor de características o qual é finalmente usado no ajuste do modelo de classificação.

A partir do ajuste, o modelo está apto à reconhecer padrões de IM em novos segmentos de EEG após terem sido filtrados usando a mesma estrutura de sub-bandas. Vale ratificar que os novos segmentos podem ser coletados tanto previamente visando a validação *off-line* do sistema quanto em tempo real visando o controle da aplicação na fase de execução.

Ao considerar a sequência de processamento de uma única sub-banda, as etapas imediatamente sub-sequentes à etapa segmentação são similares à uma arquitetura clássica de banda única. Com isso, pode-se considerar a arquitetura clássica como sendo um caso particular da abordagem de sub-bandas, correspondente ao cenário em que $N_s = 1$. Neste caso, o processamento paralelo é dispensável assim como as etapas de pontuação de sub-bandas e fusão de pontuações, com o vetor de características obtido a partir da filtragem única dos sinais sendo entregue diretamente à etapa de classificação.

Diferentes estratégias e técnicas podem ser empregadas em cada uma das etapas na cadeia de processamento ICM-IM. Alguns dos métodos comumente adotados para transformação progressiva dos sinais de EEG até o reconhecimento de padrões associados à intenção motora, foram descritos anteriormente.

A proposta de um sistema que permita a configuração automática para ajuste de um

modelo de classificação adequado às particularidades de cada usuário exige a incorporação de múltiplas técnicas em cada etapa de processamento, haja vista que o teste de diferentes configurações também requer que variadas técnicas estejam disponíveis no sistema. Nesse sentido, dentre os métodos contemplados em cada etapa da cadeia de processamento SBCSP no AutoBCI, estão:

- Filtragem temporal/espectral: IIR, FIR e FFT;
- Filtragem espacial: CSP
- Extração de características: energia dos sinais (*log* da variância)
- Pontuação de sub-bandas: LDA
- Fusão de pontuações: Meta-classificador *Bayesiano*
- Classificação: LDA, LR, SVM, KNN e MLP.

A escolha das técnicas se deu baseada na revisão de literatura que apontou as principais ferramentas exploradas no contexto de ICM-IM. Além disso, os resultados dos experimentos preliminares realizados no decorrer do trabalho, cujos resultados estão disponíveis na seção de apêndice deste documento, foram fundamentais para definição das ferramentas mais apropriadas para o escopo da ferramenta proposta.

Observada a eficácia do CSP e do LDA em problemas de classificação binária defendida na literatura (LOTTE; GUAN, 2011) e demonstrada nos experimentos preliminares, decidiu-se por adotá-los como algoritmos padrão nas etapas de filtragem espacial e pontuação de sub-bandas, respectivamente, como evidencia a Figura 32. É importante salientar que, além das técnicas supracitadas, o sistema foi implementado de modo a atender aos requisitos de modularidade e escalabilidade, a fim de possibilitar a inserção simplificada de novas classes, abordagens e técnicas de processamento no futuro.

5.2.6 Ajuste do modelo de classificação

Ao considerar a cadeia SBCSP implementada no AutoBCI, o ajuste do modelo de classificação inclui o cálculo dos parâmetros relativos ao CSP (filtragem espacial), ao LDA (pontuação de sub-bandas), ao meta-classificador *Bayesiano* (fusão de pontuações) e à técnica de classificação final empregada. Conforme já discutido, o ajuste desses algoritmos requer um conjunto de épocas de EEG devidamente rotuladas (i.e. classe de IM conhecida), o que ratifica a importância do processo de extração de épocas.

De acordo com o exposto na seção 3.2.1.1, o processo de extração de épocas de treinamento decorre da segmentação do conjunto completo de dados coletados previamente

considerando uma janela temporal de largura e localização pré-estabelecidas em relação ao momento da dica nos ensaios de aquisição. A dica representa, no segmento de sinal de EEG, o marco temporal onde espera-se que o usuário inicie a realização da IM indicada, sendo fundamental para compor o conjunto de treinamento com épocas de EEG rotuladas.

Normalmente adota-se uma janela típica com largura e localização fixas e independentes do sujeito (ver 16). No entanto, a estratégia de definição manual e empírica das propriedades da janela utilizada na extração de épocas têm se provado ineficiente em alguns casos, dado que cada sujeito reage à instrução de forma particular tanto no tempo quanto na própria resposta mental que descreve a IM (FENG et al., 2018). Nesse sentido, a adoção de abordagens de seleção de janelas temporais menos generalistas e mais personalizadas têm sido estudadas (WEI; WEI, 2016), aspecto considerado compatível com a proposta do AutoBCI.

Assim, para uma descrição mais adequada do processo de extração de épocas no AutoBCI, denota-se por T_{min} e T_{max} os instantes no tempo que marcam o momento em que a dica é apresentada ao usuário e o início da pausa para descanso em um ensaio, respectivamente. Ao assumir que no intervalo entre os marcos T_{min} e T_{max} o usuário esteja realizando a IM indicada em cada ensaio, uma janela temporal, denotada por J e pertencente a esse intervalo é usada para extração de épocas de EEG associadas à realização de IM. As duas propriedades que definem J , localização e largura, são denotadas como J_d e J_l , respectivamente, ambas dadas em segundos.

A Figura 33 ilustra o processo genérico implementado no AutoBCI, para extração das épocas de EEG que comporão o conjunto de treinamento usado no ajuste do modelo de classificação.

Nota-se que a janela típica é substituída por uma janela genérica J definida pelo par de argumentos $[J_d; J_l]$ conforme mencionado. Para fins de comparação, a janela típica foi mantida na Figura 33 em projeção a um exemplar do protocolo experimental *Graz* também incluído no escopo da plataforma.

Ao considerar também uma definição genérica do ponto de vista amostral, ou seja, para sinais amostrados a uma taxa F_s qualquer (125 ou 250Hz), as propriedades que definem a janela J contemplam as amostras no intervalo $[A_-; A_+]$, cujos extremos são determinados de modo que

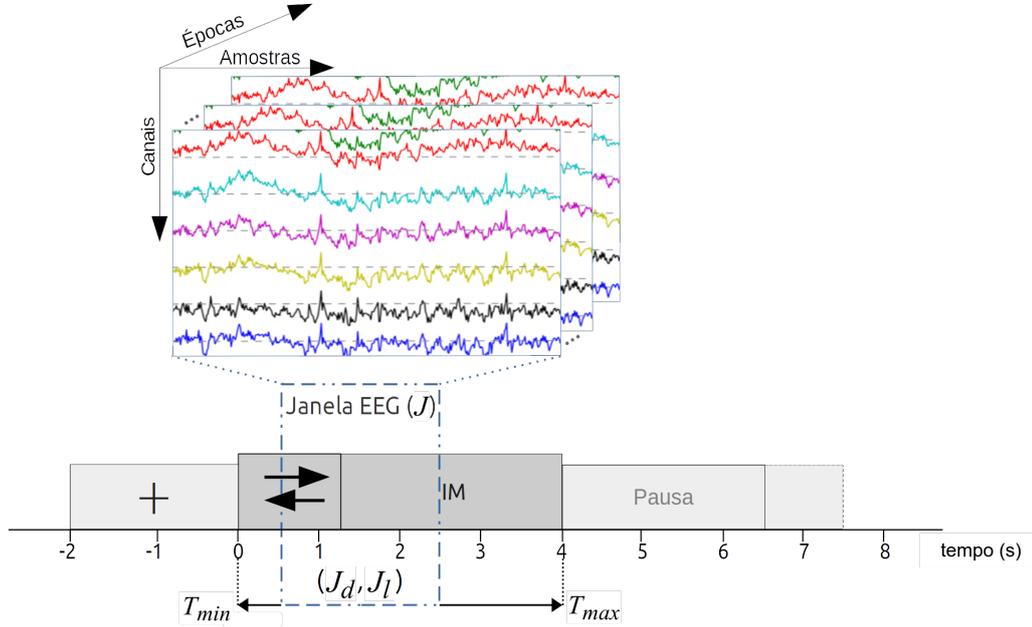
$$A_- = F_s(T_{min} + J_d) \quad (5.1)$$

e

$$A_+ = F_s(J_l) + A_- \quad , \quad (5.2)$$

onde A_- e A_+ são, respectivamente, os índices inferior e superior que delimitam o intervalo de amostras por canal em uma única época de EEG.

Figura 33. Extração de épocas de EEG de treinamento com base no par de argumentos que definem uma janela temporal J . Os traços em azul, delimitam a janela típica projetada no protocolo *Graz*, a qual está localizada à $J_d = 0,5$ segundos após a dica e possui $J_l = 2$ segundos de largura.



Fonte: Autoria própria

Uma vez que, em uma única sessão de coleta para calibração do sistema, ensaios de duas tarefas motoras distintas foram realizadas, \mathcal{A} e \mathcal{B} , representando simulações mentais da mão direita e da mão esquerda, respectivamente, assume-se que $N_{\mathcal{A}}$ épocas associadas à classe \mathcal{A} e $N_{\mathcal{B}}$ épocas associadas à classe \mathcal{B} são extraídas a partir do par de argumentos da janela J .

Ao agrupá-las em um conjunto único de treinamento, $\mathcal{D}_{\mathcal{T}} = \{\mathbf{Z}_{\rho_1} \mathbf{Z}_{\rho_2} \cdots \mathbf{Z}_{\rho_{N_{\mathcal{T}}}}\}$, cuja função é prover exemplos para o ajuste dos parâmetros livres dos algoritmos no sistema, define-se $\mathbf{Z}_{\rho_n} \in \mathbb{R}^{P \times Q}$ para representar a n -ésima época de EEG extraída do intervalo $[A_-; A_+]$. O rótulo $\rho \in \{\mathcal{A}; \mathcal{B}\}$ indica a IM realizada no experimento correspondente, com $n = 1, 2, \dots, N_{\mathcal{T}}$ e $N_{\mathcal{T}} = N_{\mathcal{A}} + N_{\mathcal{B}}$ e as dimensões de uma única época \mathbf{Z}_{ρ_n} referem-se aos P canais de EEG e às Q amostras por canal, observada a taxa de amostragem F_s .

Além do conjunto de treinamento, o processo de ajuste dos algoritmos de aprendizado de máquina requer a configuração prévia de uma série de hiperparâmetros na cadeia de processamento. Aliás, os próprios argumentos que definem a janela J , J_d e J_l , podem ser considerados um dos hiperparâmetros configuráveis de grande relevância para o ajuste do sistema. Outros hiperparâmetros possíveis são as frequências de corte inferior e superior da banda de interesse na filtragem temporal, o número de sub-bandas, o número de filtros espaciais CSP adotado na extração de características e a escolha da técnica de classificação.

Conforme o exemplo da janela típica, a atribuição de valores a esses hiperparâ-

metros comumente ocorre de forma manual e com base no conhecimento empírico e na expertise do projetista ou experimentador. Alternativamente o AutoBCI possibilita, além da configuração manual, a configuração automática desses hiperparâmetros a partir de um método de estimação, o *auto setup*.

A partir do *auto setup*, o modelo de classificação é obtido em função, não apenas do conjunto de épocas de treinamento, como também de um conjunto de instâncias otimizadas, \mathbf{h}^* , para os múltiplos hiperparâmetros na cadeia de processamento SBCSP. Com isso para além dos dados de entrada, a própria parametrização do sistema torna-se particular a cada usuário. Tendo como plano de fundo os conceitos de HPO e BO introduzidos no Capítulo 4, as seções subsequentes descrevem as particularidades do *auto setup* que aplicam o modelo *Bayesiano* de otimização à arquitetura do AutoBCI.

5.2.6.1 Método de configuração automática de hiperparâmetros: *auto setup*

O arcabouço de estratégias HPO introduzidas no Capítulo 4 permite o desenvolvimento de modelos para reconhecimento de padrões cada vez mais assertivos, inclusive na área de ICM-IM. Toda a problemática em torno da configuração manual de hiperparâmetros nesses sistemas, somada ao potencial demonstrado pelas estratégias de HPO, motivaram a implementação do método *auto setup* na plataforma AutoBCI, para o qual a aplicação da BO representa um componente chave.

Por incorporar as técnicas de BO e por ter sido projetada em linguagem compatível à utilizada no desenvolvimento dos demais módulos do AutoBCI, a biblioteca *HyperOpt* foi adotada no desenvolvimento prático do *auto setup*. A ferramenta é resultante do estudo de Bergstra, Yamins e Cox (2013a) e fornece uma infraestrutura completa de paralelização e os algoritmos necessários para aplicar a HPO em projetos práticos de aprendizado de máquina em linguagem *Python*.

O *HyperOpt* implementa todos os componentes de SMBO e BO discutidos anteriormente e permite a construção de espaços de configuração híbridos, ou seja, formados por domínios de hiperparâmetros contínuos, categóricos e condicionais, atendendo aos requisitos de um espaço de configuração amplo e diverso como o da cadeia de processamento baseada em sub-bandas implementada no AutoBCI.

As características promissoras do *HyperOpt* decorrem da proposta hierárquica assumida pela técnica *Bayesiana* TPE proposta por Bergstra et al. (2011) e que já foi discutida em seções anteriores. Em suma, a biblioteca *Python HyperOpt* empacota o TPE com o propósito de tornar prática a otimização de hiperparâmetros em algoritmos de aprendizado de máquina usando a formulação proposta em Bergstra et al. (2011).

No âmbito do *auto setup*, o TPE foi utilizado na construção da distribuição posterior

e otimização do critério de melhoria esperada (EI) para determinação das instâncias de configuração da cadeia de processamento ICM-IM baseada em sub-bandas ilustrada pela Figura 32. O TPE atua de maneira a guiar a busca pelo vetor de hiperparâmetros que maximiza o desempenho do sistema para cada usuário.

5.2.6.1.1 Composição dos dados de treinamento e validação

Ao representar por \mathcal{M} o modelo de classificação, agora compreendendo o *pipeline* com todas as etapas do processamento de sinais na fase de calibração, contendo os hiperparâmetros $h_{1:N_h}$ cada qual associado ao respectivo domínio $\mathcal{H}_{1:N_h}$, têm-se o espaço de configuração hiperparamétrica \mathcal{H} com dimensão N_h . Assim, $\mathcal{M}_{\mathbf{h}_i}$ representa o modelo obtido com a cadeia ICM-IM configurada pela instância de hiperparâmetros $\mathbf{h}_i \in \mathcal{H}$.

Conforme formulado na seção anterior, o ajuste do modelo de classificação no sistema se dá com base em um conjunto de épocas de EEG $\mathcal{D}_{\mathcal{T}}$ extraídas dos sinais de entrada e devidamente rotuladas. O processo de ajuste convencional ocorre com base em um único conjunto $\mathcal{D}_{\mathcal{T}}$, e o modelo obtido é aplicado em novos segmentos de EEG coletados em tempo real ou dispostos em conjunto de validação $\mathcal{D}_{\mathcal{V}}$.

No entanto, o processo de *auto setup* no escopo do AutoBCI requer uma composição diferente. Como discutido no Capítulo 4, a otimização pelo método *Bayesiano* é um processo iterativo, onde a cada ciclo $i = 1, 2, \dots, N_{iter}$ um novo modelo $\mathcal{M}_{\mathbf{h}_i}$ é treinado a partir da i -ésima instância do vetor de hiperparâmetros, $\mathbf{h}_i \in \mathcal{H}$, e avaliado para se obter a saída associada $g(\mathbf{h}_i)$.

Isso significa que durante o processo de ajuste, N_{iter} avaliações são realizadas a fim de permitir a busca pela instância hiperparamétrica ótima \mathbf{h}^* . Nesse cenário, usar um único conjunto de épocas $\mathcal{D}_{\mathcal{T}}$ na fase de calibração, implica assumir que esse mesmo conjunto será usado tanto no treinamento quanto no teste de cada modelo $\mathcal{M}_{\mathbf{h}_i}$. Tal cenário é contraindicado, haja vista que tende a gerar um sobre-ajuste (*overfitting*), ou seja, um modelo demasiadamente ajustado aos dados de treino, implicando baixo erro de classificação no conjunto de treinamento, mas pouco generalizável (BISHOP, 2006).

A consequência do *overfitting* na plataforma AutoBCI seria, em resumo, explicada pela possível calibração do sistema a partir de um vetor \mathbf{h}_* oriundo de uma falsa otimização, uma vez que a cadeia de processamento tenderia a apresentar baixo desempenho ao classificar novos segmentos de EEG (i.e. baixa capacidade de generalização). Na execução *on-line* esse cenário afetaria a usabilidade do sistema na tentativa de controlar a aplicação por comandos baseados em uma classificação de IM com alto viés.

A solução encontrada consiste em usar dois sub-conjuntos distintos de épocas de EEG para treinar e avaliar cada modelo $\mathcal{M}_{\mathbf{h}_i}$ durante o processo de busca *Bayesiana*. Com

isso, para evitar o *overfitting* no processo de calibração do AutoBCI, assume-se $\mathcal{D}_{\mathcal{T}_r}$ como sendo um conjunto de épocas de EEG exclusivo para treinamento do i -ésimo modelo de classificação e $\mathcal{D}_{\mathcal{T}_e}$ como um conjunto de épocas de EEG exclusivo para teste desse modelo, enquanto garante-se que $\mathcal{D}_{\mathcal{T}_r} \cap \mathcal{D}_{\mathcal{T}_e} = \emptyset$ e portanto, $\mathcal{D}_{\mathcal{T}} = \mathcal{D}_{\mathcal{T}_r} + \mathcal{D}_{\mathcal{T}_e}$. Nessa composição, o conjunto de validação, $\mathcal{D}_{\mathcal{V}}$, representa um terceiro grupo de épocas usadas para validação final do modelo obtido a partir da instância ótima \mathbf{h}^* , isto é, pós calibração.

5.2.6.1.2 Hiperparâmetros e espaço de configuração

Os hiperparâmetros ajustáveis pelo *auto setup* compreendem toda a cadeia de processamento ICM-IM de sub-bandas implementada no AutoBCI, desde o pré-processamento até a classificação. Cada hiperparâmetro h está associado a um domínio \mathcal{H} representando seu intervalo de busca individual que por sua vez ajuda a compor o espaço de configuração \mathcal{H} .

A Figura 34, apresenta a projeção dos hiperparâmetros ajustáveis pelo *auto setup* na arquitetura de sub-bandas do AutoBCI, em que é possível observar que a configuração hiperparamétrica se estende da etapa de segmentação das épocas de EEG, com a definição das propriedades de janela para extração de épocas de calibração, até a seleção da técnica de classificação e seus fatores.

Figura 34. Projeção dos hiperparâmetros na cadeia de processamento de sub-bandas implementada



Fonte: Autoria própria

Além de permitir a relação de condicionalidade entre os hiperparâmetros em uma mesma instância \mathbf{h} , a adoção do TPE também permite que domínios com valores categóricos e numéricos seja assumidos, devido à natureza hierárquica formulada nesta técnica BO (BERGSTRA et al., 2011).

Para alguns pares de hiperparâmetros, a relação de interdependência se dá a nível de domínio, em \mathcal{H} portanto, com o intervalo de busca de um sendo restringido ou expandido pelo valor atribuído a outro durante uma iteração. Ao observar os hiperparâmetros projetados na Figura 34, é o caso dos hiperparâmetros que definem a janela por exemplo, onde o valor definido para a localização (J_d) restringe o espaço de busca para a largura (J_l).

Por outro lado, em alguns casos, os hiperparâmetros apresentam uma relação de coexistência, onde um hiperparâmetro só passa a pertencer ao escopo de busca em uma determinada iteração e, conseqüentemente seu domínio, caso outro hiperparâmetro tome um determinado valor. Este é um caso exclusivo dos hiperparâmetros inerentes às técnicas de classificação, em que cada técnica possui o seu próprio sub-domínio de hiperparâmetros. Um exemplo, é o caso em que o parâmetro de regularização só passa a pertencer à instância do vetor \mathbf{h} caso o SVM tenha sido selecionado como candidato na iteração correspondente.

Devido à essa natureza dinâmica, o espaço de configuração no *auto setup* foi projetado com base em uma estrutura hierárquica de modo a permitir a exploração da condicionalidade entre os hiperparâmetros no processo de otimização. A Tabela 2 retrata a relação hierárquica entre os múltiplos hiperparâmetros contemplados pelo *auto setup* a partir das restrições estabelecidas entre eles.

A fim de melhor identificar os hiperparâmetros e correlacioná-los com as etapas na cadeia de processamento, a notação genérica h é substituída pelas respectivas notações usadas ao longo do Capítulo 3, com \mathbf{h} representando uma instância hiperparamétrica com todos os hiperparâmetros apresentados na Tabela 2.

Tabela 2. Descrição dos hiperparâmetros considerados na composição do espaço de configuração \mathcal{H} . A restrição indica a interdependência entre os hiperparâmetros e atua sobre o respectivo domínio condicional

\mathbf{h}	Descrição	Etapa	Domínio	Restrição
J_d	Localização janela pós dica (s)	Segmentação	[0; 0,5 ... 2,5; $T_{max} - 1$]	–
J_l	Largura janela pós dica (s)	Segmentação	[1; 1,5 ... $T_{max} - \frac{T_{max}}{2}$]	$1 \leq J_l \leq T_{max} - J_d$
F_l	Frequência de corte inferior (Hz)	Filtragem	[0,5; 1; 2 ... 29; 30]	–
F_u	Frequência de corte superior (Hz)	Filtragem	[$F_l + 10$; $F_l + 11$... 49; 50]	$50 \geq F_u \geq F_l + 10$
N_s	Nº sub-bandas	Filtragem	[1; 2 ... 49; 50]	$N_s \leq \text{int}((F_u - F_l)/2)^*$
N_r	Nº filtros CSP	Ext. Caracte.	[2; 4 ... $P - 1$; P]	–
ϕ	Classificador final	Classificação	LDA; LR; SVM; KNN; MLP	–

* Restrição válida somente para $N_s \geq 2$

O fator de condicionalidade expressado no espaço de configuração faz com que os parâmetros não condicionais (sem restrição) sejam definidos previamente em relação aos parâmetros com restrição. Como exemplo, nota-se que a instância de J_d é requerida para definição do hiperparâmetro J_l , a fim de se obter uma janela temporal de no mínimo 1 segundo para extração de épocas de treinamento nos limites do período entre a dica (T_{min}) e a pausa curta (T_{max}) nas tentativas durante a coleta dos sinais.

O domínio de F_u , por sua vez, é restringido por F_l de forma a se considerar um intervalo Δ_f com extensão de espectro mínimo de 10Hz entre as duas frequências de corte.

Por fim, a restrição sobre o intervalo Δ_f define o domínio do número de sub-bandas N_s com a função $\text{int}(\cdot)$ denotando a extração da parte inteira do argumento.

Além dos hiperparâmetros listados na Tabela 2, cada técnica de classificação Φ compõe, por si só, um grupo próprio de hiperparâmetros condicionais, os quais são definidos posterior à atribuição de Φ em um mesmo ciclo da busca *Bayesiana*. O sub-espaço de busca que representa esses hiperparâmetros pode ou não existir de acordo com a técnica atribuída. Para as técnicas LDA e LR, por exemplo, o sub-espaço de busca é inexistente, enquanto que para as demais técnicas possíveis para Φ o sub-espaço pode ser formado pelos seguintes hiperparâmetros condicionais e respectivos domínios:

- SVM
 - Regularização $\Phi_c = \{10^{-8} \ 10^{-7} \ \dots \ 10^4\}$
 - Função kernel $\Phi_k = \{ \textit{linear sigmoide gaussiana polinomial grau 3} \}$
- k NN
 - N° de vizinhos $\Phi_{nn} = \{ 2 \ 3 \ \dots \ N_V \}$
 - Função métrica $\Phi_d = \{ \textit{euclidiana manhattan chebyshev} \}$
- MLP
 - N° de neurônios na camada oculta $\Phi_{ne} = \{ 10 \ 20 \ \dots \ 190 \ 200 \}$
 - Taxa de aprendizagem $\Phi_{eta} = \{ 10^{-5} \ 10^{-4} \ \dots \ 10^{-2} \}$.

É importante salientar que, alguns hiperparâmetros fundamentais para as técnicas de classificação apresentadas, e que não foram considerados no espaço de configuração do *auto setup*, assumiram valores padrão típicos na literatura e previamente definidos na biblioteca python *scikit-learn* utilizada na implementação (RASCHKA, 2015). Como exemplo, para a arquitetura da NNA MLP, uma única camada oculta foi usada, a forma admitida para a função de ativação é a tangente hiperbólica e a função de custo para cálculo do erro nas múltiplas épocas é conhecida como entropia cruzada (do inglês para *cross-entropy*) (BISHOP, 2006; RASCHKA, 2015).

A variabilidade no número de hiperparâmetros associados à cada técnica de classificação pertencentes ao domínio de ϕ torna dinâmica a dimensionalidade do espaço de configuração. Além disso, conforme afirma (FEURER; HUTTER, 2019), a relação condicional e o amplo espaço de configuração (independente da escolha de ϕ), associadas aos variados tipos de hiperparâmetros em um mesmo espaço tornam a pesquisa por soluções ótimas conjuntas extremamente complexa e computacionalmente cara para maioria das abordagens HPO tradicionais. A escolha pelo método *Bayesiano* de otimização passa

por este conceito, haja vista que apresenta notória eficiência no que tange ao número de iterações necessárias para convergência em um contexto em que o tempo de treinamento é relevante para a usabilidade do sistema (BASHASHATI; WARD; BASHASHATI, 2016b).

5.2.6.1.3 FFT aplicada ao ajuste eficiente do modelo

Sumariamente, a filtragem temporal busca atenuar ruídos e delimitar o espectro de frequência nos sinais. Em se tratando desta etapa do processamento, especificamente, o *AutoBCI* inclui três técnicas distintas para que o experimentador opte por qual usar durante o processo de configuração manual do sistema, são elas: FIR, IIR e FFT.

Com o propósito de minimizar a elevação do custo de treinamento inerente ao uso de sub-bandas e tornar ainda mais eficiente o processo de busca *Bayesiana* por \mathbf{h}^* , foi adotada a decomposição em frequência via FFT como ferramenta de filtragem temporal padrão do *auto setup*. Aspecto este que exclui do espaço de configuração a escolha do método de filtragem bem como dos parâmetros de ordem inerentes às opções de filtros digitais.

Ao empregar FFT e usar os coeficientes resultantes para delimitar as sub-bandas, a transformação nos sinais de entrada para cálculo dos coeficientes DFT é realizada uma única vez enquanto que, ao usar um banco de filtros convencional, o número de transformações é condicionado ao número de sub-bandas N_s .

Conforme descrito na seção 3.2.2.1.2, a informação espectral nos P canais em uma dada época \mathbf{Z} é representada pela matriz de coeficientes complexos $\ddot{\mathbf{X}} \in \mathbb{C}^{P \times Q}$, cujos elementos são definidos conforme a equação 3.4 e correspondem à decomposição do sinal na base de *Fourier*.

Seja $\mathcal{F} = \{F_l, \dots, F_i, \dots, F_u\}$ o conjunto contendo M frequências discretas na faixa de interesse Δ_f , com $F_u \leq \frac{F_s}{2}$, a quantidade M é definida por,

$$M = \frac{(F_u - F_l)}{\delta_f}, \quad (5.3)$$

em que $\delta_f \triangleq F_{i+1} - F_i = \frac{F_s}{Q}$ denota o espaçamento entre *bins* de frequências consecutivos em *Hertz*, também denominado de resolução em frequência.

Após extrair somente os M *bins* contidos em Δ_f de cada linha de \mathbf{X} , tem-se uma matriz $\ddot{\mathbf{X}}^{P \times M}$ de dimensão reduzida em relação a \mathbf{Z} , uma vez que $M \leq \frac{Q}{2}$.

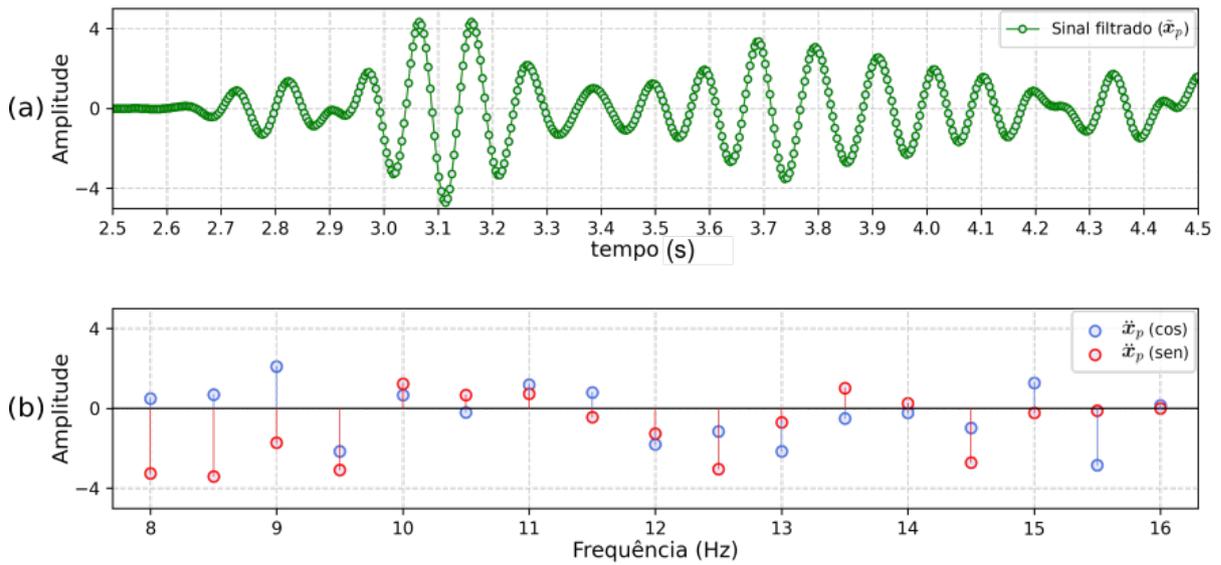
Doravante as colunas de $\ddot{\mathbf{X}}$ mantém o conteúdo em frequência dos sinais nos P canais de EEG, isto será fundamental para determinar a tarefa de IM realizada.

Como cada coeficiente corresponde à amplitude do sinal de determinado canal e em determinado *bin* de frequência, a matriz $\ddot{\mathbf{X}}$ pode ser interpretada como uma representação

mais compacta dos sinais filtrados pelos filtros passa-faixa convencionais apresentados na seção 3.2.2.1, mas ser igualmente útil para representar a informação associada à IM nos sinais a partir dos *bins* associados às frequências correspondentes.

A Figura 35 ilustra exatamente este ponto. Ao considerar um mesmo segmento de sinal bruto \mathbf{Z}_p , a curva 35-a representa o sinal $\tilde{\mathbf{X}}_p$ resultante da filtragem por um filtro passa-faixa convencional, ao passo que no gráfico 35-b são apresentados os termos dos coeficientes DFT complexos associados à frequência na mesma faixa de interesse, decompostos nas bases seno e cosseno.

Figura 35. Comparativo entre as amostras no sinal $\tilde{\mathbf{x}}_p \in \mathbb{R}^{1 \times Q}$ obtido após filtragem usando um filtro IIR de 5ª ordem com faixa de interesse $\Delta_f \triangleq [8, 16]Hz$ (a) e os termos nas bases senoidal e cossenoidal dos coeficientes $\tilde{\mathbf{x}}_p \in \mathbb{R}^{1 \times M}$ correspondentes às frequências na mesma faixa Δ_f (b). Como ambos foram obtidos de um mesmo sinal bruto \mathbf{Z}_p , coletado a uma frequência de amostragem $F_s = 250Hz$, têm-se $Q = 500$ amostras. Ao mesmo tempo, com uma resolução $\delta_f = \frac{F_s}{Q} = 0,5$ entre *bins* de frequência consecutivos, têm-se $M = 16$.



Fonte: Autoria própria

Observa-se que, ao manterem uma representação explícita do conteúdo frequencial, o uso dos M coeficientes DFT em $\tilde{\mathbf{x}}_p \in \mathbb{C}^{1 \times M}$ em detrimento das Q amostras no sinal $\tilde{\mathbf{x}}_p \in \mathbb{R}^{1 \times Q}$, permite uma redução significativa da dimensionalidade na saída da filtragem temporal.

Apesar da qualidade inferior da decomposição realizada pela FFT no sentido de se aproximar de um filtro ideal em relação à filtros digitais convencionais como FIR e IIR (GHRISSE; CHERIF, 2012), um dos estudos preliminares realizados no decorrer deste trabalho apontam que, do ponto de vista de classificação de tarefas motoras em sistemas de ICM, os componentes da DFT, em geral, mantêm a informação necessária para o reconhecimento dos padrões nos sinais de EEG relativos à intenção motora.

Os resultados do estudo em questão, inserido no A, mostram que além de manter o desempenho médio de classificação entre múltiplas classes de IM em um sistema ICM-IM de sub-bandas, o custo computacional ao usar a DFT é significativamente reduzido em relação ao uso de um filtro passa-faixa IIR na etapa de filtragem.

Uma vez que não haja perda de informação relevante do ponto de vista de classificação de tarefas motoras, essa característica pode ser extremamente útil para reduzir o custo computacional da etapa de calibração por isso é explorada no AutoBCI, a fim de reduzir o tempo de processamento em cada iteração da otimização *Bayesiana* no *auto setup*.

A fim de evitar inconsistências numéricas e facilitar os cálculos a partir da matriz de coeficientes $\ddot{\mathbf{X}}$, nas etapas de processamento subsequentes os termos correspondentes ao seno e ao cosseno em cada coeficiente complexo \ddot{x}_{pc} (ver Eq. 3.4), são separados e intercalados de modo a compor uma representação real para a matriz de coeficientes onde $\ddot{\mathbf{X}} \in \mathbb{R}^{P \times 2M}$. Com isso, as amplitudes referentes a p -ésima linha de $\ddot{\mathbf{X}}$ passam a ser expressadas na forma do vetor,

$$\ddot{\mathbf{x}}_p = \begin{bmatrix} \hat{c}_1 \\ \vdots \\ \hat{c}_{2M} \end{bmatrix}^T, \quad \begin{cases} \hat{c}_{2c-1} = \text{imag}(\ddot{x}_{pc}) & \text{para } c = 1, 2, \dots, M \\ \hat{c}_{2c} = \text{real}(\ddot{x}_{pc}) & \text{para } c = 1, 2, \dots, M \end{cases}, \quad (5.4)$$

onde $\text{imag}(\cdot)$ representa a função que extrai o coeficiente do termo imaginário do argumento complexo, equivalente ao seno, e $\text{real}(\cdot)$ extrai o termo real do argumento complexo, equivalente ao cosseno. Note que para cada vetor $\ddot{\mathbf{x}}_p$ os elementos de índice ímpar contém os termos relacionados ao seno dos coeficientes complexos enquanto que os elementos de índice par detém os termos relacionados aos cossenos.

Ainda que a nova representação tenha o dobro de elementos em relação à representação anterior, ao comparar com as dimensões da matriz de sinais resultante da filtragem convencional, a redução tende a ser expressiva especialmente no contexto de sistemas de ICM-IM, uma vez que M depende das frequências de corte no intervalo Δ_f e $2M \leq Q$.

Dado um conjunto de N_s sub-bandas com sobreposição de $\frac{S}{2}$ (i.e. 50%) entre si, para ajusta-las aos M bins contidos em \mathcal{F} , a quantidade N_s deve satisfazer à relação $M = N_b(N_s + 1)$, de forma a obter N_b , como sendo o número de bins de frequências consecutivas em cada sub-banda.

5.2.6.1.4 Função objetivo e avaliação de instâncias

O espaço de configuração \mathcal{H} , a técnica de modelagem TPE e a função de ativação EI, o componente faltante para completar o escopo de implementação BO no *auto setup* consiste no critério utilizado para avaliar cada instância de \mathbf{h} durante o processo de

otimização. Este critério é equivalente à uma representação para a função objetivo $g(\mathbf{h})$ cujas saídas orientam o processo de busca por \mathbf{h}^* .

Neste trabalho, a proposta é modelar a acurácia de generalização do classificador final em função dos hiperparâmetros correspondentes e encontrar um conjunto ótimo de valores \mathbf{h}^* que minimizam o erro de classificação ou maximizam a acurácia esperada. O problema de encontrar valores ótimos \mathbf{h}^* para os hiperparâmetros da cadeia de processamento BCI-MI pode ser expressado como:

$$\mathbf{h}^* = \arg_{\mathbf{h} \in \mathcal{H}} \max g(\mathbf{h}) \quad (5.5)$$

Para tanto, a cada iteração i da busca *Bayesiana*, com $i = 1, 2, \dots, N_{iter}$, avalia-se o desempenho médio de generalização ac_i associado à i -ésima instância de hiperparâmetros \mathbf{h}_i .

Por padrão a plataforma AutoBCI, realiza uma validação cruzada de 5-pastas na busca pelo conjunto ótimo de hiperparâmetros. Isso significa que em cada uma das N_{iter} iterações da otimização *Bayesiana*, o conjunto único de épocas de treinamento $\mathcal{D}_{\mathcal{T}}$ é dividido em 5 sub-conjuntos de igual tamanho. Uma série de 5 validações é executada, cada uma tomando um dos sub-conjuntos para representar $\mathcal{D}_{\mathcal{T}_e}$ e os quatro sub-conjuntos sobressalentes para representar $\mathcal{D}_{\mathcal{T}_r}$. A cada validação da série, um novo sub-conjunto é usado para representar $\mathcal{D}_{\mathcal{T}_e}$ e assim sucessivamente até que os 5 conjuntos tenham sido cobertos.

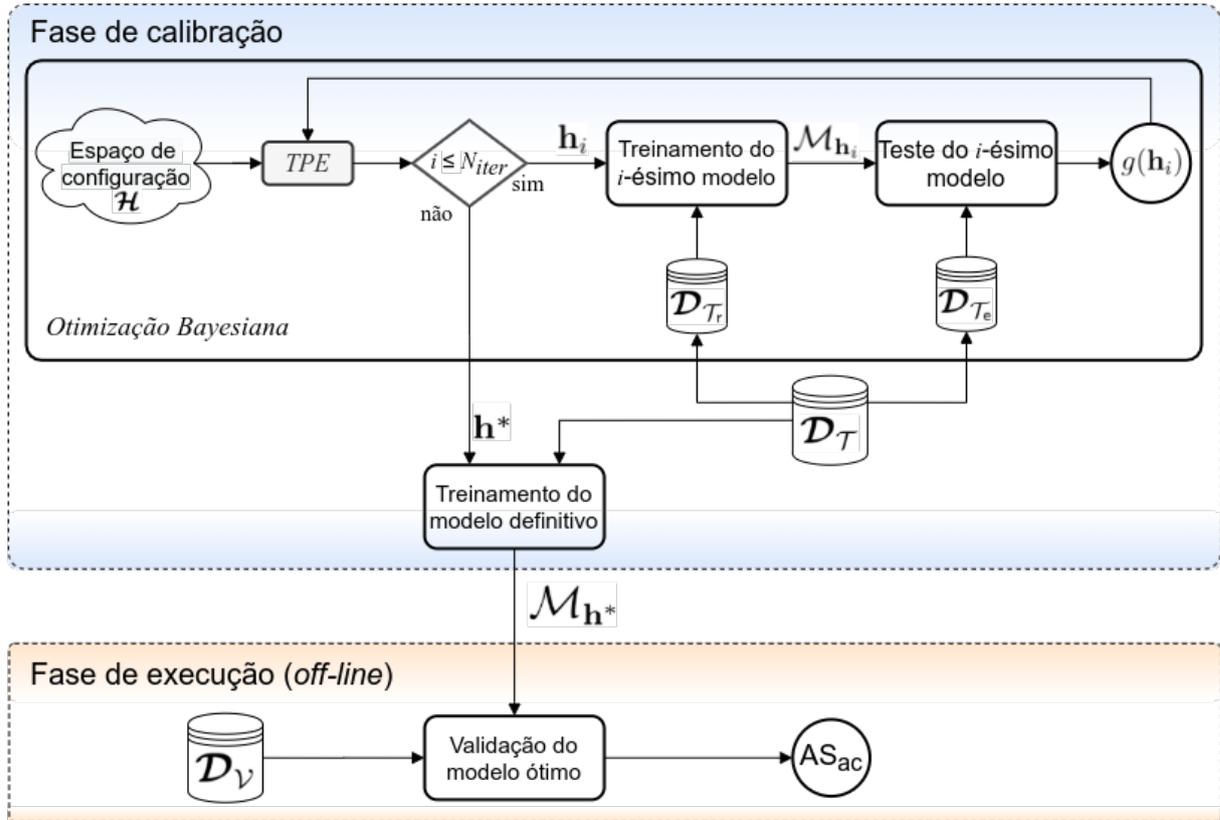
Em cada pasta o modelo $\mathcal{M}_{\mathbf{h}_i}$ é ajustado usando o conjunto $\mathcal{D}_{\mathcal{T}_r}$ corrente e testado a partir do respectivo conjunto $\mathcal{D}_{\mathcal{T}_e}$. Ao final das 5 pastas, a acurácia média de generalização entre elas define a saída $g(\mathbf{h}_i)$ associada à i -ésima instância do vetor de hiperparâmetros.

Em outras palavras, a função $g(\mathbf{h}_i)$, a qual deseja-se maximizar, representa a acurácia de classificação média da i -ésima iteração, isto é $ac_i = \frac{1}{5} \sum_{j=1}^5 ac_{ij}$, em que o desempenho na j -ésima avaliação na validação cruzada, ac_{ij} , é dada pela relação entre o número de épocas corretamente classificadas e o total de épocas no conjunto $\mathcal{D}_{\mathcal{T}_e}$ nos termos da equação 3.32.

O processo de treinamento e teste é repetido para as N_{iter} iterações na busca *Bayesiana*. Ao final, a instância do vetor de hiperparâmetros associada ao máximo desempenho representa o vetor \mathbf{h}^* . A Figura 36 apresenta uma visão geral do método de seleção automática de modelo implementada, abordando em forma de diagrama os principais tópicos supracitados.

Ao final do processo de configuração sintetizado na Figura 36, $\mathcal{M}_{\mathbf{h}^*}$ representa o modelo definitivo gerado a partir do conjunto ótimo de hiperparâmetros, \mathbf{h}^* , obtido com a otimização *Bayesiana*, e das épocas de treinamento do usuário agregadas em $\mathcal{D}_{\mathcal{T}}$. Os parâmetros do modelo ajustado é armazenado para uso futuro na classificação de um novo

Figura 36. Diagrama funcional do processo de ajuste do modelo de classificação a partir da configuração automática de hiperparâmetros promovida pelo *auto setup*



Fonte: Autoria própria

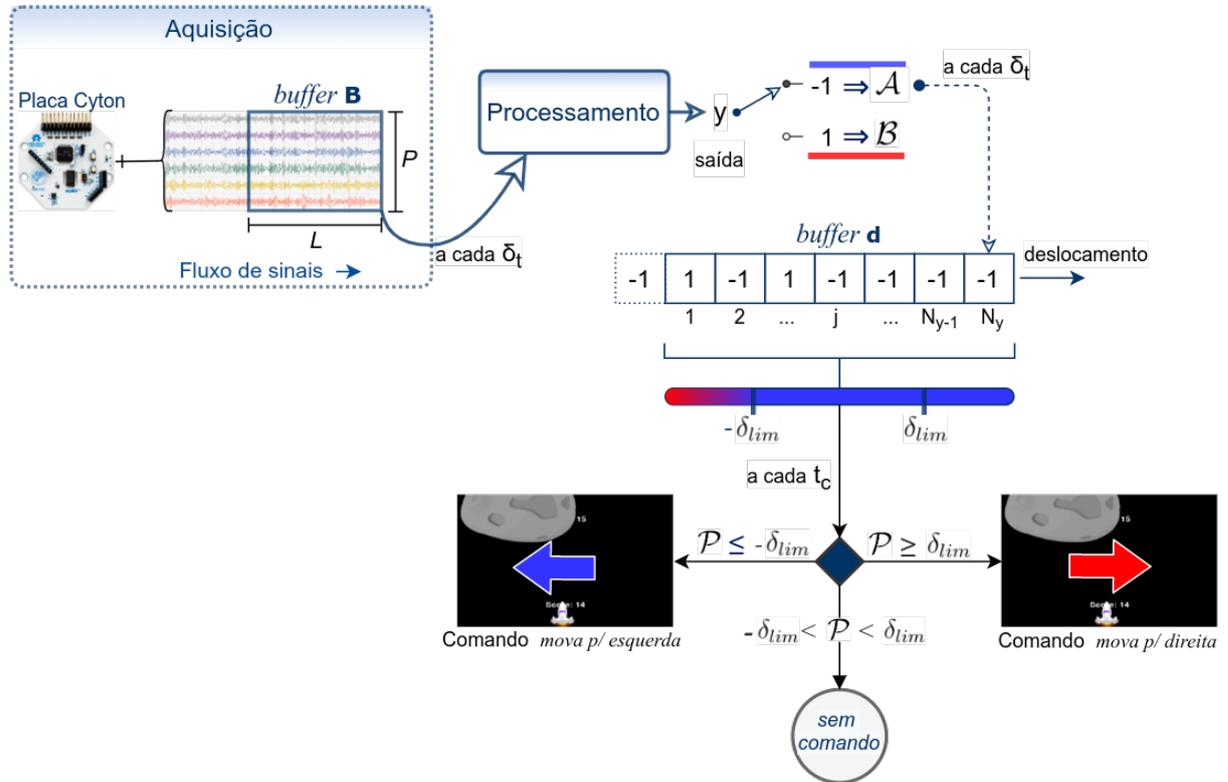
conjunto de épocas de EEG, \mathcal{D}_V , como ilustrado na parte inferior da Figura 36 (execução *off-line*), ou de segmentos de EEG coletados em tempo real (execução *on-line*).

5.2.7 Execução e controle *on-line*

Em contraponto à fase de calibração, durante a fase de execução os sinais são fornecidos pelo amplificador a uma taxa de amostragem F_s e o fluxo de dados é digitalizado e enviado para processamento em tempo real. A medida em que os dados são recebidos pelo sistema, um repositório temporário, denotado como *buffer* B , é usado para extrair épocas do fluxo contínuo de sinais que serão processadas usando o modelo de classificação ajustado na fase de calibração.

Em ciência da computação, o termo *buffer* é comumente empregado para representar um repositório temporário em uma transição de dados em que há uma diferença entre a taxa na qual esses dados são gerados e a taxa na qual são processados, o que é o caso em sistemas ICM-IM típicos. Aqui, o *buffer* B faz referência ao segmento extraído do fluxo contínuo de sinais de EEG durante a fase de execução *on-line*, sendo usado para armazenar temporariamente as L amostras mais recentes nos P canais de EEG. Assim, L

Figura 37. Diagrama esquemático da fase de execução *on-line*. O amplificador empurra amostras de EEG para as etapas de processamento. Um *buffer* B armazena as amostras mais recentes e pode ser acessado pelos módulos de processamento de sinal. A cada δ_t segundos, esses módulos processam os dados atualmente em B e realizam uma classificação



Fonte: Autoria própria

tem interpretação de tamanho do *buffer* e $B \in \mathbb{R}^{P \times L}$ define o *buffer* de forma matricial. A Figura 37 ilustra o processo descrito.

Uma possível analogia que pode ser feita à função do *buffer* B no processo da Figura 37 é imaginá-lo como uma janela de largura fixa L por onde o sinal de EEG passa em um fluxo contínuo observada a taxa de amostragem do amplificador, que no caso da placa *OpenBCI Cyton*, $F_s = 250\text{Hz}$ para $P \leq 8$ canais de EEG ou $F_s = 125\text{Hz}$ caso $8 < P \leq 16$ canais. As amostras nessa janela são enviadas ao módulo de processamento periodicamente, à cada δ_t segundos.

A cada período de amostragem, i.e. $\frac{1}{F_s}$, o *buffer* B é atualizado com um novo vetor de amostras de dimensão $\mathbb{R}^{P \times 1}$ e uma vez atingida a capacidade máxima de L amostras por canal, as amostras mais antigas são constantemente e automaticamente descartadas enquanto amostras mais recentes são admitidas. Para possibilitar tal comportamento, na prática B assume a forma de estrutura de dados em lista encadeada onde um novo vetor de amostras "empurra" o vetor mais antigo para fora da lista.

Para atender à proposta deste trabalho baseada no desenvolvimento de um sistema ICM-IM personalizável e adequado às características cognitivas de cada usuário, o número

máximo de amostras, L , é definido de forma dinâmica conforme o valor atribuído, manual ou heurísticamente, ao hiperparâmetro J_l . Sabe-se que J_l define a largura da janela temporal J usada na extração de épocas de EEG durante a etapa de calibração (vide seção 3.2.1.1). Assim, garante-se que a largura de \mathbf{B} seja equivalente à largura das épocas usadas no ajuste do modelo de classificação.

Seguindo a ilustração da Figura 37, a cada δ_t segundos, o segmento atualmente em \mathbf{B} é enviado ao módulo de processamento para as devidas transformações nos sinais e reconhecimento de padrões que ajudem a discriminar entre as classes de IM. Uma vez que δ_t é um múltiplo da taxa de amostragem, a periodicidade em que um novo segmento é enviado para classificação usando o modelo ajustado pode ser expressada em termos amostrais na forma $\delta_s = \delta_t F_s$. Um fato a ser considerado é que, como a cada envio toda a cadeia de processamento é realizada, o valor atribuído à δ_t deve ser suficiente para classificar o segmento anterior antes que um novo segmento seja enviado ao módulo de processamento, conforme recomenda Duarte (2017).

Nota-se que a variável δ_s define a sobreposição amostral entre segmentos consecutivos enviados para classificação, com $\delta_s = 1$ implicando máxima sobreposição e $\delta_s = LF_s$ em sobreposição inexistente. Apesar de o valor de δ_t ser passível de alteração pelo próprio usuário na interface do AutoBCI, um valor padrão é admitido a fim de se ter um equilíbrio entre máxima e mínima sobreposição e evitar tanto a sobrecarga da unidade de processamento quanto a perda de informações relevantes para descrição da intenção motora do usuário.

Ao considerar as duas classes de IM no escopo deste trabalho, \mathcal{A} e \mathcal{B} , representando tarefas motoras da mão direita e da mão esquerda, respectivamente, um dado segmento de sinal enviado para classificação à partir de \mathbf{B} gera uma entre duas saídas discretas possíveis, sendo $y = -1$ para \mathcal{A} ou $y = 1$ para \mathcal{B} . As saídas do classificador obtidas à cada δ_t segundos durante a fase de execução são usadas para parametrizar a geração e o envio de sinais de comando à aplicação e proporcionam o controle unidimensional do cursor virtual, i.e. movimento para a esquerda ou para direita da tela.

5.2.7.1 Estratégia para geração de comandos

A estratégia incorporada ao AutoBCI para geração de um sinal de comando à aplicação utiliza um conjunto de rótulos de classe produzidos pelo classificador para identificar o padrão de engajamento recente do usuário e decidir sobre sua intenção motora. Para tanto, denota-se por \mathbf{d} um segundo repositório, denominado *buffer* de decisão, cuja função é acumular as N_y últimas classificações realizadas pelo sistema em fase de execução, para que sejam posteriormente utilizadas no cálculo e tomada de decisão sobre o comando.

A ideia por trás de utilizar múltiplas saídas do classificador em detrimento de uma saída única na geração de um comando consiste na busca por aumentar a confiabilidade do comando gerado. Enquanto que em uma estrutura onde um comando advém de uma única saída se têm uma probabilidade significativa de um comando indesejado ser gerado em decorrência de uma eventual classificação incorreta, ao usar um conjunto de saídas têm-se um histórico recente da intenção do usuário. Observada a capacidade de generalização do modelo de classificação, com essa estratégia busca-se atenuar a possibilidade de ocorrência de comandos indesejados.

Semelhante ao comportamento do *buffer* \mathbf{B} explicado na seção anterior, em \mathbf{d} as classificações mais recentes empurram as classificações mais antigas para fora do *buffer*, como forma de se obter sempre os últimos N_y rótulos de classe produzidos. Ao usar $j = 1, 2, \dots, N_y$ como índice para os elementos em \mathbf{d} , observa-se que $\mathbf{d}_j = y_j$ e portanto $\mathbf{d}_j \in \{-1; 1\}$.

Não é difícil inferir que a definição quanto ao tamanho de \mathbf{d} , i.e. N_y , é crucial para se delimitar a quantidade de classificações consideradas no cálculo do comando. Uma vez que a cada δ_t segundos, um novo rótulo de classe é fornecido pelo módulo de processamento, o cálculo de N_y passa a depender somente da definição de um atraso temporal denotado por t_a , também chamado de tempo de ação por corresponder ao tempo estimado para que as predições recentes sejam suficientes para expressar de forma persistente a intenção motora do usuário. Em outras palavras, o parâmetro t_a delimita o intervalo entre o início do primeiro segmento e o fim do último segmento de EEG, ambos extraídos à partir de \mathbf{B} , cujas classificações compõem \mathbf{d} . Diante disso, o tamanho de \mathbf{d} pode ser definido matematicamente por:

$$N_y = \text{int} \left(\frac{t_a}{\delta_t} \right), \quad (5.6)$$

em que $\text{int}(\cdot)$ extrai apenas a parte inteira do resultado.

Como os rótulos em \mathbf{d} representam valores unitários, que diferenciam-se pelo sinal, sendo $a_j < 0$ para classe \mathcal{A} e $a_j > 0$ para classe \mathcal{B} , a média simples entre os N_y elementos no *buffer* pode ser usado no cálculo da proporção,

$$\mathcal{P} = \left(\frac{1}{N_y} \sum \mathbf{d}_j \right) \times 100. \quad (5.7)$$

Note que o sinal de \mathcal{P} implica predominância de uma classe em relação à outra, com isso, $\mathcal{P} < 0$ denota predominância da classe \mathcal{A} em relação à classe \mathcal{B} enquanto que $\mathcal{P} > 0$ implica o contrário. Ao mesmo tempo, o módulo da proporção, $|\mathcal{P}|$, denota o grau de predominância, com $|\mathcal{P}| = 100$ indicando predominância máxima.

Ao observar este cenário sob o prisma da tomada de decisão quanto ao envio ou não de um sinal de comando e de qual comando enviar, a equação Eg. (5.7) fornece duas

informações importantes: (i) a percepção sobre o nível de engajamento do usuário na tentativa de gerar um comando específico, ao analisar o grau de predominância entre as classes e; (ii) a direção para o qual tende a intenção do usuário, a partir do sinal de \mathcal{P} .

Diante das informações, para a tomada de decisão efetiva sobre o comando no AutoBCI, foi adotado um limiar δ_{lim} que estabelece a predominância mínima entre as classes para disparo de um sinal de comando. Em suma, o objetivo com adoção de um limiar é que um comando seja gerado se, e somente se, as predições mais recentes acerca da intenção do usuário, ou seja, nos últimos t_c segundos, mostrem um desequilíbrio significativo entre as duas classes de IM indicando uma tendência segura para uma das classes evitando o disparo precoce. Neste caso, t_c representa a periodicidade em que o *buffer d* é checado e \mathcal{P} é calculado para tomada de decisão sobre o comando.

Na prática, o limiar assume a função de um "gatilho" que dispara em uma das direções caso o grau de predominância da classe correspondente em relação à outra seja suficiente à ponto de superar o valor atribuído à δ_{lim} . Adicionalmente, o sinal de \mathcal{P} é usado para decidir a direção do disparo. Isto posto, um comando só é enviado à aplicação caso uma das seguintes condições seja atendida:

$$\begin{cases} \text{mova para esquerda} & \text{se } \mathcal{P} \leq -\delta_{lim} \\ \text{mova para direita} & \text{se } \mathcal{P} \geq \delta_{lim} \end{cases} \quad (5.8)$$

Em suma, para gerar um comando, é necessário que o usuário mantenha-se engajado em uma única tarefa mental a fim de que o classificador produza saídas consecutivas de uma mesma classe de IM por um período de tempo suficiente. O valor atribuído à t_a , o qual define o tamanho do *buffer d*, serve de *baseline* para orientar o usuário sobre o tempo mínimo de engajamento necessário para disparo do sinal de comando. Assim como δ_t , o valor de t_a é personalizável no sistema.

Na tentativa de fornecer uma visão mais clara sobre o processo descrito, o diagrama apresentado na Figura 37 também contempla a estratégia de tradução em comandos adotada no AutoBCI. Uma analogia possível é considerar a estratégia descrita nessa seção como um sistema de votação, em que, os rótulos em \mathbf{d} representam votos para ambas as classes, e a decisão sobre o comando é tomada a partir da contagem desses votos de forma a se obter a classe majoritária por maioria qualificada.

Dada a alta variabilidade da atividade elétrica cerebral, já amplamente discutida neste trabalho, bem como o fato de que alguns usuários conseguem se adaptar melhor à mecânica do sistema e gerar padrões mais discriminativos do que outros, afetando sobremaneira a capacidade de generalização do modelo de aprendizado, é razoável que o limiar de disparo acompanhe a natureza dinâmica desse contexto e seja definido conforme as características de cada usuário. Para tanto, apesar de também ser um fator personalizável

no AutoBCI, o valor padrão para δ_{lim} no sistema equivale à acurácia de validação *off-line*, $ac_{\mathcal{V}}$ a qual representa o desempenho de generalização do modelo de classificação obtida a partir de um conjunto de épocas de validação, $\mathcal{D}_{\mathcal{V}}$, ou seja, $\delta_{lim} = ac_{\mathcal{V}}$.

5.3 Teste e validação

Com o intuito de avaliar o desempenho geral da plataforma AutoBCI bem como obter uma impressão prática do método de *auto setup*, duas classes de experimentos foram idealizadas, com base nos modos típicos de operação em sistemas de ICM-IM: validação *off-line* e teste de operação *on-line*.

A validação *off-line* da plataforma considerou a aferição da capacidade do sistema em otimizar a fase de calibração, ao configurar automaticamente os múltiplos hiperparâmetros de processamento com base nos padrões particulares de cada instância de dados submetida ao sistema. Com isso, neste experimento é dado um maior foco na validação das rotinas no módulo de processamento especificamente, no sentido de verificar a capacidade da plataforma em adaptar a arquitetura de processamento a cada usuário e a correlação desse procedimento com o desempenho de classificação.

O teste de operação *on-line*, por sua vez, estende o objeto de avaliação para além do processamento e atinge especialmente os módulos de aquisição e controle. O objetivo neste caso é utilizar o modelo de classificação, obtido com a cadeia de processamento devidamente ajustada usando configurações manuais ou o método *auto setup* para classificar o fluxo contínuo de sinais de entrada gerados em tempo real de forma a parametrizar o envio de comandos de controle à aplicação virtual incorporada ao sistema.

O planejamento inicial compreendia a realização sessões de testes com um grupo de participantes reais, recrutados em momento oportuno, visando tanto a validação de desempenho *off-line* quanto o teste de operação *on-line* da aplicação. Contudo, a suspensão de atividades laboratoriais em decorrência da pandemia da Covid-19 no período proposto para a realização dos experimentos impossibilitou o recrutamento de pessoas para testes reais.

Diante de tal impossibilidade imposta por motivos de saúde pública, no sentido de preservar a integridade dos eventuais participantes, a alternativa encontrada consistiu em simulações a partir dos três conjuntos de dados públicos de EEG utilizando o ambiente de simulação incorporado ao AutoBCI. O objetivo é simular o comportamento de indivíduos reais, o que, apesar de não absorver todas as variáveis de uma aquisição real, permite sessões de teste mais longas a partir de um número expressivo de sujeitos, aumentando a variabilidade dos dados sem os desgastes ao usuário inerente de coletas reais.

Como visto na seção 5.2.4, o simulador implementado representa uma versão artificial

do cenário de coleta real, baseado inclusive, no mesmo dispositivo de aquisição de sinais adotado, a placa *OpenBCI Cyton*. A fim de aproximar tanto quanto possível do cenário real e buscar a robustez nos resultados, um número expressivo de sujeitos foi considerado, 72 no total. Esse quantitativo agrega os sinais provenientes de todos os sujeitos nos três conjuntos de dados públicos apresentados anteriormente (i.e. conjuntos 2A, 2B e LE) e visa garantir a diversidade e variabilidade dos dados de teste tanto no cenário *off-line* quanto no cenário *on-line*.

Seguindo o disposto na seção 3.1.3, os sinais nos conjuntos 2A e 2B são amostrados à uma taxa $F_s = 250\text{Hz}$ o que possibilita simular coletas reais utilizando a placa *Cyton* sem o módulo adicional do ponto de vista da frequência de amostragem. Já sob a perspectiva da quantidade de eletrodos, o conjunto 2B mantém a representação desse cenário ao contemplar apenas $P = 3$ canais, ao passo que, o conjunto 2A, por contemplar $P = 22$ canais de EEG, extrapola o limite de 8 canais sem o uso do módulo *daisy* e portanto serve para estender a análise a um cenário alternativo ao uso de placas *OpenBCI*.

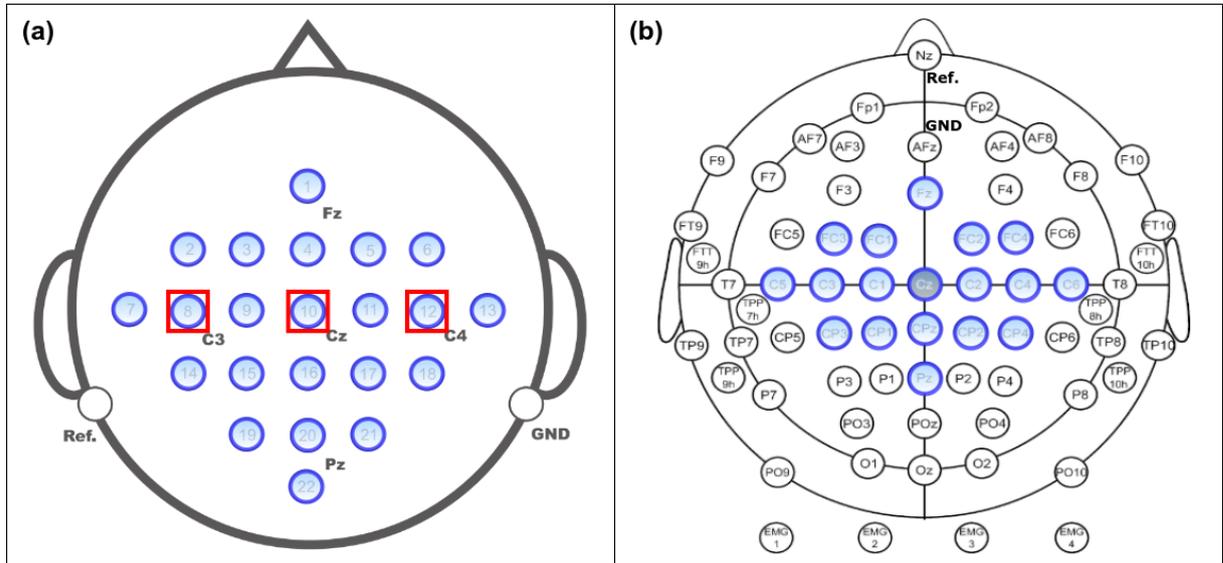
Quanto ao conjunto LE, sua participação nos testes foi planejada para simular cenários com o uso da placa *Cyton* estendida pelo módulo *daisy*, o que dobra o limite de canais possíveis em uma coleta real. Como originalmente os dados neste conjunto são coletados a uma taxa de amostragem de 250Hz e a partir de uma matriz densa de eletrodos de EEG, 62 no total, adequações foram necessárias para compatibilizar os dados com o cenário de simulação. A taxa de amostragem original foi reduzida para um fator 8 vezes menor, a partir de um processo conhecido como *downsampling*, obtendo-se uma taxa final $F_s = 125\text{Hz}$. Adicionalmente, o número de canais foi reduzido de 62 para $P = 16$, completando os requisitos impostos pelo cenário.

A Figura 38 destaca os canais considerados nos experimentos de teste e validação em projeção à matriz de eletrodos original adotada na coleta dos três conjuntos públicos de sinais de EEG dados, todos compatíveis com sistema internacional de posicionamento 10-20 (JURCAK; TSUZUKI; DAN, 2007).

Vale ressaltar que, os canais de EMG e EoG contemplados nos protocolos originais são automaticamente descartados no AutoBCI e, portanto, são desconsiderados nos testes. Outrossim, na Figura 38-b especificamente, a seleção dos $P = 16$ canais destacados em azul, considerou eletrodos posicionados na região do córtex motor, dada a notória relação da atividade sináptica nessa área com o fenômeno associado à IM.

As seções subsequentes apresentam as particularidades das duas classes de experimentos supracitadas. Em ambos os casos, a plataforma AutoBCI foi configurada tanto manualmente quanto usando o *auto setup* a fim de possibilitar a comparação entre esses modos de configuração e verificar a eficácia do método de definição automática de hiper-

Figura 38. Posicionamentos dos sensores de EEG baseado no sistema internacional 10-20 adotados na aquisição dos três conjuntos de dados adotados no trabalho: 2A, 2B e LE. À esquerda as posições circuladas em azul correspondem ao 22 eletrodos considerados no conjunto de dados 2A enquanto que o quadrado vermelho indica a posição no escalpo dos 3 eletrodos do conjunto 2B. À direita, os 16 eletrodos convenientemente selecionados são destacados pelo círculo azul em meio à matriz completa de eletrodos associada aos sinais do conjunto LE



Fonte: Modificado de Brunner et al. (2008) e Lee et al. (2019)

parâmetros usando métricas de avaliação de desempenho de classificação e de eficiência computacional, bem como o impacto desse método no controle da aplicação.

5.3.1 Validação de desempenho *off-line*

A validação *off-line* do AutoBCI buscou avaliar a influência do método de *auto setup* no desempenho de classificação de IM em sinais de EEG, considerando a variabilidade dos dados nos 72 sujeitos adotados. Neste caso, o foco dos experimentos é direcionado à validação das rotinas de processamento propriamente ditas e das estratégias usadas para capacitar a plataforma quanto a adaptação da cadeia conforme o usuário.

A abordagem utilizada na avaliação consiste no comparativo entre o desempenho de classificação obtido com o *auto setup* e os desempenhos obtidos a partir de configurações manuais configuração da cadeia de ICM-IM implementada no AutoBCI. Assim, dois modos distintos de configuração manual foram formatados com base em parametrizações típicas da literatura, sendo o primeiro baseado na cadeia de banda única e o segundo na cadeia de sub-bandas.

Como forma de facilitar a compreensão dos experimentos, bem como dos resultados, a partir de então, a sigla AS será usada para representar a configuração automática de hiperparâmetros com o *auto setup* enquanto as siglas CMBU e CMSB representam os

modos de configuração manual de banda única e de sub-bandas, respectivamente.

Cada um dos três modos de configuração é usado para configurar os hiperparâmetros na cadeia de processamento do AutoBCI e, com isso ajustar o modelo de classificação a partir do conjunto de épocas de treinamento, $\mathcal{D}_{\mathcal{T}}$, referente a cada um dos 72 sujeitos. A validação é *off-line* devido ao desempenho de classificação dos três modelos ser aferido com base em sinais coletados previamente, originados dos três conjunto de dados públicos de EEG. Destarte, uma vez ajustado, os três modelos obtidos a partir dos modos de configuração são aplicados em novo conjunto de épocas, $\mathcal{D}_{\mathcal{V}}$, para obtenção da acurácia de classificação *off-line*.

Em termos de quantidades de exemplos nos conjuntos $\mathcal{D}_{\mathcal{T}}$ e $\mathcal{D}_{\mathcal{V}}$, adotou-se a mesma proporção entre os ensaios disponíveis em cada conjunto de dados, i. e. 50%, mantendo-se o equilíbrio entre as duas classes de IM. Isso significa que, para os sujeitos do conjunto 2A, tanto os dados de treinamento, $\mathcal{D}_{\mathcal{T}}$, quanto os dados de validação, $\mathcal{D}_{\mathcal{V}}$, são constituídos de $N_{\mathcal{T}} = N_{\mathcal{V}} = 144$ épocas de EEG, sendo $N_{\mathcal{A}} = 72$ épocas associadas à IM da mão esquerda e $N_{\mathcal{B}} = 72$ épocas associadas à IM da mão direita, em ambos os conjuntos. O equilíbrio entre as classes contribui para o uso da acurácia como métrica de desempenho.

Quanto aos sujeitos da base pública 2B, por sua vez, os conjuntos de treinamento e validação são compostos por $N_{\mathcal{T}} = N_{\mathcal{V}} = 300$, sendo $N_{\rho} = 150$ épocas por classe e $\rho \in \{\mathcal{A}; \mathcal{B}\}$. Finalmente, para os 54 sujeitos da base pública LE, $N_{\mathcal{T}} = N_{\mathcal{V}} = 200$ épocas compuseram os conjuntos $\mathcal{D}_{\mathcal{T}}$ e $\mathcal{D}_{\mathcal{V}}$, com $N_{\rho} = 100$ épocas por classe em ambos.

A Figura 36 definida anteriormente, ilustra o processo de validação *off-line* do modelo produzido pelo *auto setup*. Nota-se que o modelo definitivo é calibrado a partir de um conjunto de épocas $\mathcal{D}_{\mathcal{T}}$ e validado a partir de $\mathcal{D}_{\mathcal{V}}$, os mesmo usados no treinamento e na validação, respectivamente, dos modelos gerados por CMBU e CMSB. O que difere o procedimento ilustrado na figura em questão, do procedimento de validação de ajustes manuais é estritamente a abordagem usada na instanciação dos hiperparâmetros, a qual, para o *auto setup* dar-se-á heurísticamente enquanto que para CMBU e CMSB ocorre de forma manual.

Os valores usados para configurar manualmente os hiperparâmetros nos modos CMBU e CMSB são apresentados na Tabela 3 e, conforme já afirmado, foram definidos com base em valores amplamente adotados em projetos de ICM-IM. Configurações atribuídas em estudos consolidados na literatura foram consideradas, especialmente as proposições de Lotte e Guan (2011), Ang et al. (2008) e Ang et al. (2012a).

Com base nos hiperparâmetros da Tabela 3, os modelos referentes à CMBU e CMSB foram ajustados e validados. Como resultado, obteve-se as respectivas acurácias de generalização em $\mathcal{D}_{\mathcal{V}}$, $\text{CMBU}_{ac_{\mathcal{V}}}$ e $\text{CMSB}_{ac_{\mathcal{V}}}$, para cada um dos 72 sujeitos avaliados, na

Tabela 3. Definições de valor para o conjunto de hiperparâmetros para os dois modos de configuração manual, CMBU e CMSB, ambos usados na validação da plataforma AutoBCI. Os valores foram definidos com base em estudos correlatos, tais quais Ang et al. (2008) e Ang et al. (2012a).

Hiperparâmetro	Notação	CMBU	CMSB
Localização da janela pós dica (<i>seg</i>)	J_d	0,5	0,5
Largura da janela (<i>seg</i>)	J_l	2	2
Ordem do filtro passa-faixa	Θ	5 ^a	5 ^a
Frequência de corte inferior (Hz)	F_l	8	4
Frequência de corte superior (Hz)	F_u	30	40
Número de filtros CSP	N_r	8	8
Número de sub-bandas	N_s	–	9
Classificador	ϕ	LDA	SVM linear
Regularização	ϕ_c	–	10 ⁻⁴

forma da equação Eq. (3.32) em que p_t equivale a $N_{\mathcal{V}}$.

Subsequente ao processo de validação as abordagens de configuração manual, CMBU e CMSB, a opção de configuração automática via *auto setup* foi ativada e a calibração do sistema se deu a partir do conjunto ótimo de hiperparâmetros \mathbf{h}^* , obtido a partir de $N_{iter} = 100$ iterações da busca *Bayesiana*, nos termos apresentados na seção 5.2.6.1.4. A acurácia de generalização do *auto setup*, $AS_{ac_{\mathcal{V}}}$, também é calculada para cada um dos 72 sujeitos avaliados com base no mesmo conjunto $\mathcal{D}_{\mathcal{V}}$.

Ao final da validação usando os dados de todos os sujeitos, têm-se as respectivas acurácias de classificação, $ac_{\mathcal{V}}$, nos três modos de configuração, o que possibilita a comparação dos desempenhos obtidos. Um ponto a se destacar é que a dinâmica do *auto setup* permite o ajuste dos hiperparâmetros tanto na direção de uma cadeia de banda única quanto de uma cadeia de sub-bandas, a depender das instâncias ótimas selecionadas. Isso é possível, uma vez que as definições apresentadas na Tabela 3 pertencem ao espaço de configuração \mathcal{H} .

5.3.2 Teste de controle *on-line* simulado

Diferentemente da validação *off-line*, o teste de controle *on-line* depende de segmentos extraídos do fluxo contínuo de sinais de EEG gerados em tempo real e submetidos ao módulo de processamento do AutoBCI para classificação e consequente geração de um sinal de comando à aplicação. A intenção motora do usuário é classificada usando o modelo devidamente ajustado.

Desta vez, os experimentos adicionam os módulos de aquisição e controle ao ambiente de testes, e buscam avaliar toda a arquitetura do AutoBCI. O foco principal está na

verificação do impacto gerado pela configuração automática de hiperparâmetros no controle da aplicação e, para tanto, são realizadas sessões de experimentos a partir dos mesmos 72 sujeitos considerados no experimento anterior bem como dos três modos de configuração (AS, CMBU e CMSB) a fim de se correlacionar o uso do *auto setup* com a taxa de sucesso na geração e envio de comandos à aplicação.

Dadas as motivações já discutidas anteriormente, para testar os módulos do sistema no cenário de controle *on-line* utilizou-se o ambiente de simulação, o qual foi incorporado ao AutoBCI com o intuito de possibilitar o uso do sistema a partir de conjuntos de dados públicos de EEG ou coletas prévias, sem a necessidade de uma aquisição em tempo real. Conforme a seção 5.2.4, as rotinas compõem uma versão artificial e puramente lógica da placa *OpenBCI Cyton* e são capazes de simular o comportamento de indivíduos em processos de aquisição reais.

A estratégia de emulação implementada, segue o disposto em Duarte (2017), com a seleção de segmentos de sinais rotulados e coletados previamente. À medida que são selecionados, os sinais de EEG são fornecidos ao módulo de aquisição na mesma taxa de amostragem usada na coleta original. O fluxo artificial de sinais é usado para controlar a trajetória do cursor. Nota-se que o funcionamento da aquisição simulada depende de uma fonte de sinais de EEG armazenada no computador com os devidos meta-dados, ou seja, as marcações e rótulos de classe obtidas durante a coleta (vide seção 3.2.1.1).

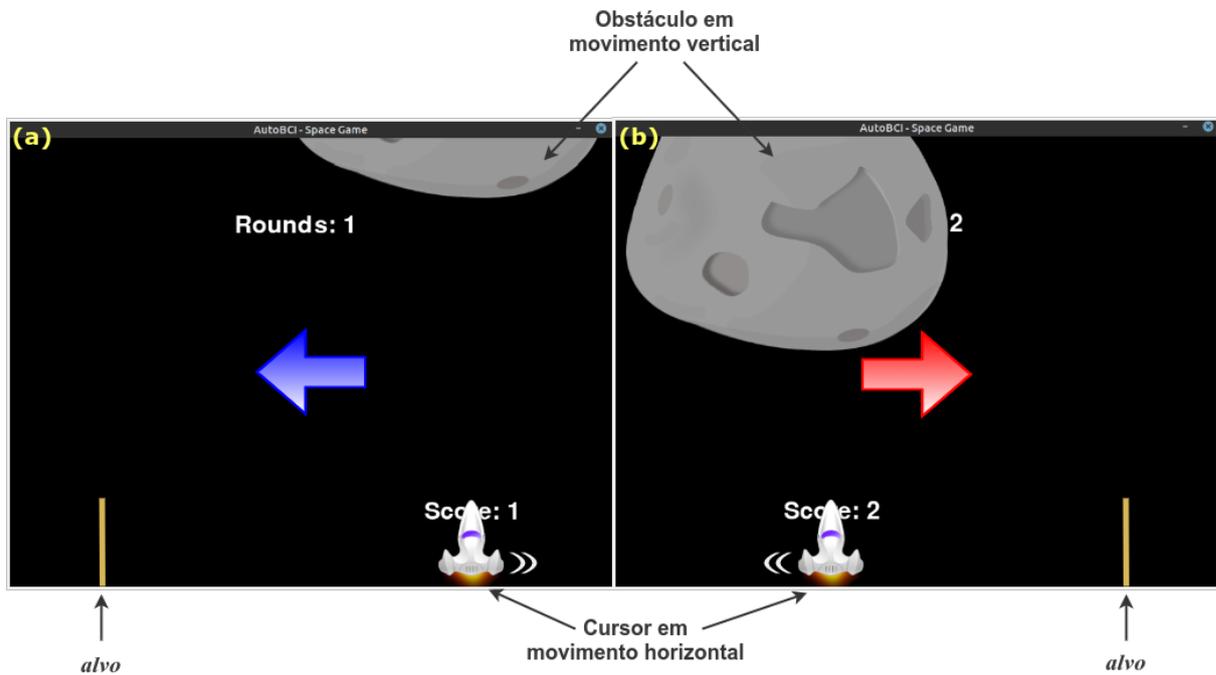
Uma vez que, o conjunto de treinamento, $\mathcal{D}_{\mathcal{T}}$, é usado no ajuste do modelo de classificação, o conjunto $\mathcal{D}_{\mathcal{V}}$, usado na validação *off-line* e cuja composição em função da base de dados já fora definida na seção anterior, também é usado para simular cada sujeito no controle *on-line* da aplicação. Os dados de cada sujeito são usados para simular um usuário real do sistema na tentativa de operar o cursor virtual em múltiplas execuções do jogo ICM Space Game.

5.3.2.1 Ambiente virtual de experimentação *on-line*

O ICM Space Game é a aplicação virtual incorporada ao AutoBCI. Basicamente, consiste em um jogo que simula o controle bi-direcional de um cursor 1D. Em cada execução do jogo, o objetivo é conduzir o cursor (nave) de um lado à outro da tela utilizando exclusivamente imagéticas motoras das mãos direita ou esquerda.

A tentativa de manobrar o cursor na horizontal até um alvo imaginário no lado oposto da tela ocorre enquanto um obstáculo (asteroide) se aproxima em velocidade constante e no sentido vertical. O foco do usuário deve estar em gerar os padrões de IM adequados de modo que os comandos correspondentes sejam suficientes para tirar o cursor da rota de impacto e conduzi-lo até uma zona "segura" da tela. A Figura 39 apresenta duas

Figura 39. Telas do jogo ICM Space Game durante duas tentativas de controle do cursor 1D (nave). O jogo representa a aplicação virtual incorporada ao AutoBCI e é usado no teste de controle *on-line* da plataforma



Fonte: Autoria própria

telas do jogo ICM Space Game extraídas durante duas tentativas de controle do cursor usando dados de aquisição simulada.

Na Figura 39-a o asteroide surge na parte superior direita da tela alinhado verticalmente com a nave. Após um tempo de espera, g_e , dado em segundos, em que ambos os objetos permanecem estáticos, o asteroide começa a se aproximar em direção à parte inferior da tela e em velocidade constante g_v . Enquanto isso, espera-se que o usuário esteja engajado na tarefa mental que possibilite a geração de comandos conforme a estratégia na seção 5.2.7.1 para movimentação da nave no sentido horizontal e em direção ao lado esquerdo da tela. A Figura 39-b segue uma narrativa análoga, porém com referenciais opostos.

As setas são meramente ilustrativas e indicam o movimento esperado para o cursor em direção ao alvo (zona segura) identificado pelas linhas verticais amarelas em ambas as imagens na Figura 39. Todos os parâmetros de jogo mencionados são personalizáveis na plataforma AutoBCI, incluindo o número de execuções do jogo bem como a quantidade de tentativas por execução.

As coordenadas horizontais em pixel que definem o posicionamento do alvo, seja quando está à direita seja à esquerda da tela, também são personalizáveis na GUI do AutoBCI, assim como a taxa de arrasto em pixels por segundo e a distância em pixels percorrida pela cursor a cada comando enviado. Quanto ao posicionamento do cursor,

via de regra, este é inicializado no mesmo lado em que está o obstáculo e, portanto, as coordenadas horizontais que marcam o centro dos dois objetos se equivalem no início da tentativa.

Há três condições para encerramento da partida:

- i. imediatamente após a nave atingir o alvo (limiar em amarelo);
- ii. nave manter-se suficientemente afastada do asteroide até que este percorra toda a extensão vertical da tela;
- iii. imediatamente após a nave ser atingida pelo asteroide.

A fim de contabilizar a taxa de sucesso no controle da aplicação, um sistema de pontuações foi implementado de modo que o encerramento de uma tentativa em decorrência das condições (i) e (ii) incorra em incremento de 1 à pontuação geral. Por outro lado, o encerramento provocado pela condição (iii) implica incremento de 0.

O tempo decorrido em cada tentativa também é contabilizado, para que seja possível diferenciar as condições (i) e (ii). Nesta perspectiva, a condição (i) passa a ser a forma de encerramento desejável uma vez que o encerramento da tentativa ocorre em tempo reduzido em relação à condição (ii), sugerindo habilidade e agilidade do usuário em gerar os padrões cognitivos necessários bem como em manter-se engajado na mesma classe de IM.

5.3.2.2 Especificações e procedimentos experimentais

Diante do cenário experimental apresentado, a etapa seguinte consiste na definição de cada uma dos parâmetros que o compõem para que seja possível a comparação entre os sujeitos bem como entre os modos CMBU, CMSB e AS.

Primeiramente, foram definidos os parâmetros de jogo, com as dimensões da tela fixada em 800×600 pixels e a coordenada horizontal do alvo sendo igual à 160 pixels caso o cursor inicie à direita da tela e 640 pixels caso o cursor inicie à esquerda, e vice-versa, ambos em relação à extremidade esquerda da tela. Independentemente das dimensões atribuídas à tela de jogo, o obstáculo ocupa sempre 45% da largura definida.

A velocidade de aproximação do obstáculo foi definida em 40 pixels/segundo, o que acarreta em uma estimativa de aproximadamente 15 segundos para que este percorra toda a extensão vertical da tela. O deslocamento do cursor à cada comando é igual à 120 pixels com arrasto de 150 pixels/segundo, o que significa que um sinal de comando leva 0,8 segundos para ser reproduzido pelo cursor.

Note que, uma vez que tanto o cursor quanto o alvo foram inicializados à 160 ou à 640 pixels da tela, um padrão ouro de controle equivale à quatro comandos enviados consecutivamente na direção do alvo.

Ao todo, foram realizadas 100 tentativas de controlar o cursor por modo de configuração hiperparamétrica a partir dos dados de cada um dos 72 sujeitos. As tentativas foram separadas em blocos de 5 sessões com 20 tentativas cada, a fim de simular a pausa longa e aproximar o cenário de testes tanto quanto possível de uma operação real. Ou seja, para cada sujeito 300 tentativas de controle foram realizadas.

Ao considerar o experimento completo a partir de dados de um único sujeito e m único modo de configuração, uma vez obtido o modelo de classificação definitivo na fase de calibração do AutoBCI, este modelo foi usado na classificação em tempo real de segmentos de EEG fornecidos artificialmente pelo sistema de aquisição simulada.

Ao início de cada tentativa, o cursor e parte do obstáculo são apresentados em um dos lados da tela permanecendo estáticos por um período de espera de 5 segundos. A apresentação do obstáculo indica o caminho que deve ser percorrido pelo cursor e a classe correspondente à MI da mão oposta. Sabendo-se da classe esperada, o sistema começa a selecionar as épocas associadas à essa classe no conjunto de dados de validação, \mathcal{D}_y , ou seja, épocas de \mathcal{A} para esquerda ou épocas de \mathcal{B} para direita.

As épocas são concatenadas em um repositório temporário a partir do qual é enviado ao sistema um novo vetor com P amostras com $1 \times P$ à cada $\frac{1}{F_s}$ segundos, a fim de respeitar a taxa de amostragem oficial e emular o funcionamento da placa *Cyton*. A Figura 37 apresentada anteriormente ilustra bem os passos seguintes, em que, após um tempo inicial de LF_s segundos, o segmento de EEG com as L amostras mais recentes por canal, as quais compõe o estado corrente do *buffer* \mathbf{B} , é enviado para processamento e classificação usando o modelo de classificação ajustado.

À cada $\delta_t \triangleq 0,1$ segundos, uma nova instância do *Buffer* \mathbf{B} é enviada ao módulo de processamento. As saídas de classificação são acumuladas no *buffer* de decisão \mathbf{d} , cujo número de elementos, N_y , é dado pela equação (5.6) em que $t_a \triangleq 2$.

Iniciada a tentativa com as épocas de uma determinada classe sendo selecionada e suas amostras enviadas periodicamente para classificação, após um período de espera de 5 segundos, um sinal visual concomitante à um sinal sonoro é emitido indicando que o cursor passa a responder aos sinais de comando gerados. Até então nenhum comando, eventualmente gerado pelo sistema durante o período de espera, é reproduzido pelo cursor. Imediatamente, o obstáculo começa a progredir em direção à parte inferior da tela à 40pixels/segundo ao mesmo tempo em que novas classificações são adicionadas ao *buffer* \mathbf{d} pela direita e outras são descartadas pela esquerda (ver Figura 37).

A cada $\delta_c \triangleq 1$ segundo, os elementos em \mathbf{d} são usados para cálculo de \mathcal{P} e a decisão sobre o envio do comando é tomada com base no sinal do valor resultante e em um limiar $\delta_{lim} \triangleq ac_{\mathcal{V}}$, em que $ac_{\mathcal{V}}$ é a acurácia de classificação obtida para o sujeito durante a validação *off-line* a partir do respectivo modo de configuração.

Nota-se que, ao definir $\delta_c = 1$ e $t_a = 2$ têm-se uma sobreposição de 50% dos elementos de \mathbf{d} entre tomadas de decisões, onde a ideia é simular a condição real em que estados mentais imediatamente anteriores interferem no estado mental atual do indivíduo.

O processo segue até que uma das três condições para encerramento da tentativa seja satisfeita. Conforme definido na seção anterior, um acumulador de pontuações, denotado por p_s , é incrementado em 1 caso a tentativa tenha sido encerrada devido às condições (i) ou (ii).

Adicionalmente, o tempo de duração da tentativa em segundos é contabilizado em t_s e utilizado na avaliação de desempenho. Uma vez que durante o tempo de espera o sistema anexa épocas da classe esperada com base na indicação do posicionamento do asteroide na tela, este tempo também é considerado na contabilização de t_s .

Ao fim da tentativa, uma nova foi iniciada até que o total de 20 fosse atingido, encerrando uma sessão de testes. Dentre as tentativas por sessão, 10 alvos são posicionados à esquerda e 10 à direita da tela, mantendo a proporção entre a MI das mãos esquerda e direita. A sequência dos alvos é definida aleatoriamente antes do início da sessão, com a restrição de não haver 4 tentativas consecutivas da mesma classe. O tempo de espera no início de cada tentativa simula a pausa para descanso buscando reproduzir o comportamento de um usuário real operando a plataforma.

Ao todo, foram executadas 5 sessões com o mesmo número de tentativas, em que cada uma gerou uma pontuação, p_s , e um tempo de execução, t_s , possibilitando inferências baseadas em cálculos de média e demais análises estatísticas. As 5 sessões são repetidas com as mesmas definições nos parâmetros de jogo e de controle para os 72 sujeitos e para cada um dos 3 tipos de configuração.

Por meio das pontuações obtidas, p_s , obteve-se a taxa de sucesso média, $ac_{hit} = \frac{p_s}{20}$, a qual representa o número de acertos ao alvo entre as 20 tentativas por sessão. A taxa de sucesso média e o tempo médio de execução entre as sessões são utilizados no cálculo da ITR média de cada sujeito e modo de configuração.

A ITR é amplamente utilizada como métrica de desempenho no controle *on-line* de sistemas de ICM-IM e pode ser calculada conforme a equação (3.35) (THOMPSON; BLAIN-MORAES; HUGGINS, 2013). A ITR é obtida em bits por segundo e mede a capacidade de controle efetivo em função da porcentagem de tentativas em que o alvo indicado fora atingida e do tempo gasto para conclusão de cada sessão. Quanto maior o

número de acerto no menor tempo, maior o ITR.

Diante disso, a ITR média é adotada como métrica de usabilidade para investigar a influência do *auto setup* no controle em relação aos tipos de configuração manual. A hipótese levada em consideração nessa investigação é que quanto maior a capacidade preditiva do modelo de classificação, menor o tempo necessário para conclusão da sessão de testes e maior a taxa de acerto dos comandos gerados.

5.4 Análise dos Resultados

Após a realização dos testes, a próxima etapa da pesquisa consistiu na análise estatística dos resultados obtidos em todos os experimentos descritos na seção 5.3. Métricas específicas, já formuladas na seção 3.3 foram usadas na quantificação dos resultados, dentre as quais destacam-se métricas derivadas da matriz de confusão, especialmente a acurácia de classificação na forma das equações (3.32) e (3.33).

A acurácia é usada, tanto na aferição do desempenho *off-line* da ferramenta quanto do desempenho *on-line*, para medir a capacidade dos modelos de classificação em discriminar entre classes de IM bem como avaliar a taxa de sucesso no controle simulado da aplicação virtual.

Com o objetivo de validar a aplicabilidade da plataforma AutoBCI ao classificar os sinais de EEG com cadeia auto-configurada, a acurácia obtida nos testes de validação *off-line* com o AS para cada um dos 72 usuários foi comparada ao desempenho em ambos os modos de configuração manual, CMBU e CMSB.

A eficiência computacional também foi medida a partir dos tempos gastos durante o treinamento e teste dos modelos de classificação otimizados, ao considerar a estratégia padrão de filtragem de sinais no AutoBCI, baseada no algoritmo da FFT em cadeia de sub-bandas, em comparação com técnicas de filtragem convencional, baseadas em bancos de filtros.

A análise sob essa perspectiva visou validar a capacidade da FFT em minimizar o custo médio de treinamento do modelo sem prejuízo à sua capacidade preditiva. Para tanto, as acurácias de generalização e os tempos médios gastos no ajuste dos modelos definitivos usando BO foram calculados para cada sujeito considerando primeiro a FFT como método de filtragem e em seguida um filtro digital convencional.

Ademais, a taxa de transferência de informação (ITR) é usada para avaliar a velocidade de comunicação bem como a usabilidade prática da plataforma, seguindo o disposto na equação (3.35). A métrica foi considerada útil para medir a capacidade e a agilidade do sistema em detectar os padrões de IM que descrevem a intenção motora nos sinais de EEG e traduzi-los em comando reais para a aplicação, haja vista que leva em

consideração a taxa efetiva em que os comandos são enviados.

A taxa de sucesso entre as pontuações em cada sessão do teste de controle *on-line*, ac_{hit} , juntamente com o tempo total agregado nas 20 tentativas por sessão, t_s , são usados no cálculo da ITR média em bits/segundo de cada sujeito e modos de configuração, como forma de comparar os desempenhos obtidos.

Nos testes *on-line*, as abordagens adotadas na experimentação e na análise e discussão dos resultados, com a comparação entre os modelos clássicos e modelos de configuração otimizada, propiciaram uma visão geral sobre a relação entre a capacidade preditiva do modelo ótimo, obtido via *auto setup*, e o controle efetivo da aplicação.

Além disso, esperava-se validar toda a logística ICM-IM implementada no AutoBCI, sobretudo o gerenciamento do fluxo de sinais e a estratégia de geração de comandos, uma vez que o controle virtual, mesmo que simulado, contempla a atuação dos três módulos do sistema e a aplicação do modelo ajustado na fase *off-line*.

Rotinas utilizando bibliotecas de visualização em linguagem *Python*, como *matplotlib* e *seaborn*, compatíveis com as tecnologias adotadas no desenvolvimento da plataforma proposta no trabalho, foram implementadas a fim de melhor representar os dados e produzir análises mais claras baseadas em tabelas e gráficos comparativos.

Trabalhos que realizaram testes e avaliações de desempenho de classificação similares, ou seja, utilizando os mesmos conjuntos de dados, também foram considerados na análise dos resultados como forma de posicionar o trabalho em âmbito geral. Os resultados obtidos com o *auto setup* foram comparados aos resultados das abordagens de configuração em referenciais correlatos.

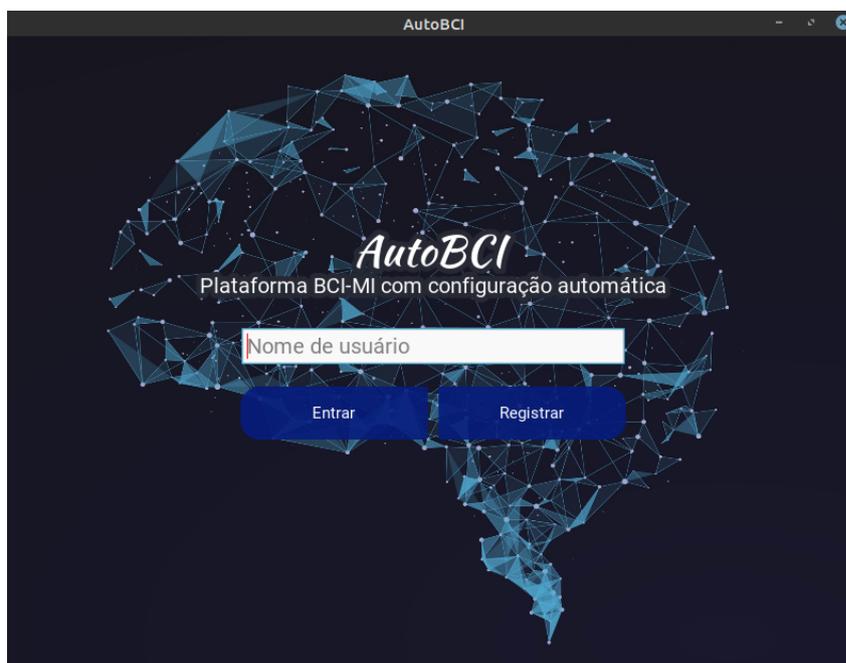
6 PLATAFORMA AUTOBCI

Uma apresentação geral sobre a ferramenta proposta neste trabalho foi fornecida ainda no Capítulo 5, com a arquitetura principal do AutoBCI sendo ilustrada na Figura 29. Neste capítulo, mais detalhes acerca das principais funcionalidades implementadas na plataforma bem como da interface gráfica desenvolvida serão apresentados, com ênfase nos passos necessários para uma operação satisfatória do sistema, cumprindo assim um dos objetivos traçados pelo trabalho relacionado à documentação do sistema proposto.

A primeira versão do sistema representa o produto final da pesquisa e está disponível de forma gratuita no ambiente *GitHub*¹. Para além da ampla divulgação do trabalho, a abertura completa do código implementado em linguagem *Python* e a publicização em um ambiente difundido, visa incentivar a melhoria colaborativa do sistema bem como contribuir com novas pesquisas em ICM-IM e áreas afins.

As ferramentas usadas no desenvolvimento do AutoBCI foram destacadas na seção 5.2.1, com uma GUI projetada com base na biblioteca gráfica *Kivy*. Os passos e os recursos necessários para instalação da ferramenta também estão disponíveis no ambiente do *GitHub* e, uma vez instalada e executada, suas funcionalidades podem ser acessadas a partir da tela inicial apresentada na Figura 40.

Figura 40. Tela inicial da plataforma AutoBCI pela qual é possível ter acesso às funcionalidades do sistema após o registro do usuário



Fonte: Autoria própria

Conforme nota-se na interface da Figura 40, o acesso às funcionalidades do sistema

¹ <https://github.com/vitorvilasboas/autobci>

exige um breve registro prévio a fim de se obter informações potencialmente úteis do usuário. Além de possibilitar o estabelecimento de uma sessão individual e permitir a personalização da interface, o registro pode ser como um questionário inicial acerca das características físicas e psicológicas dos usuários.

Uma vez registrado, o usuário tem acesso à todas as funções implementadas nos três módulos que compõem a arquitetura do AutoBCI, e que já foram discutidos anteriormente, tais quais: aquisição, processamento e controle. As opções em cada um dos módulos e a sequência de ações para sua operacionalização serão descritas nas seções subsequentes.

6.1 Módulo de Aquisição de Sinais de EEG

De acordo com o diagrama na Figura 30, o módulo de aquisição do AutoBCI foi projetado para gerenciar todas as funções relativas à entrada de dados no sistema, desde a conexão com um amplificador de EEG específico até o armazenamento em disco ou destinação dos sinais coletados para processamento em dois modos de operação, calibração *off-line* e execução *on-line*.

Além disso, as funcionalidades do módulo incluem uma interface para configuração prévia do protocolo usado na mediação da coleta para a fase de calibração (*off-line*) e gerencia tanto os eventos quanto os meta-dados ao longo do experimento.

A configuração do experimento de coleta ocorre em duas etapas no AutoBCI. Primeiramente o usuário estabelece o modo de aquisição e a fonte dos sinais de entrada para em seguida definir os parâmetros do protocolo experimental. Como apontado no Capítulo 5, a aquisição dos sinais de EEG pode ocorrer tanto no modo real, usando o fluxo de sinais gerados em tempo real pelo amplificador *OpenBCI* conectado à interface do sistema, quanto em modo simulado com a reprodução de sinais previamente coletados de forma a emular a entrada do amplificador.

Enquanto a aquisição real é possível somente via placa *Cyton* nesta primeira versão do AutoBCI, a reprodução no modo simulado é possível tanto a partir de coletas anteriores, efetuadas com o próprio AutoBCI, ou a partir de bases de dados públicas de EEG incorporadas ao sistema.

O que diferencia a aquisição real do modo simulado é o fato de a primeira utilizar o fluxo de sinais medidos em tempo real pelo amplificador de EEG. Integrada à placa de aquisição *Cyton* da *OpenBCI*, a qual foi apresentada na seção 5.2.3, a configuração de uma aquisição real com o AutoBCI exige poucas ações do usuário, como pode ser observado na interface apresentada na Figura 41.

Na ilustração, o usuário informa a porta serial a qual o *dongle* está conectado (passo 2), habilita ou não o uso da *Daisy* (passo 3) e rotula os canais utilizados conforme a

Figura 41. Interface de configuração do modo de aquisição real no AutoBCI. A sequência numérica indica os passos que devem ser seguidos pelo usuário na preparação do sistema e integração com o *hardware* de aquisição



Fonte: Autoria própria

disposição no escalpo (passo 4). Para evitar um eventual erro de configuração e garantir a sincronia entre a geração dos meta-dados e o fluxo de sinais enviados ao computador, a taxa de amostragem (F_s) é definida automaticamente pelo sistema assim que o usuário opta pelo módulo adicional.

A Figura 42, por sua vez, apresenta a tela do sistema onde o usuário pode configurar a aquisição simulada. Diferentemente da versão de base implementada em Duarte (2017), limitada à reprodução de coletas próprias, na versão do simulador implementada no AutoBCI, duas opções podem ser consideradas pelo usuário: (I) usar dados de uma aquisição real anterior realizada no próprio sistema usando a placa *Cyton* ou; (ii) utilizar sinais de EEG de algum dos 72 sujeitos disponíveis nos três conjuntos de dados públicos cujos protocolos são interpretados nativamente pelo sistema, os quais foram apresentados em 3.1.3.

A nova implementação tira do usuário a responsabilidade de conhecimento prévio dos detalhes do experimento que originou o arquivo de coleta informado e permite a extensão do uso do processo de simulação para além de coletas realizadas com o amplificador *OpenBCI*, tornando possível a reprodução de dados adquiridos de outras fontes e com protocolos experimentais distintos sem exigir do usuário conhecimento específico acerca destes.

Figura 42. Configuração para aquisição simulada no AutoBCI. Na sequencia apresentada, um arquivo com dados públicos de EEG de um dos conjuntos reconhecidos pelo sistema é convertido para formato compreendido pelo AutoBCI e selecionado para reprodução na mesma taxa de amostragem usada durante a coleta original dos sinais, também compatível com as taxas de amostragem do *OpenBCI*.



Fonte: Autoria própria

Conforme ilustrado na Figura 42, para utilizar dados públicos de EEG, o usuário aciona a opção equivalente na interface do sistema (passo 1), define o conjunto de dados desejado e escolhe um dos sujeitos associados à esse conjunto (passos 2 e 3) e informa o local do arquivo original de dados (passo 4), o qual, no caso ilustrado, é disponibilizado em um formato específico para gravação de biosinais. Novamente, a taxa de amostragem é definida automaticamente pelo sistema assim que o conjunto de dados públicos é selecionado.

Vale ressaltar ainda que a opção pelo uso de sinais públicos de EEG exige que o usuário tenha efetuado o download dos dados originais previamente, os quais são disponibilizados de forma gratuita e cujos sítios serão apresentados na seção 3.1.3 a seguir. A inclusão destes dados junto ao pacote do AutoBCI não seria uma opção viável, dado que os registros para cada sujeito apresentam um grande volume, totalizando aproximadamente

67 gigabytes entre dados e meta-dados.

Uma vez fornecidas as informações acima e após o usuário optar por converter os dados originais (botão do passo 5), o sistema processa internamente os dados e meta-dados relativos ao conjunto informado, identificando automaticamente informações particulares à coleta como taxa de amostragem, rótulos de classes de IM contempladas, eventos e cronologia do protocolo experimental, número de tentativas e execuções por tarefa e especificações dos canais e seu posicionamento do escalpo, gerando, ao final, um novo arquivo cujos dados e meta-dados estão prontos para serem reproduzidos na aquisição simulada. Neste novo arquivo apenas os eventos relativos às tarefas motoras ME e MD estão contemplados, sendo desconsideradas todas as informações acerca de outras tarefas motoras.

Algo importante a se destacar é que o processo de conversão só é necessário uma única vez por sujeito disponível e, com isso, a reprodução a partir dos sinais de EEG deste sujeito pode ser realizada com a simples identificação do local do arquivo resultante, ao definir diretamente a opção indicada pelo passo 6. Isso também é verdade para o caso de simulações a partir de coletas anteriores, realizadas no próprio AutoBCI, em que os dados e meta-dados já são gerados no formato adequado para processamento e, portanto, os para tanto os passos de 1 a 5 na Figura 42 podem ser desconsiderados.

Em ambas as abordagens de aquisição, a taxa de amostragem é um componente crucial no processo e coleta. Na aquisição real esse componente é controlado pelo próprio amplificador que amostra os sinais em uma taxa predefinida, cabendo ao sistema apenas ler o canal de entrada desses sinais e sincronizar os eventos do protocolo experimental. Na aquisição simulada, porém, a amostragem artificial dos sinais passa também a ser controlada pelo módulo de aquisição do AutoBCI de modo a respeitar a amostragem original dos dados de reprodução. Para tanto, o simulador extrai do arquivo de reprodução um vetor com P amostras (1 amostra por canal) a cada intervalo de tempo $\frac{1}{F_s}$ e o envia para a etapa subsequente (ver Figura 30), repetindo esse processo até a última amostra no arquivo.

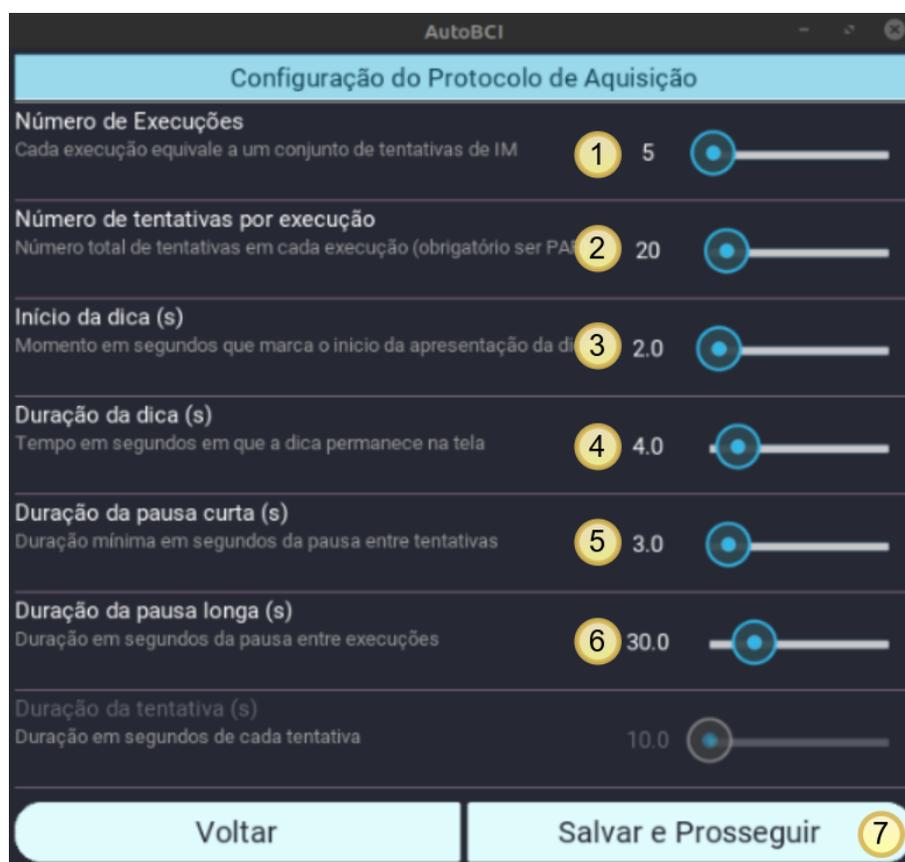
Conforme abordado na seção 3.1 a aquisição típica na fase de treinamento de sistemas ICM-IM baseia-se em um protocolo experimental com instruções bem definidas aos usuários sobre o tipo de tarefa motora a ser executada em cada uma de suas repetições. Os principais objetivos neste processo são: (i) treinar os usuários na modulação satisfatória da atividade cerebral e; (ii) obter um conjunto de exemplos rotulados para treinamento do modelo de classificação.

Nesse sentido, a fim de possibilitar a extração das épocas de calibração, de acordo com o processo detalhado na seção 3.2.1.1, uma das funções executadas pelo módulo de aquisição no AutoBCI é o gerenciamento do protocolo experimental antes e durante a

coleta. O tipo de protocolo implementado no sistema corresponde à uma versão do já conhecido protocolo *Graz* (PFURTSCHELLER; SILVA, 1999), amplamente discutido neste trabalho e adotado na literatura.

Uma vez definido o modo de aquisição pelo usuário, real ou simulado, através dos passos 5 ou 7 nas Figura 41 e 42, respectivamente, o próximo estágio para execução da coleta propriamente dita consiste na configuração da cronologia de eventos do protocolo, disponível no sistema por meio da interface mostrada na Figura 43.

Figura 43. Interface de configuração do protocolo experimental no AutoBCI. A sequência numérica indica os passos a serem seguidos pelo usuário para definição do número de execuções e tentativas para cada tarefa motora bem como a cronologia de eventos de coleta em cada tentativa.



Fonte: Autoria própria

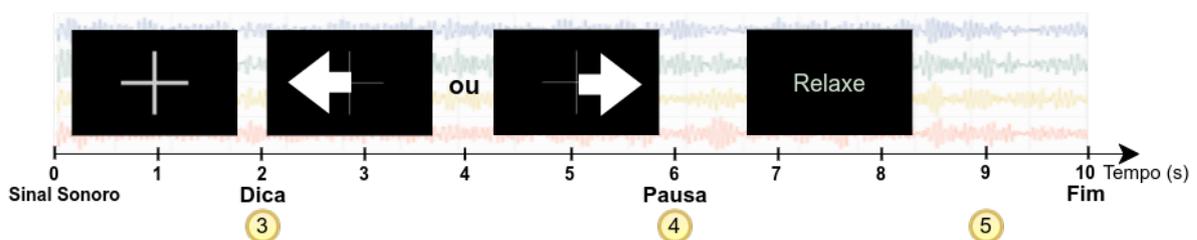
Primeiramente, o usuário define o número de execuções e o número de tentativas por execução (passos 1 e 2). Vale ressaltar que o produto entre esses dois parâmetros define o número total de épocas que poderão ser extraídas dos sinais de EEG a resultantes da coleta a partir das dicas. Além disso, como o parâmetro em (2) indica o número total de tentativas esse valor deve ser para para contemplar o mesmo número de tentativas para as duas classes de tarefas motoras disponíveis, mão direita e mão esquerda.

Os passos 3 e 4 definem o momento em que a dica é apresentada ao usuário e a

permanência da dica na tela que também equivale ao período para realização da tarefa motora indicada, respectivamente. Por fim, os parâmetros 5 e 6 estabelecem a pausa mínima entre duas tentativas e a pausa entre duas execuções, respectivamente. Um tempo adicional, que assume um valor aleatório entre 0 e 1 definido automaticamente pelo sistema a cada tentativa é somado ao valor definido em (5) a fim de pausa mínima é adicionada por um valor aleatório entre 0 e 1 em cada tentativa conforme sugerem Tangermann et al. (2012). Nota-se que a duração de cada tentativa é calculada automaticamente.

Ao prosseguir com a coleta (passo 7), o módulo de aquisição estará pronto para inicializar o fluxo de dados a partir do amplificador ou do arquivo de reprodução. Uma vez iniciada, o módulo de aquisição iniciará a apresentação das instruções visuais ao usuário com base nos parâmetros definidos nos passos 3 a 5. Uma sequência de dicas de ambas as tarefas motoras é construída e embaralhada aleatoriamente, de modo a se ter sempre $\frac{N_{trials}}{2}$ dicas por classe, com N_{trials} denotando o número de tentativas em uma única execução. A Figura 44 apresenta as telas apresentadas ao usuário em uma tentativa cuja cronologia do protocolo é definida com base nos valores representados na Figura 43 anterior.

Figura 44. Exemplo de sequência de eventos, equivalente à uma única tentativa de MI, apresentada ao usuário durante a coleta de sinais de EEG usando o protocolo experimental. No início de cada tentativa um sinal sonoro breve é tocado concomitante a apresentação de uma cruz fixa na tela, que neste caso permanece na tela por 2 segundos. Em seguida a dica na forma de uma seta para a direita ou para esquerda define a tarefa motora esperada pelos próximos 4 segundos. Em $t = 6$ o usuário recebe instruções para relaxar durante a pausa curta, até que o processo seja reiniciado na próxima tentativa a partir de $t = 10$.



Fonte: Autoria própria

Ao longo de toda a aquisição, o fluxo de sinais de EEG é armazenado na memória do computador. O índice de amostragem correspondente ao exato momento em que a dica é apresentada em cada N_{trials} tentativa de cada execução é usado para identificar o início do segmento de EEG associado ao rótulo da tarefa motora. O controle dos eventos sincronizados ao fluxo de amostragem com a associação dos trechos dos sinais à realização da MI é um processo fundamental na estrutura de sistemas BCI-MI síncronos ao permitir o uso das marcações para extração das épocas de calibração dos algoritmos.

Concluídas todas as execuções definidas previamente, o fluxo de sinais é interrompido

e a aquisição é encerrada com o armazenamento dos sinais e dos meta-dados em arquivo único em formato (*.npy*). Os meta-dados é representado como um dicionário de dados o qual mantém tanto as marcações dos eventos quanto as informações gerais da coleta, tais quais: identificação dos canais utilizados, frequência de amostragem, número de execuções, número de tentativas por tarefa, rótulos numéricos usados para identificar as classes de MI, data e hora da coleta.

6.2 Módulo de Processamento

O módulo de processamento do AutoBCI implementa a cadeia de sub-bandas apresentada na seção 5.2.5, contudo conforme conveniência do usuário pode ser configurada de forma a compreender somente as etapas da bordagem de banda única o que, naturalmente, não inclui as rotinas que implementam as camadas de pontuação e fusão de sub-bandas.

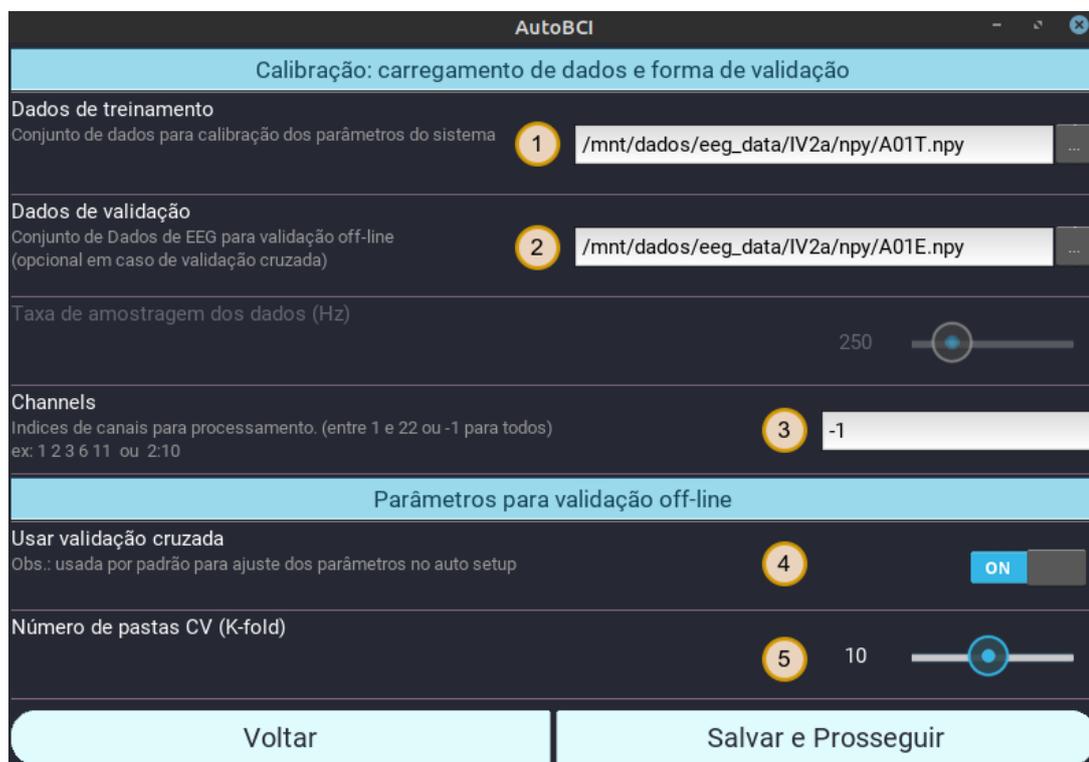
De todo modo, conforme mencionado anteriormente e ilustrado na Figura 29 o módulo gerencia todas as etapas de processamento compreendidas a partir da aquisição até a saída do classificador que antecede a geração do comando para a aplicação virtual e atua nas duas fases de operação do sistema, calibração e execução.

Na fase de calibração os parâmetros dos algoritmos na cadeia de processamento são ajustados de forma *off-line* para se obter o modelo de classificação a partir de um conjunto de épocas de EEG coletadas previamente e devidamente rotuladas. Uma vez realizada a aquisição dos sinais usando o protocolo experimental, o que culmina no salvamento dos dados e meta-dados no disco, o usuário pode iniciar o processo de calibração do sistema definindo os requisitos da interface apresentada na Figura 45.

A tela na Figura 45 representa o primeiro estágio do processo de calibração do sistema onde o usuário fornece, principalmente, o arquivo (resultante de uma coleta anterior) de onde serão extraídas as épocas de EEG para o ajuste dos parâmetros do modelo de classificação (passo 1) e os índices de canais que serão considerados na calibração (passo 2). Assim que o usuário informa a fonte dos sinais para calibração o sistema realiza uma checagem no arquivo e atualiza automaticamente os índices de canais e taxa de amostragem.

Além de fornecer as fontes de dados para calibração, o usuário deve optar pelo modo de validação *off-line* do modelo obtido ao final da calibração. A validação *off-line* é realizada a partir de um segundo conjunto de épocas, não consideradas na calibração, extraídas de outro arquivo de coleta informado no passo 2. Alternativamente o usuário pode optar por realizar uma validação cruzada, processo em que, conforme apresentam Clerc, Bougrain e Lotte (2016a), baseia-se na sub-divisão dos dados em N_k -pastas (passo 5), as quais são usadas para calibrações e validações sucessivas ao longo de N_k iterações.

Figura 45. Interface de configuração inicial do procedimento de calibração do modelo de classificação no AutoBCI.



Fonte: Autoria própria

Ao optar pela validação cruzada, o fornecimento do arquivo do passo 2 é opcional e o processo de treinamento e teste em cada iteração é realizada a partir do arquivo fornecido no passo 1 somente. Se ainda assim o usuário fornecer o segundo arquivo de dados, as épocas e respectivos rótulos extraídos dos dois arquivos fornecidos serão concatenadas formando um conjunto único de dados usado na calibração e validação cruzada.

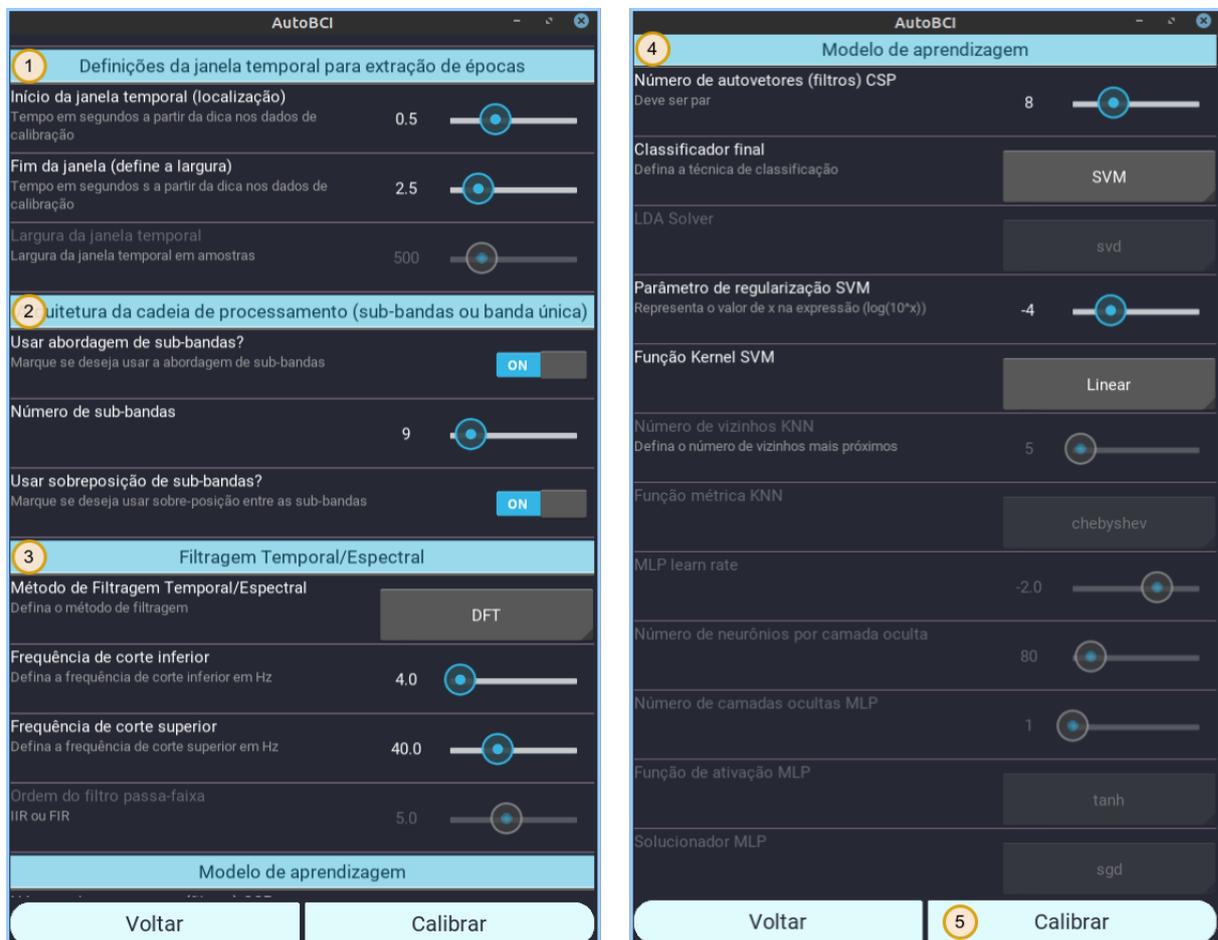
Ao prosseguir com a calibração, uma nova interface é apresentada ao usuário, desta vez para configuração dos algoritmos nas etapas da cadeia de processamento do sistema. Este é um ponto crucial na fase de calibração e acomoda uma das principais contribuições deste trabalho, o método de configuração automática dos hiperparâmetros, *auto setup*, cujos detalhes foram discutidos ao longo do Capítulo 5.

O AutoBCI foi implementado para aceitar dois modos de configuração distintas: (i) a manual, onde tradicionalmente e de forma empírica, o usuário define um a um os hiperparâmetros necessários para construção do modelo de classificação ou; (ii) a automática onde o *auto setup* atua, abstraindo do usuário a tarefa de configuração de todos os hiperparâmetros requeridos.

6.2.1 Configuração manual do sistema

O primeiro modo de configuração consiste na definição manual dos parâmetros em cada etapa da cadeia de processamento implementada no AutoBCI. A Figura 46 representa a interface de configuração disponível no sistema onde o usuário pode sintonizar manualmente cada um dos blocos de parâmetros agrupados conforme a etapa na cadeia a qual pertencem. A interface de configuração é separada em duas partes na Figura somente para fins de visualização completa das opções.

Figura 46. Interface de seleção e configuração manual dos algoritmos para compor a cadeia de processamento do AutoBCI. Os grupos de hiperparâmetros são agrupados conforme as etapas de processamento e os valores definidos na instância apresentada correspondem às definições da cadeia típica de sub-bandas sugerida por (NOVI et al., 2007)



Fonte: Autoria própria

Como nota-se as primeiras configurações (grupo 1) estão associadas às propriedades J_d (localização) e J_l (largura) da janela temporal (J) em relação ao momento da dica no protocolo configurado na interface da Figura 43. Tais definições são usadas pelo sistema na extração das épocas de EEG dos dados fornecidos anteriormente que servirão de exemplos para o treinamento supervisionado e para validação do modelo de classificação.

No grupo 2 estão os hiperparâmetros que definem o uso ou não de sub-bandas, onde o usuário, caso opte pela cadeia mais sofisticada, deve fornecer a quantidade de sub-bandas (N_s) a ser considerada na filtragem das épocas extraídas. Além disso, o usuário pode optar ou não pela sobreposição de 50% entre sub-bandas consecutivas. É importante dizer que, as atribuições dos hiperparâmetros do grupo 2 vão determinar o tipo de configuração manual, i. e. CMSB ou CMBU.

Os parâmetros de filtragem, como o tipo de filtro utilizado (FFT, FIR ou IIR) e as frequências de corte inferior (F_l) e superior (F_u) são definidos no grupo 3 na interface da Figura 46, em que, caso à opção do usuário seja um dos filtros digitais de resposta impulsiva este também deve informar a ordem desse filtro.

Outro ponto a se destacar é que na definição do algoritmo FFT para filtragem dos sinais a resolução que definem frequência, δ_f , a qual define o espaçamento entre *bins* de frequências consecutivos, é calculada automaticamente pelo sistema conforme o argumento de J_l e a frequência de amostragem dos sinais de entrada, F_s .

Por fim, no conjunto de hiperparâmetros do grupo 4 o usuário define as opções para extração de características nos sinais por meio da seleção do número de filtros espaciais CSP, assim como escolhe uma das 5 técnicas de classificação incorporadas ao sistema sintonizando em seguida os hiperparâmetros associados ao classificador escolhido.

Vale lembrar que a escolha das técnicas de classificação adotadas no escopo do AutoBCI foram definidas ainda na seção 3.2.4 e correspondem às técnicas comumente destacadas pela literatura correlata como as mais eficazes na classificação de padrões de IM em sinais de EEG (LOTTE et al., 2007; LOTTE et al., 2018; NICOLAS-ALONSO; GOMEZ-GIL, 2012; BASHASHATI et al., 2015).

Ao observar a quantidade de informações a serem fornecidas pelo usuário na calibração manual do sistema, é notório que esse procedimento exige um conhecimento prévio de cada etapa do processamento em sistemas de ICM-IM bem como das diversas técnicas de processamento de sinais e aprendizado de máquina disponíveis na plataforma.

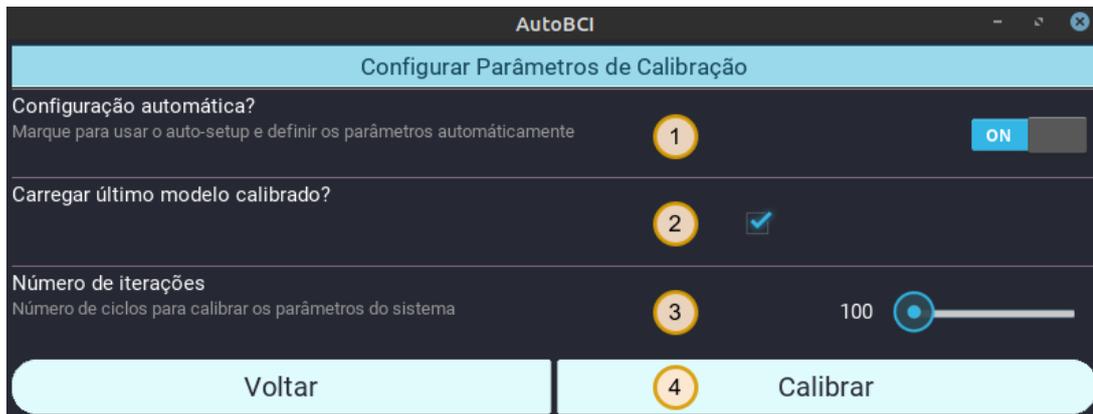
6.2.2 Configuração automática do sistema (*auto setup*)

Como forma de abstrair do usuário a necessidade de conhecimento profundo de como funcionam as etapas de pré-processamento e facilitar o processo de configuração do módulo de processamento na plataforma desenvolvida, o *auto setup* é capaz de sintonizar automaticamente os valores nos múltiplos hiperparâmetros apresentados na Figura 46.

Para tanto, o método realizada um processo de otimização *Bayesiana* que determina as instâncias ótimas desses hiperparâmetros com base nas características de cada usuário expressada nos sinais de EEG (descrição na seção 5.2.6.1). A opção pelo uso do método de

configuração automática no AutoBCI está disponível por meio da interface mostrada na Figura 47.

Figura 47. Passos para configuração automática da cadeia de processamento no AutoBCI. Ao ativar o *auto setup* o sistema seleciona, configura e valida iterativamente múltiplas combinações de técnicas de processamento de forma a compor uma cadeia de processamento adequada ao usuário



Fonte: Autoria própria

A configuração dos sistema para uma calibração automática do sistema (passo 1) é muito simplificada em relação à configuração manual e exige do usuário apenas a definição do número de iterações (N_{iter}) da otimização *Bayesiana* na busca pelo conjunto ótimo de hiperparâmetros do usuário, \mathbf{h}^* .

De forma adicional, o sistema permite o uso da distribuição de modelos provenientes de uma otimização *Bayesiana* anterior, onde a busca por novas instâncias hiperparamétricas ótimas será iniciada a partir das instâncias ótimas da busca mais recente cujos dados foram armazenados pelo próprio sistema e associados à seção do usuário automaticamente.

A Figura 48 foi extraída durante o processo de ajuste dos hiperparâmetros realizado pelo AutoBCI. As linhas indicam as instâncias candidatas do conjunto de hiperparâmetros em cada iteração da busca *Bayesiana*, as quais são usadas para treinar modelos individuais, $\mathcal{M}_{\mathbf{h}_i}$, e validá-los usando os dados de treinamento fornecidos na etapa anterior em um processo de validação cruzada de 5-pastas conforme descrito na seção 5.2.6.1. O destaque em amarelo indica o percurso percorrido pela otimização e a melhor valor obtido entre as funções objetivo, $g(\mathbf{h}_i)$, calculadas até então (acurácia média de classificação).

Ao fim do processo apresentado na Figura 48, o sistema é configurado automaticamente usando os valores no conjunto ótimo de hiperparâmetros, ou seja, as instâncias hiperparamétricas responsáveis pela melhor acurácia média esperada (acurácia de treinamento).

Um detalhe importante implícito no *auto setup*, consiste no uso do algoritmo da FFT como método de filtragem temporal padrão durante a otimização a fim de torná-la

Figura 48. Processo de busca pelo conjunto ótimo de hiperparâmetros a partir da busca *Bayesiana* promovida pelo método *auto setup*. Diferentes instâncias da cadeia de processamento são avaliadas a fim de se obter uma configuração que maximize a acurácia esperada.

Fonte: Autoria própria

mais eficiente, especialmente em iterações em que a instância de $N_s > 1$ representa o uso de sub-bandas. O ganho em eficiência possibilita, por exemplo, a ampliação da busca, ou seja, a definição de um valor maior para N_{iter} com um ônus reduzido quanto ao tempo de calibração em relação à filtragem usando um dos filtros digitais incorporados, IIR e FIR.

6.2.3 Ajuste e validação *off-line* do modelo de classificação

Conforme amplamente discutido ao longo deste documento, o objetivo da fase de calibração é obter um modelo de classificação capaz de reconhecer padrões que descrevam o fenômeno de IM associado à cada classe. Nesse sentido, independentemente do tipo de configuração escolhida, manual ou automática, após a configuração do sistema o modelo de classificação definitivo é ajustado a partir do conjunto completo de treinamento fornecido pelo usuário e com base nos hiperparâmetros definidos. Os parâmetros do modelo obtido são armazenados na memória do computador e associado com a seção do usuário podendo ser usado, à qualquer tempo, para classificar novos padrões de IM similares em segmentos de EEG até então desconhecidos.

A validação *off-line* do modelo é realizada com base no arquivo de dados para validação, também fornecido pelo usuário por meio do passo 2 da interface mostrada na Figura 45. Os sinais de EEG em cada ensaio no arquivo de dados fornecido são segmentados usando a janela temporal configurada no sistema e as épocas resultantes são submetidas às etapas da cadeia de processamento e ao modelo de classificação devidamente calibrado.

O processo de validação é realizado no AutoBCI assim que o ajuste do modelo é encerrado sem requerer qualquer ação específica do usuário para tal, além do envio das configurações de calibração. A Figura 49 apresenta os resultados do processo de validação mostrado ao usuário em forma de janela *pop-up*.

Figura 49. Interface de apresentação dos resultados da validação *off-line* do modelo de classificação no AutoBCI



:: RESULTADOS DE VALIDAÇÃO OFF-LINE ::	
Acurácia [Treino]:	97.22%
Acurácia [Teste]:	92.36%
Kappa [Teste]:	0.8472

Fonte: Autoria própria

Como é possível notar, são apresentadas as acurácias de classificação obtidas ao aplicar o modelo ajustado tanto nos dados de treinamento (\mathcal{D}_T) quanto nos dados de validação (\mathcal{D}_V). Adicionalmente é calculado o coeficiente *Kappa*, definido com base na acurácia de validação, ac_V (THOMPSON; BLAIN-MORAES; HUGGINS, 2013).

Assim como os parâmetros do modelo de classificação, os resultados da validação *off-line* são armazenados para cada usuário do sistema a fim de que possam ser utilizados pelo módulo de controle durante a fase de operação *on-line*, para além da aplicação em épocas de EEG agrupadas em um conjunto de validação.

6.3 Módulo de Controle

O módulo de controle é o terceiro componente da arquitetura geral do AutoBCI ilustrada na Figura 29. Sua função é prover ao usuário a possibilidade de controlar uma aplicação virtual usando apenas a imagética motora das mãos direita e esquerda e para tanto sua implementação contempla um conjunto de métodos e interfaces que possibilitam a integração entre os demais módulos do sistema e a aplicação.

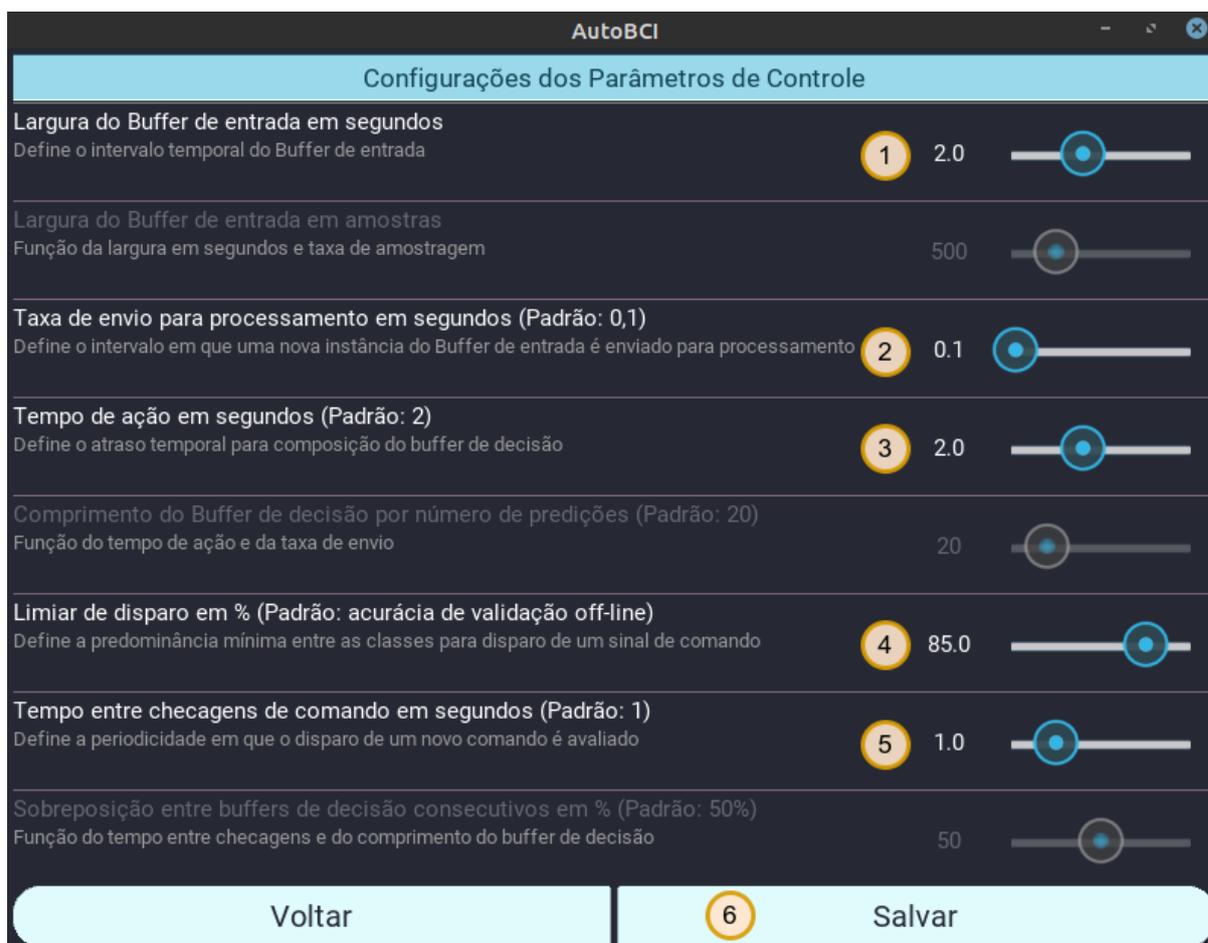
A principal função do módulo de controle é fornecer mecanismos de tradução da saída do módulo de processamento em sinais de comando para a aplicação durante a fase de execução *on-line* do sistema. Sendo assim, o modelo de classificação devidamente calibrado é aplicado nos sinais fornecidos em tempo real pelo módulo de aquisição, passa pela cadeia de processamento e a saída do classificador é convertida em comandos de controle de acordo com o processo ilustrado na Figura 37.

Tendo em vista que a tradução das saídas do classificador em comandos para a aplicação exige a configuração de uma série de parâmetros no sistema, conforme mencionado na seção 5.2.7, o AutoBCI engloba um conjunto de telas que possibilitam a personalização do módulo de controle conforme as preferências do usuário.

Dentre os parâmetros personalizáveis no sistema, estão os parâmetros genéricos de controle, que foram desvinculados dos parâmetros específicos da aplicação como forma de

tornar o sistema escalável no sentido de incluir novas aplicações no futuro sem a necessidade de alteração no código central do módulo de controle. A Figura 50 representa a interface disponível no AutoBCI para configuração dos parâmetros de controle.

Figura 50. Interface de configuração dos parâmetros de controle no AutoBCI. As definições são usadas pelo sistema na tradução das saídas do módulo de processamento em sinais de comando para a aplicação virtual



Fonte: Autoria própria

O parâmetro identificado como passo 1 define a largura L do *buffer* de entrada B , que conforme definido no capítulo anterior, o qual armazena temporariamente as amostras fornecidas pelo módulo de aquisição e as envia periodicamente para classificação usando o modelo ajustado na fase de calibração.

A periodicidade em que esses segmentos temporários em B são enviados para classificação é definida pelo passo 2. Por padrão, a taxa de envio para classificação é de 10 segmentos por segundo, $\delta_t = 0,1$ e a largura L de B é definida com o mesmo valor de J_d atribuído pelo usuário na configuração manual ou estimado usando a configuração automática.

Tanto a taxa de envio para classificação quanto o tempo de ação no passo 3,

t_a , determinam a quantidade de rótulos de saída da classificação que será usada para composição do *Buffer* de decisão d e o limiar de disparo no passo 4 estabelece o quão predominante os rótulos associados à uma classe deve ser em relação à outra classe para que seja gerado um comando para a aplicação. Em outras palavras, o limiar de disparo, denotado por δ_{lim} representa um *gatilho* para a aplicação e recebe por padrão o percentual de acurácia de validação, ac_V , calculado durante a validação *off-line* do modelo de classificação do usuário.

Por fim, o passo 5 na Figura 50 define o tempo em segundos entre checagens do limiar de comando, ou seja, o intervalo entre dois (possíveis) envios de comando à aplicação. A razão entre o tempo de checagem, t_c , e o tempo de ação, t_a determinam o grau de sobreposição entre os rótulos usados na tomada de decisão sobre o comando.

Além dos parâmetros de controle configuráveis por meio da interface na Figura 50, uma série de outros parâmetros também devem ser definidos. Desta vez os parâmetros associados especificamente à aplicação virtual, a qual já foi apresentada na seção 5.3.2.1 e consiste no jogo ICM Space Game. Para tanto, têm-se a interface da Figura 51.

Acerca das configurações da aplicação ICM Space Game, especificamente, o primeiro parâmetro a ser definido (passo 1) representa o número de sessões de controle, as quais são separadas por um intervalo em segundos (passo 2) e contemplam, cada qual, um número de tentativas de controle do cursor até o alvo definido pelo passo 3. O tempo de espera no início de cada tentativa é definido no passo 4.

Um ponto a se destacar é que o número de tentativas equivale ao número de alvos a serem atingidos por MI, sendo que em metade das tentativas em uma sessão haverão alvos posicionados à direita da tela e metade à esquerda, como forma de se manter a estratificação entre as tarefas motoras esperadas do usuário.

As dimensões da tela de jogo podem ser selecionadas no passo 5 e são importantes para o cálculo das proporções nos passos 6 e 7, as quais estabelecem o posicionamento dos alvos quando estão à direita ou à esquerda da tela, respectivamente. O passo 8 define o deslocamento em pixels do cursor na tela em pixels à cada comando enviado enquanto que no passo 9 a velocidade com que esse deslocamento é realizado.

Finalmente, o passo 9 determina a velocidade de aproximação do obstáculo (asteróide) e, conseqüentemente, delimita o tempo que o usuário tem para modular a atividade cerebral e induzir a geração de comandos sucessivos de modo que o cursor saia da zona de impacto com o obstáculo.

Vale mencionar que a personalização, tanto dos parâmetros genéricos de controle quanto dos parâmetros específicos da aplicação, por parte do usuário é opcional, haja vista que todos os parâmetros possuem definições padrão previamente configuradas na

Figura 51. Interface de configuração dos parâmetros específicos do ICM Space Game. As definições controlam o ambiente e a jogabilidade da aplicação virtual



Fonte: Autoria própria

plataforma. Isto posto, e uma vez definidos todos os parâmetros, o AutoBCI está pronto para iniciar as sessões de controle. As telas na Figura 52 mostram diferentes tentativas de controle do cursor durante uma sessão do ICM Space Game no AutoBCI.

Após o início da sessão o cursor (nave) é posicionado em um dos lados da tela (escolha aleatória) seguindo as proporções definidas durante a configuração dos parâmetros representados pelos passos 6 e 7 na Figura 51. Após o tempo de espera, em que o obstáculo (asteroide) permanece estático mas visível no mesmo lado do cursor na tela, é esperado que o usuário comece a gerar os padrões de MI de uma das mãos, correspondentes ao lado oposto da tela.

A tela identificada pelo numeral 1 ilustra o momento em que a primeira tentativa

Figura 52. Telas extraídas durante múltiplas tentativas de controle da aplicação virtual usando IM das mãos direita e esquerda no AutoBCI. A sequência delimita o início e o fim de uma única sessão de controle, da primeira de 20 tentativas até a apresentação dos resultados ao usuário



Fonte: Autoria própria

é iniciada. Ambos os objetos, nave e asteroide, permanecem estáticos na tela. Na tela 2, passado o tempo de espera, o asteroide começa a se movimentar no sentido vertical na velocidade constante definida previamente pelo usuário e em direção à parte inferior da tela. Ao mesmo tempo o cursor passa a estar apto a receber comandos com base nos padrões gerados pelo usuário e classificados usando o modelo ajustado na plataforma. A tela 3 retrata a 14ª tentativa de controle da mesma sessão em que, desta vez, o alvo aparece do lado direito da tela.

O objetivo em cada tentativa é conduzir a nave até o alvo (barra amarela nas telas 1, 2 e 3) no menor tempo possível, encerrando assim a tentativa, ou, pelo menos, conduzir a nave para uma região em que o impacto com o asteroide é evitado, sendo que neste caso a tentativa é encerrada após o asteroide percorrer toda a extensão vertical da tela. Ao atender uma dessas condições um ponto é contabilizado enquanto que na ocorrência do impacto a pontuação não é incrementada.

Ao final da execução de todas as tentativas pré-configuradas no sistema a tela 4 é apresentada ao usuário informando o número de tentativas, a pontuação final obtida na sessão e o tempo decorrido entre a primeira e a última tentativa. Uma nova sessão é iniciada após a pausa longa.

Conforme explanado na seção 5.2.4, o AutoBCI inclui o modo de aquisição simulada como alternativa à aquisição real usando um amplificador de EEG. Na fase de execução *on-line* o algoritmo de aquisição simulada pode ser usado para fornecer as amostras de EEG ao *buffer* B sob-demanda, tendo como fonte ensaios de um conjunto de sinais coletados previamente cujas classes de IM associadas são conhecidas a partir dos meta-dados armazenados.

No contexto do controle do ICM Space Game isso significa que enquanto o alvo é apresentado no lado esquerdo da tela o sistema de aquisição simulada envia amostras pertencentes à ensaios relacionados IM da mão esquerda e vice-versa, como forma de o engajamento do usuário na respectiva tarefa mental.

A Figura 37 citada anteriormente, detalha o processo em que as classificações resultantes do processamento dos sinais em tempo real parametrizam a tomada de decisão sobre o envio do comando, baseado também nas configurações dos parâmetros nas interfaces das Figuras 50 e 51. Já a Figura 53 apresentada a seguir, é proposta com o intuito de ilustrar o fluxo de informações no sistema durante uma sessão de controle usando o sistema de aquisição simulada.

Os registros remetem ao processo de envio das amostras de determinada classe ao *buffer* B de entrada conforme a posição do alvo em uma dada tentativa de controle. Os registros marcados pelos dizeres em inglês *buffer receive LEFT* indica que amostras associadas à realização de IM da mão esquerda estão sendo enviadas ao *buffer* de entrada, após a constatação de que o alvo está posicionado no lado esquerdo da tela. O oposto é verdadeiro em registros "*buffer receive RIGHT*".

Enquanto isso, os registros iniciados pela palavra *check*, denotam uma checagem ao *buffer* de decisão, *d*, cujos elementos no momento da checagem correspondem aos rótulos provenientes do classificador entre colchetes, onde 1 representa MI da mão esquerda e 2 representa MI da mão direita. A checagem é realizada a cada t_c segundos para tomada de decisão sobre o envio do comando. A instrução *target* indica o lado do alvo na tela e, portanto, também indica o comando esperado no momento da checagem.

As últimas linhas entre os registros na Figura 50 são apresentadas ao final de cada sessão e consolidam os dados contabilizados durante as tentativas de controle, os quais são úteis para avaliar o desempenho do sistema durante o controle simulado.

Figura 53. Registros em inglês obtidos durante uma sessão de controle usando o sistema de aquisição simulada. Os registros relatam o processo de envio de amostras ao *Buffer* de entrada pelo simulador a partir da leitura do posicionamento do alvo (*target*) bem como a composição do *buffer* de decisão pelas saídas de classificação a cada checagem do limiar de comando

```
vitor entrou (True)
Acurácia configuração atual : 92.36
Connecting to Acquisition Simulator
Início do streaming, amostragem de classe aleatória... classe 0 escolhida
Início do streaming, amostragem de classe aleatória... classe 1 escolhida
Wait ...
Início do streaming, amostragem de classe aleatória... classe 0 escolhida
<< buffer receive LEFT <<
<< buffer receive LEFT <<
<< buffer receive LEFT <<
check 1 :: [1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1] :: target=[1]
<< buffer receive LEFT <<
check 2 :: [1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 2, 2, 2, 2, 2, 2, 2, 2] :: target=[1]
check 3 :: [2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 1, 1, 1, 1, 1, 1, 1, 1] :: target=[1]
<< buffer receive LEFT <<
      :
      :
      :
>> buffer receive RIGHT >>
check 123 :: [1, 1, 1, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2] :: target=[2]
>> buffer receive RIGHT >>
check 124 :: [2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2] :: target=[2]
check 125 :: [2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2] :: target=[2]
>> buffer receive RIGHT >>
Streaming stopped. Closing connection to hardware
Stopping streaming...
Wait for buffer to flush...
Closing Serial...
nrounds: 20, | score: 16 | util time: 204
nchecks: 125 | ncommands: 100
Full time: 270.65 268.250000000000006
```

Fonte: Autoria própria

7 RESULTADOS E DISCUSSÕES

Este capítulo apresenta e discute os resultados obtidos nas duas categorias de experimentos descritas no Capítulo 5. Os experimentos de teste e validação se complementam com o intuito de validar os módulos do AutoBCI e a proposta de configuração automática da cadeia de processamento, o *auto setup* (AS).

A discussão dos resultados considera os desempenhos obtidos em ambos os cenários experimentais, no comparativo entre o AS e os modos de configuração manual, CMBU e CMSB, tanto em âmbito geral quanto para cada um dos três conjuntos de dados públicos adotados.

O tempo para ajuste dos modelos, o desempenho de classificação *off-line* e a taxa de sucesso no envio de comandos e controle da aplicação virtual são os critérios considerados, todos baseados nas métricas já descritas ao longo do trabalho bem como em problemas exclusivamente binários, com discriminação entre duas classes de IM, mão esquerda (ME) *vs.* mão direita (MD).

Durante a análise dos resultados os usuários do sistema representados pelos 72 sujeitos provenientes das bases públicas de sinais, são identificados numericamente, com os sujeitos do conjunto 2A sendo representados pelos índices de 1 a 9, os sujeitos do conjunto 2B representado pelos índices de 10 a 18 e os sujeitos do conjunto LE representados pelos índices de 19 até 72 .

7.1 Resultados de validação *off-line*

O procedimento de validação *off-line* do sistema, descrito em detalhes na seção 5.3.1, avaliou o desempenho dos modelos de classificação, os quais foram ajustados a partir de uma cadeia de processamento personalizada e configurada automaticamente com o método *auto setup*, na classificação de épocas de EEG agrupadas em um conjunto de validação, \mathcal{D}_V , as quais não foram utilizadas no ajuste dos modelos.

A eficácia dos modelos provenientes da estimativa de hiperparâmetros via *auto setup* é medida no comparativo entre seus desempenhos individuais de generalização e o desempenho de modelos cujos ajustes provém de configurações hiperparamétricas manuais para cadeias de banda única (CMBU) e de sub-bandas (CMSB), definidas pelas instâncias típicas listadas na Tabela 3.

Por serem frequentes na literatura, as abordagens de configuração manual são tomadas como referência e seus desempenhos de generalização, ou seja, na classificação das épocas no conjunto \mathcal{D}_V de cada um dos 72 sujeitos avaliados, são usados como unidades de controle experimental para medir o ganho em acurácia do *auto setup*.

Diante do exposto, a Tabela 4 apresenta as acurácia médias de validação, $acm_{\mathcal{V}}$, obtidas entre os modelos provenientes de cada um dos modos de configuração e considerando os sujeitos em cada uma das três bases de dados públicas adotadas. Os resultados na última linha na Tabela 4 referem-se aos desempenhos médios de todos os 72 sujeitos avaliados, independentemente da base a qual pertencem.

Tabela 4. Média das acurácias de validação, $acm_{\mathcal{V}}$ usando os três modos de configuração (AS, CMBU e CMSB) e para as três bases públicas de sinais consideradas (2A, 2B e LE). O desvio padrão é usado como medida de dispersão entre os sujeitos

	CMBU $_{acm_{\mathcal{V}}}$	CMSB $_{acm_{\mathcal{V}}}$	AS $_{acm_{\mathcal{V}}}$
2A	77,93 ± 16,4	82,25 ± 14,2	88,51 ± 12,5
2B	74,18 ± 13,9	74,91 ± 15,2	82,75 ± 11,9
LE	61,38 ± 12,3	62,09 ± 13,8	75,86 ± 14,7
Todos	65,04 ± 14,4	66,21 ± 15,7	78,30 ± 14,7

Os resultados na Tabela 4 denotam ganhos significativos em acurácia nos modelos originados do *auto setup* em relação à modelos ajustados a partir de configurações manuais de hiperparâmetros. Ao considerar dados de todos os 72 sujeitos, os ganhos médios de 13,3% ± 9,0% em relação à CMBU e de 12,1% ± 7,9% em relação à CMSB sugerem que modelos produzidos a partir da estimativa de hiperparâmetros apresentam uma melhora importante na capacidade preditiva comparada à de modelos provenientes de uma configuração padrão.

Esse cenário também é observado ao analisar a diferença de desempenhos nos três conjuntos de dados individualmente, em que o *auto setup* proporciona ganhos em acurácia entre 14,5% e 8,6% sobre CMBU e entre 13,8% e 6,3% sobre CMSB, sendo ambas as máximas observadas na média entre os 54 sujeitos do conjunto LE.

Para ilustrar, em termos do número de épocas de validação referentes ao conjunto *LE* em específico, essa diferença entre modelos AS em relação aos modelos de configuração manual significou, em média, 28 classificações corretas a mais entre as 200 épocas em $\mathcal{D}_{\mathcal{V}}$, um número expressivo do ponto de vista de ICM-IM uma vez que pode ser determinante no processo de classificação de sinais em tempo real visando o controle da aplicação.

Além de evidenciarem o ganho preditivo a partir do *auto setup*, os resultado também apontam que cadeias de sub-bandas, mesmo que configuradas de maneira manual por instâncias hiperparamétricas universais entre os sujeitos, já apresentam desempenhos de classificação melhores em comparação à cadeias de banda única. Uma das formas de explicar o ganho médio aproximado de 1.3% para todos os sujeitos da abordagem CMSB em relação à CMBU, refere-se ao fato de a primeira usar informações espectrais mais

precisas do padrão cognitivo dos indivíduos ao executarem as tarefas de IM, conforme apresentado na seção 3.2.5.

Portanto, segundo os resultados demonstrados na Tabela 4, o uso de cadeias de sub-bandas somado à aplicação do *auto setup* para estimativa de hiperparâmetros em suas etapas amplifica a capacidade do sistema em reconhecer os padrões que descrevem os fenômenos de IM de ambas as mãos como forma de melhor discriminar a intenção motora do indivíduo.

Ao mesmo tempo em que demonstram a eficácia do *auto setup*, os resultados expressam a capacidade do AutoBCI na adaptação da cadeia de processamento conforme os padrões cognitivos de cada usuário, propiciando a obtenção de modelos de classificação mais eficazes em relação à cadeias de processamento rígidas e inespecíficas do sujeito.

Com o objetivo de investigar a abrangência dos resultados na Tabela 4 e fornecer uma análise mais aprofundada sobre os desempenhos relativos à cada sujeito, os gráficos na Figura 54 correlacionam a performance individual dos 72 modelos AS às performances dos modelos CMBU e CMSB, respectivamente.

Nos dois gráficos da Figura 54 os 72 sujeitos são representados pelos pontos menores em verde, cujas coordenadas expressam as acurácias no conjunto de validação obtidas pelo modelo AS e modelos CMBU e CMSB de referência. Os pontos em destaque na cor azul representam as acurácias médias já reveladas na Tabela 4.

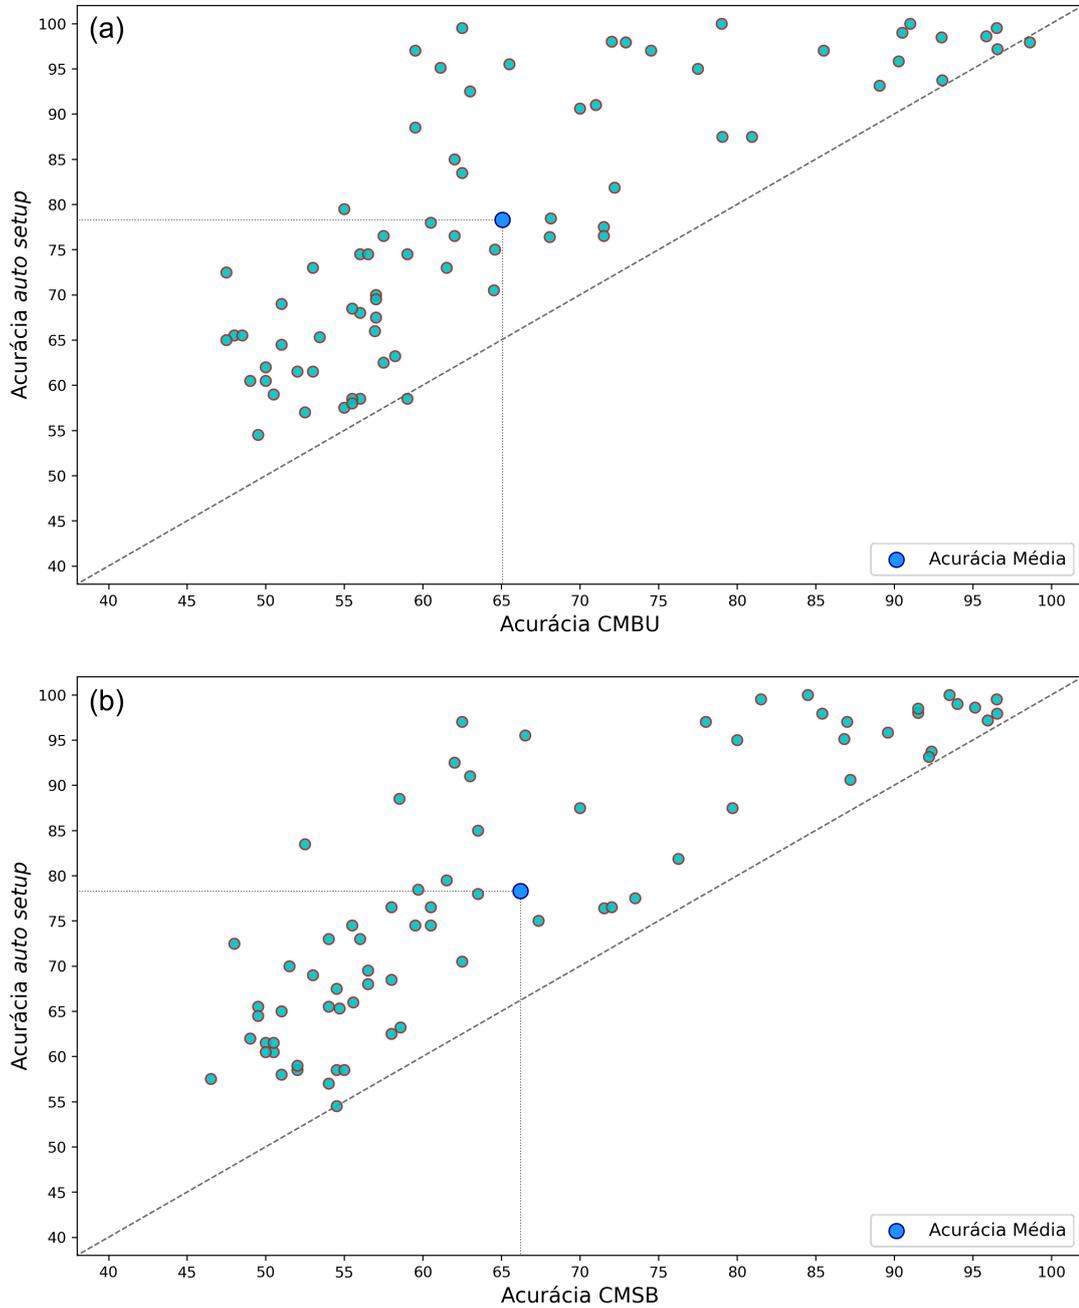
Conclusões em diferentes prismas podem ser retiradas dos gráficos apresentados, especialmente no que tange à capacidade do *auto setup* em maximizar o desempenho de classificação baseado na personalização dos hiperparâmetros do sistema. Primeiro, ao observar a alta dispersão entre os desempenhos em ambos os gráficos, fica evidente que o desempenho de classificação é influenciado sobretudo pela alta variabilidade da atividade cerebral no EEG observada intra e inter-sujeitos.

A discrepância entre as particularidades cognitivas dos sujeitos, retratada pelas acurácias de seus respectivos modelos de classificação, demonstra que, mesmo usando um método de otimização hiperparamétrica e técnicas sofisticadas de processamento, reconhecer os padrões que descrevem a intenção de cada indivíduo não é uma tarefa trivial.

Isto posto, a Figura 54 também demonstra aspectos relevantes da comparação entre o *auto setup* e a configuração manual. Em ambos os gráficos, nota-se que para a maior parte dos sujeitos os ganhos médios discutidos anteriormente refletiram nas validações individuais, com poucos casos em que o modelo ajustado via *auto setup* significou perda na capacidade de generalização em relação à modelos parametrizados usando configurações típicas (pontos abaixo da linha diagonal).

Precisamente, 97,2% das validações de sujeitos representadas na Figura 54-a mos-

Figura 54. Dispersão das acurácias de classificação considerando todos os 72 sujeitos avaliados e comparativo individual entre os respectivos desempenhos obtidos com modelo AS e modelos CMBU (a) e CMSB (b).



Fonte: Autoria própria

traram alguma melhora de desempenho a partir de modelos ajustados com o *auto setup* em relação à modelos decorrentes de CMBU. Os desempenhos de configurações típicas de banda única dos sujeitos 3 e 42 superaram em 0,5% e 0,7%, respectivamente, os desempenhos do *auto setup*, com ambos significando 1 época a mais corretamente classificada conforme o número de elementos \mathcal{D}_V das bases 2A e LE, às quais os dados pertencem.

Enquanto isso, ao considerar as validações na Figura 54-b, o sujeito 71 foi o único caso

em que a configuração típica de sub-bandas obteve a mesma capacidade de generalização em relação ao modelo ajustado com AS, em todos os demais a acurácia do modelo AS superou a do respectivo modelo CMSB. Assim, para os dados de 98,6% dos sujeitos houve ganho de desempenho do *auto setup* sobre modelos CMSB.

Vale destacar que, um dos três casos em que modelos provenientes do *auto setup* não foram capazes de maximizar o desempenho de generalização, caracteriza dados de um sujeito com notória capacidade em modular a atividade cerebral e gerar os padrões cognitivos necessários para discriminação entre as classes de IM. Prova disso é que, independentemente da abordagem de configuração, todos os desempenhos obtidos para o sujeito 3 superam os 96,5% em acurácia, nível de desempenho também observado em trabalhos correlatos (LOTTE; GUAN, 2011; ANG et al., 2012a).

Por outro lado, os sujeitos 42 e 71, ambos pertencentes à base de dados LE, foram avaliados pelos autores do próprio estudo em que os dados foram disponibilizados publicamente em Lee et al. (2019) como indivíduos que apresentam dificuldades natas em aprender a modular a atividade cerebral de forma satisfatória, fenômeno conhecido como analfabetismo em ICM, e portanto, seus modelos normalmente performam próximos à aleatoriedade (i.e. 50% de classificações corretas).

Os ganhos individuais na validação dos demais sujeitos com o *auto setup* denotam a eficácia da estratégia de treinar os modelos de classificação em função de instâncias hiperparamétricas particulares dos sujeitos. Isso é evidenciado especialmente através dos pontos próximos à extremidade superior esquerda em ambos os gráficos na Figura 54 os quais representam os piores desempenhos nas abordagens de referência e que foram notoriamente maximizados pelo *auto setup*.

Dentre os 71 sujeitos cujos modelos AS apresentaram ganho em contraposição à abordagem CMSB, o aumento máximo em acurácia observado foi de 34,5% para os dados do sujeito 53 pertencente à base LE, para o qual o desempenho passou de 62,5% de acerto com configuração manual de sub-bandas para 97,0% usando o *auto setup*, um ganho expressivo ao considerar a não-linearidade em problemas de classificação de IM. O mesmo sujeito representou o ganho máximo em relação à CMBU, desta vez com 37,5% mais épocas corretamente classificadas pelo modelo AS, passando de 119 para 194 acertos na classificação entre 200.

Todos os aspectos discutidos indicam que a melhora no desempenho médio de classificação a partir do uso do *auto setup* não é marginal e ocorre, não de forma isolada, mas generalizada entre os sujeitos, denotando a robustez do método de ajuste automático baseado em configurações individualizadas implementado no AutoBCI.

Uma discussão pertinente dos resultados se dá ao analisá-los no contexto do anal-

fabetismo em sistemas de ICM-IM mencionado anteriormente. Segundo o que definem Ahn et al. (2013), corroborado por Lee et al. (2019), um limite seguro de desempenho para configurar alfabetização em ICM é de 70%, dependendo do volume de dados e das diretrizes no experimento de validação.

Ao adotar esse limiar para categorizar os 72 sujeitos como alfabetizados ou não em ICM-IM em função das acurácias nos três modos de configuração, nota-se que, ao adotar a CMBU no ajuste dos parâmetros de classificação, modelos relativos à apenas 23 sujeitos (i.e. 31,9%) apresentaram desempenho acima de 70%, enquanto que na cadeia de CMSB essa proporção sobe para 34,7%, o que corresponde à 25 sujeitos.

Por outro lado, ao aplicar o *auto setup*, o número de sujeitos considerados alfabetizados aumenta para 46 com uma proporção de 63,9% dos sujeitos avaliados, o que implica um aumento significativo do número de sujeitos considerados aptos à operar sistemas de ICM-IM de forma minimamente satisfatória, conforme as definições supracitadas na literatura.

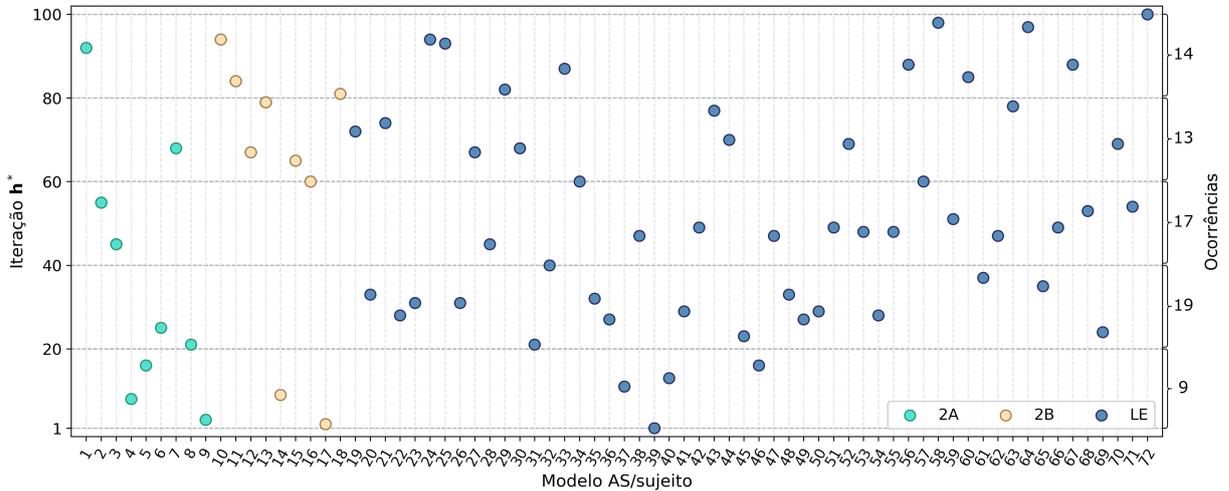
Esse resultado aponta que, em relação ao melhor cenário de configuração manual típica, CMSB, 44,7% dos sujeitos antes considerados analfabetos em ICM-IM passaram à categoria de alfabetizados a partir do modelo construído com base na estimativa de hiperparâmetros realizada no método AS, o que sugere uma ampliação da usabilidade do sistema por um número maior de sujeitos.

Outrossim, ao analisar o número de modelos com alta capacidade de generalização, $ac_v \geq 90\%$, foi revelado que com o *auto setup* 23 dos 72 sujeitos apresentaram capacidade preditiva acima dos 90%, enquanto que para as abordagens CMBU e CMSB esse número foi de 9 e 10, respectivamente. Ou seja, com o *auto setup* um grupo aproximadamente 56% maior de modelos, correspondentes aos pontos na extremidade direita dos gráficos na Figura 54, foi capaz de discriminar com notória eficácia as características entre as classes de IM, sugerindo robustez da estratégia proposta.

Uma vez concluída a discussão comparativa entre as abordagens de configuração, passa-se a analisar os resultados sob o prisma das instâncias hiperparamétricas ótimas de cada sujeito avaliado. Primeiro, uma visão geral sobre o número de iterações (N_{iter}) necessárias para convergência da busca *Bayesiana* no ajuste de cada um dos 72 modelos baseados no *auto setup* é apresentada na Figura 55.

O gráfico ilustra a dispersão dos índices da instância hiperparamétrica candidata cuja saída da função objetivo, representada pela acurácia esperada, obteve seu ponto de máximo em meio às $N_{iter} = 100$ iterações da busca *Bayesiana*. Os pontos 55 são categorizados em cinco intervalos de 20 iterações, em que pode ser avaliada a dispersão das iterações das instancias ótimas de **h**.

Figura 55. Dispersão e distribuição por sujeito dos índices de iterações do *auto setup* cujas instâncias hiperparamétricas foram responsáveis pelo modelo com máxima acurácia esperada. Os pontos representam o número de iterações necessárias para convergência da busca *Bayesiana* para cada modelo/sujeito. As cores diferem os sujeitos quanto à base de dados a qual pertencem

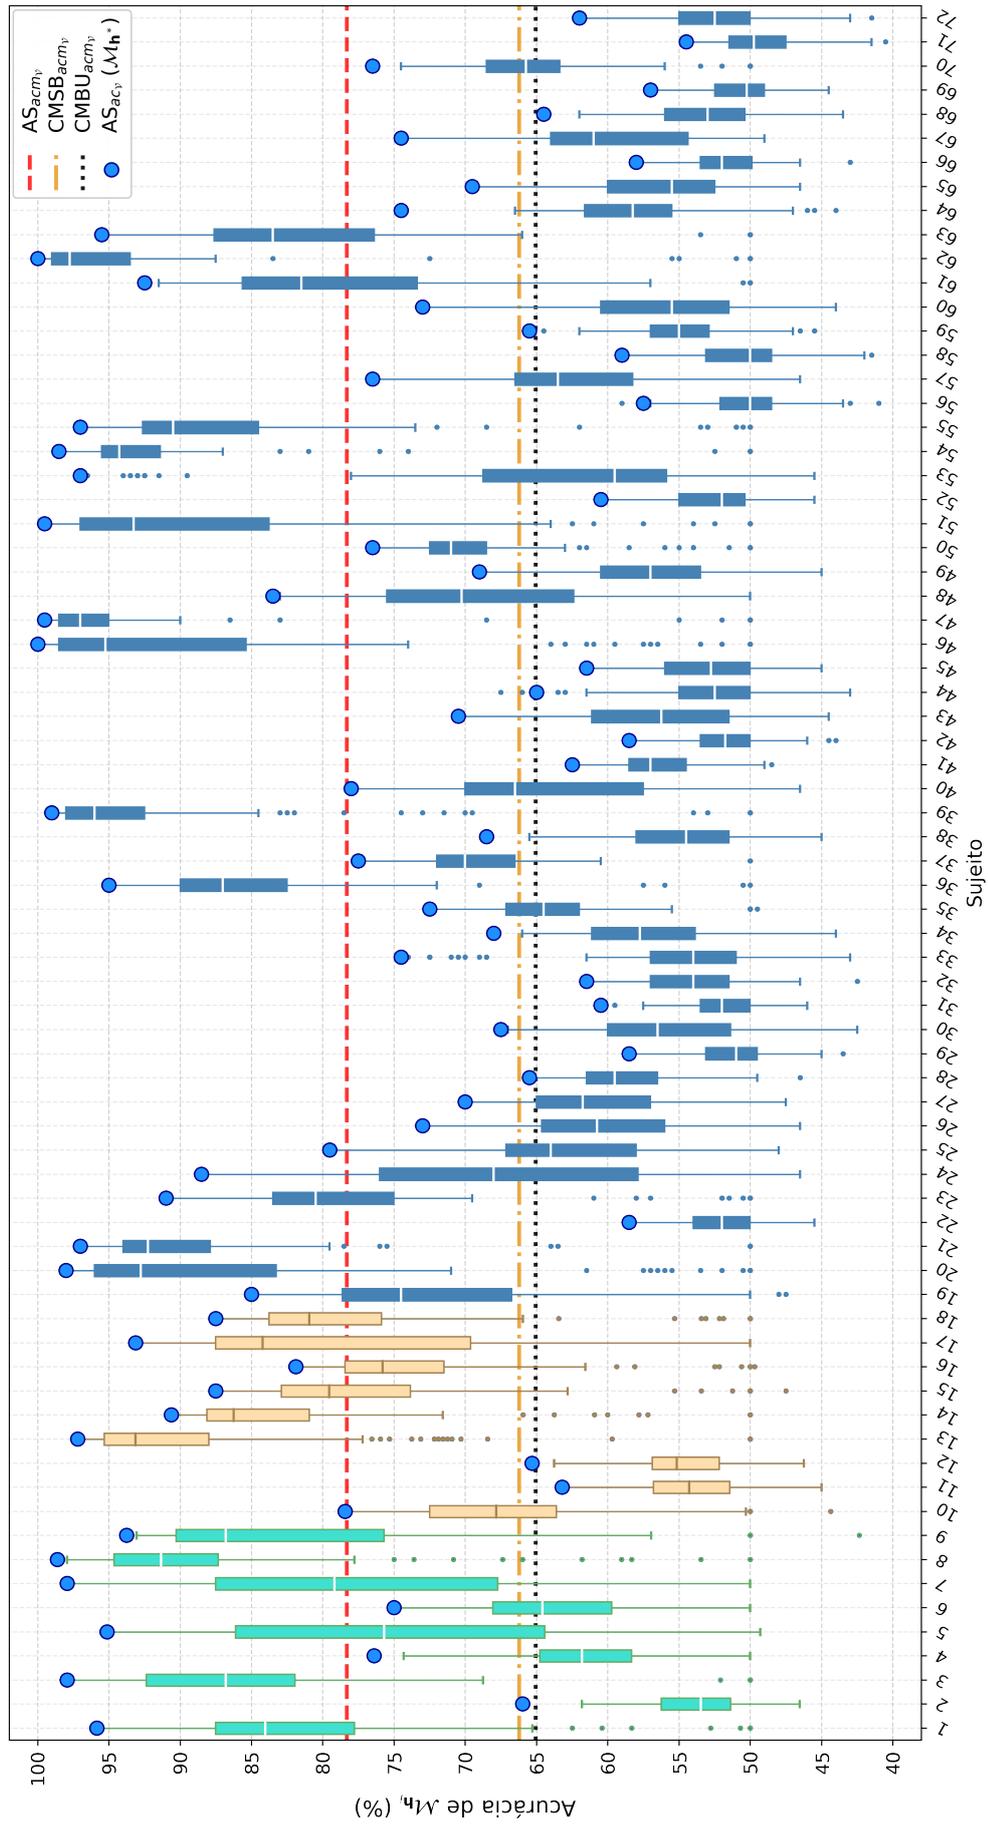


Fonte: Autoria própria

Os quantitativos à direita do gráfico apontam para uma alta variabilidade entre os índices, com um número médio aproximado de iterações para convergência igual a 51 porém com um desvio padrão de $\pm 27,3$. A dispersão apresentada somada à amplitude dos índices com acurácias máximas sendo encontradas tanto na iteração 1 (sujeito 39) e quanto na iteração 100 (sujeito 72) impossibilitam a conclusão sobre um número de iterações ideal independente do sujeito. Além disso, índices de "iterações ótimas" próximos à 100, i.e. $N_{iter} \geq 80$, sugerem uma margem para melhora preditiva dos modelos em um cenário com um maior número de iterações no *auto setup*.

Como se sabe, para se chegar aos hiperparâmetros ótimos representados nos respectivos \mathbf{h}^* , $N_{iter} = 100$ outras instâncias foram avaliadas por validação cruzada no conjunto de treinamento $\mathcal{D}_{\mathcal{T}}$. A fim de se ter uma impressão geral sobre a variabilidade dos desempenhos em função dos hiperparâmetros configurados durante a busca *Bayesiana*, cada um dos modelos gerados pelas instâncias candidatas foram aplicados nas épocas de validação, $\mathcal{D}_{\mathcal{V}}$. Como resultado, obteve-se as saídas da função objetivo $g(\mathbf{h})$ definida pelos desempenhos de generalização dos modelos em cada iteração. A Figura 56 busca sintetizar a discrepância entre esses desempenhos.

Figura 56. Dispersão dos desempenhos em cada uma das $N_{iter} = 100$ iterações da busca *Bayesiana* no AS. As linhas horizontais representam as acurácias médias entre todos os sujeitos nos três modos de configuração apresentadas na Tabela 4 e os pontos em azul representam a acurácia do modelo definitivo



Fonte: Autoria própria

Nota-se pelo *boxplot* na Figura 56, o quanto o desempenho de classificação varia de acordo com as instâncias hiperparamétricas definidas em cada iteração. A diferença entre os pontos de mínimo e de máximo da função substituta sugere que as perturbações nos valores atribuídos a cada hiperparâmetro gera um impacto significativo na saída da função objetivo $g(\mathbf{h})$ (i.e. no desempenho do sistema).

Os *outliers* também expressam o quanto algumas instâncias de \mathbf{h} podem gerar modelos com muito baixa capacidade preditiva em relação às medianas, assim como o processo de busca pode encontrar instâncias específicas que maximizam de maneira expressiva a acurácia de generalização em relação às demais instâncias dentro dos quartis.

Ademais, em consonância com o que já fora ilustrado pela Figura 55 na perspectiva da iteração de \mathbf{h}^* , os pontos em azul, que identificam as máximas acurácias de generalização de cada sujeito e que definem a acurácia média do *auto setup*, $AS_{acm\mathcal{V}}$, justificam o desvio padrão apresentado na Tabela 4 ao mostrarem a discrepância existente entre os desempenhos dos modelos ótimos $\mathbf{M}_{\mathbf{h}^*}$. A discussão desses desempenhos em termos numéricos será realizada posteriormente para cada um dos conjuntos de dados.

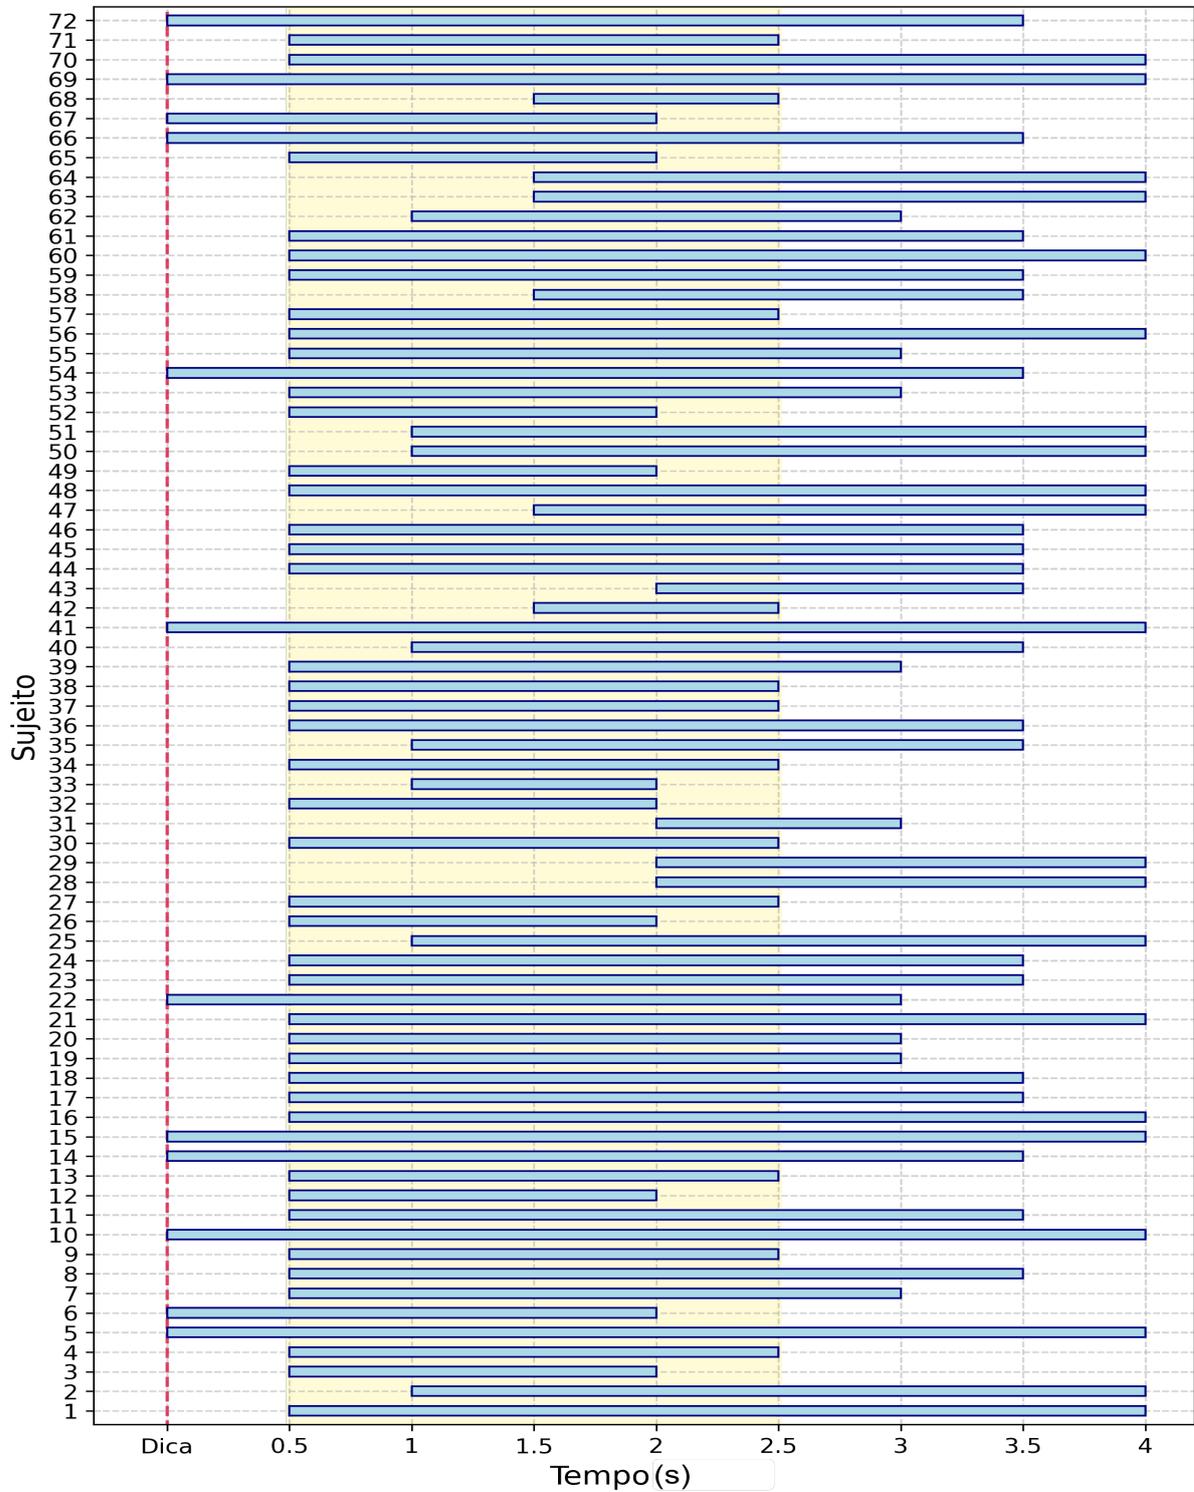
Por hora, como forma de elucidar o quão variáveis foram os modelos ótimos em termos de suas configurações hiperparamétricas, os gráficos nas Figuras 57 a 62 apresentam os resultados considerando os hiperparâmetros inerentes a cada uma das etapas da cadeia SBCSP implementada no AutoBCI, cujos domínios foram definidos na seção 5.2.6.1.2.

Em primeiro lugar, a Figura 57 ilustra a variabilidade entre as janelas temporais J em que as propriedades de localização, J_d , e largura, J_l , em relação à dica foram ajustadas pelo *auto setup*. As janelas ótimas obtidas são usadas na etapa de segmentação dos sinais de EEG para extração de épocas para compor os conjuntos $\mathcal{D}_{\mathcal{T}}$ e $\mathcal{D}_{\mathcal{V}}$.

Nota-se uma diferença significativa entre as janelas ótimas obtidas entre os sujeitos, o que, dentre outros aspectos, ilustra a característica não estacionária dos sinais de EEG na descrição dos padrões de IM. Além disso, os resultados na Figura 57 corroboram com a tese de que os fenômenos neurofisiológicos geralmente ocorrem em um segmento temporal específico a depender, principalmente, da capacidade do sujeito em modular a atividade elétrica, conforme ressaltam Wei e Wei (2016).

A porção expressiva de instâncias de $J = [J_d, J_l]$ distintas da janela típica $J = [0, 5, 2]$, 86,2%, as quais maximizam a capacidade preditiva dos modelos, sugere haver informação temporal relevante nos sinais, do ponto de vista de discriminação entre as classes de IM, que muitas vezes é desprezada ao usar configurações hiperparamétricas manuais e rígidas. Destaque para os sujeitos 28 e 29 em que 75% das amostras de EEG usadas no ajuste do modelo AS diferem no tempo em relação às amostras usadas em configurações manuais.

Figura 57. Janelas J usadas na extração de épocas de treinamento e validação do modelo de classificação cujas propriedades J_d e J_l em relação à dica compuseram as instâncias hiperparamétricas ótimos, \mathbf{h}^* , por sujeito. A faixa em amarelo compreende a janela típica com $J_d = 0,5$ e $J_l = 2$



Fonte: Autoria própria

Além disso, a localização variável das janelas ótimas representadas na Figura 57 indica que as informações úteis adicionais podem estar localizadas tanto em amostras

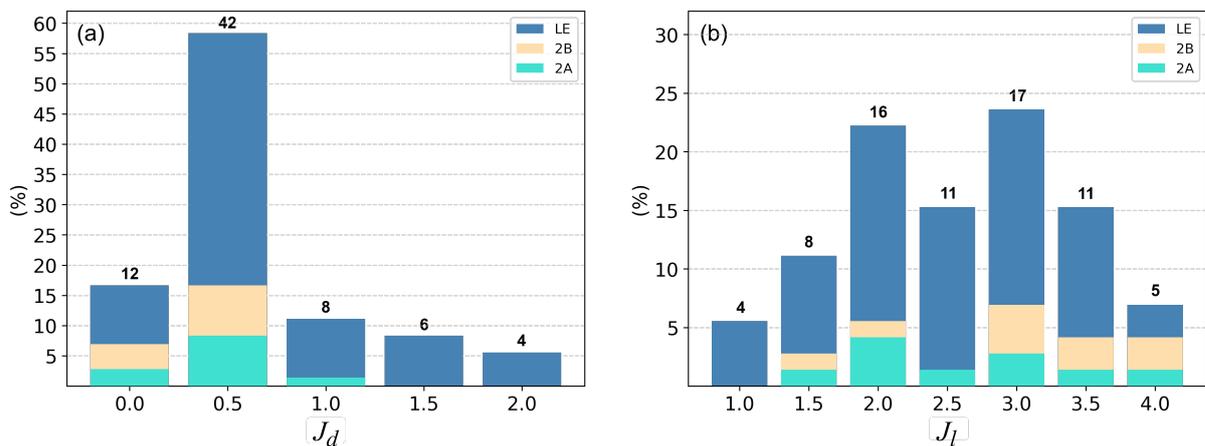
anteriores quanto em amostras posteriores aos segmentos de EEG considerados no ajuste dos modelos e que essa definição é dependente do sujeito.

Nesse sentido, majoritariamente, os modelos ótimos são obtidos com janelas temporais iniciadas até 0,5 segundos após a apresentação da dica visual ao usuário, sendo 75% dos modelos associados à estas localizações mas que se diferenciam substancialmente pela largura, J_l , da janela adotada.

Uma possível análise a partir destes resultados, seria a relação com agilidade da resposta dos indivíduos à dica apresentada durante a coleta dos sinais, ou seja, para a maioria dos sujeitos as informações que descrevem a intenção motora estão, de fato, localizadas mais próximas à dica, i.e. $J_d \leq 1$ segundo. Isso corrobora com a hipótese de que, normalmente, há uma resposta cognitiva satisfatória e rápida à dica, a qual tende a se perder progressivamente à medida que a janela se afasta da sugestão apresentada, conforme já apontara o estudo preliminar em).

Para uma discussão mais lúcida sobre a distribuição de cada propriedade nas instâncias ótimas da janela temporal, os histogramas na Figura 58 trazem os percentuais de ocorrência de cada elemento no domínio dos dois hiperparâmetros, J_d e J_l , dentre os modelos definitivos do *auto setup*.

Figura 58. Distribuição das instâncias ótimas para os hiperparâmetros conforme os valores de domínio de J_D (a) e de J_L (b). A separação por cores indica a proporção de cada conjunto de dados nos percentuais.



Fonte: Autoria própria

Os gráficos (a) e (b) possibilitam associar de forma quantitativa as variações nas duas propriedades e ajudam a ressaltar, além dos pontos supracitados, outros aspectos ocultos na Figura 57, potencialmente úteis para avaliar as implicações da janela nos desempenhos de classificação. Nota-se, por exemplo, que somente 22,2% dos modelos usaram janelas de largura padrão, $J_l = 2$ segundos, sendo que um percentual ainda menor, 13,8% correspondem em largura, e localização à janela comumente usada, 10 entre 72.

Outra peculiaridade observada na distribuição na Figura 58-a, desta vez mais associada à propriedade de largura, J_l , é que 83,3% dos modelos ótimos foram obtidos com pelo menos 2 segundos de informação temporal, sendo que 6,9% usaram toda a informação temporal disponível, $J_l = 4$. Dentre os 5 sujeitos cujos modelos têm $J_l = 4$, vale destacar o sujeito 5 pertencente à base 2A, para o qual a adoção de uma janela de largura máxima significou um ganho em acurácia de 34,1 e 8,3% em relação às abordagens CMBU e CMSB, respectivamente. O referido ganho indica a eficácia da cadeia de sub-bandas em relação à banda única, amplificada pelo uso do *auto setup*.

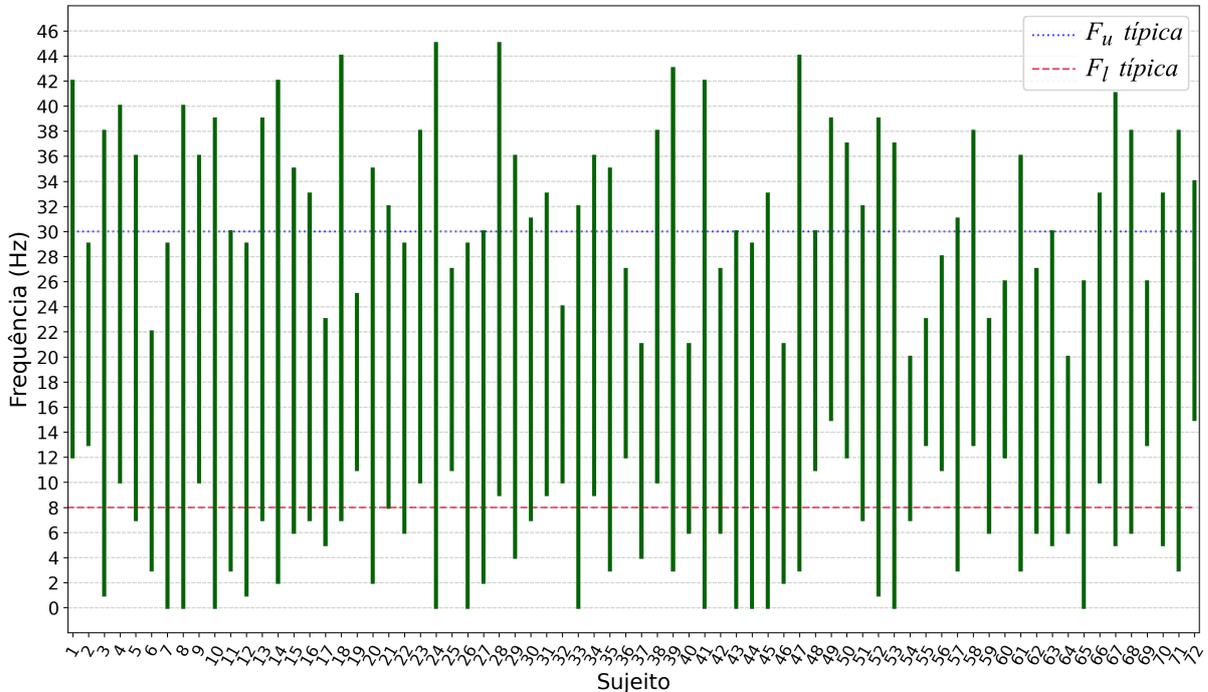
Na perspectiva do engajamento, ao observar os resultados ilustrados nas Figuras 57 e 58 é possível inferir que uma parcela significativa dos sujeitos, 61,1%, mantém o engajamento na tarefa indicada durante o experimento por um período maior que o tradicional de 2 segundos, a ponto de o uso de mais amostras no ajuste do modelo não significar ruído mas sim informação adicional para discriminação efetiva entre as classes.

Por outro lado, os 16,7% de janelas com J_l menor em relação à largura típica, indicam que nem sempre as informações temporais normalmente consideradas no treinamento serão úteis para o processo de classificação de IM, podendo, na verdade representar ruído. Dentre os 4 modelos baseados em janelas com apenas 1 segundo de informação temporal, por exemplo, 3 são treinados por épocas formadas por sub-conjuntos de amostras das épocas típicas, casos dos sujeitos 33, 42 e 68, com destaque para o modelo AS do sujeito 33 cujos ganhos de desempenho em relação à modelos CMBU e CMSB representaram 23,5% e 19% respectivamente.

Em suma, com base nos resultados apresentados nas Figuras 57 e 58, conclui-se que janelas localizadas próximo à dica, $J_d \leq 0,5$, e de largura, J_l , entre 2e3,5 segundos, tendem à contribuir para o ajuste de modelos mais generalistas. Contudo, em conformidade com o que já afirmavam Feng et al. (2018) e Wei e Wei (2016), e dada a variabilidade entre as instâncias ótimas encontradas para os respectivos hiperparâmetros, é improvável que uma janela universal contemple todas as informações relevantes para classificação independentemente do sujeito, o que evidencia a importância de uma estratégia para estimação dessas propriedades como o *auto setup*.

Para além da janela temporal usada na extração de épocas, a eficácia do AutoBCI e de sistemas ICM-IM em geral, também depende em grande parte da banda de frequência usada na filtragem temporal. A fim de proporcionar uma análise dos modelos obtidos pelo *auto setup* pelo ponto de vista espectral, a Figura 59 apresenta as instâncias associadas aos hiperparâmetros que delimitam o intervalo de frequências $\Delta_f = [F_l, F_u]$ para a etapa de filtragem, as quais foram definidas pelo *auto setup* durante a calibração automática dos modelos de cada um dos sujeitos.

Figura 59. Intervalos de frequências Δ_f cujos extremos representados pelas frequências de corte inferior, F_l , e superior, F_u , foram ajustados pelo *auto setup* ao considerar os dados de treinamento de cada sujeito e o espaço de configuração hiperparamétrica na otimização *Bayesiana*. As linhas pontilhadas delimitam o intervalo comumente adota em configurações manuais, tal qual $\Delta_f = [8, 30]$ Hz



Fonte: Autoria própria

Nota-se pelas barras na Figura 59 que, assim como no domínio tempo, as informações espectrais discriminantes específicas dos sujeitos são substancialmente desiguais e também apresentam uma relação de alta variabilidade entre si. As linhas pontilhadas representando as frequências de corte inferior e superior tipicamente adotadas em configurações manuais, $F_l = 8$ Hz e $F_u = 30$ Hz respectivamente, evidenciam o distanciamento de alguns intervalos ótimos do intervalo convencional.

Em termos numéricos, foram obtidos 68 intervalos totalmente diferentes entre os sujeitos, sendo que em um deles $0 - 29$ Hz contém frequências discriminativas ótimas usadas em três modelos correspondentes aos sujeitos 7, 26 e 44, enquanto que um segundo intervalo, $6 - 27$ Hz está associado aos sujeitos 42 e 62 e, por fim, o intervalo $23 - 38$ Hz é o mesmo para os sujeitos 10 e 38.

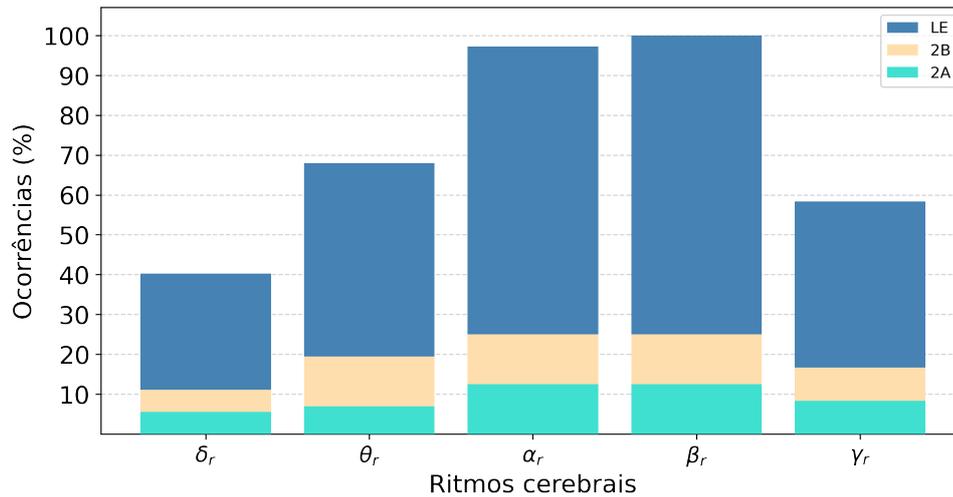
As frequências ótimas de corte inferior e superior variaram conforme as relações $0.5 \leq F_l \leq 15$ Hz e $20 \leq F_u \leq 45$, cobrindo praticamente todo o espectro contemplado nos domínios de ambos os hiperparâmetros. Ao todo, 15 frequências de corte inferiores diferentes, sendo $F_l = 0.5$ Hz a mais comum com 12 ocorrências, enquanto $F_u = 29$ Hz e $F_u = 38$ Hz, ambas com 6 ocorrências, as frequências de corte superior mais observadas entre as 26 ocorrências distintas.

Além disso, nenhum dos modelos foi ajustado com sinais filtrados em banda única típica entre $\Delta_f = [8, 30]$, sendo que apenas 10 a banda de frequência correspondeu a um intervalo mais estreito, com $F_l \geq 8$ e $F_u \leq 30$, o que implica em 62 extrapolações do intervalo padrão em CMBU. Por outro lado, 41 intervalos ótimos estão confinados entre as instâncias manuais padrão em CMSB, $F_l \geq 4$ e $F_u \leq 40$, no entanto nenhum com $\Delta_f = [4, 40]$.

Acerca da amplitude dos intervalos ótimos obtidos, característica importante no particionamento da banda discriminativa do sujeito conforme o número de sub-bandas selecionado, 28 larguras diferentes foram observadas entre as instâncias, sendo 28Hz a largura mais frequente por ser aplicada em 6 modelos. A largura média entre os intervalos corresponde a 27Hz, com o menor intervalo entre 13 – 23Hz usado no modelo associado ao sujeito 55 e o maior intervalo entre 0 – 45Hz no modelo do sujeito 24.

Uma análise relevante dos números observados pode ser obtida ao projetar os respectivos intervalos de frequências discriminativas nos ritmos cerebrais conhecidos e cujos intervalos normalmente compreendidos foram apresentados na seção 2.3.1. Nesse sentido, a Figura 60 apresenta a distribuição das instâncias ótimas que delimitam Δ_f entre os intervalos associados à cada ritmo cerebral de acordo com a Tabela 1.

Figura 60. Distribuição por ritmos cerebrais contemplados entre as instâncias ótimas dos hiperparâmetros de frequência que delimitam o intervalo $\Delta_f = \{F_l, F_u\}$. As cores indicam a proporção de ocorrências para cada conjunto de dados.



Fonte: Autoria própria

Conforme o esperado, praticamente todos os intervalos contemplam frequências associadas aos ritmos μ_r (8 – 12Hz), pertencente ao intervalo de α_r (8 – 13)Hz, e β_r (13 – 30Hz). No entanto, para um número significativo de sujeitos, a banda discriminativa incorpora frequências associadas à todos os outros ritmos cerebrais, especialmente os ritmos θ_r (4 – 8)Hz e γ_r (> 30Hz), já contemplados na cadeia CMSB. Vale ressaltar

que, mesmo sendo comum a associação dos ritmos cerebrais aos intervalos de frequência mencionados, esses podem variar entre os indivíduos e conforme seus estados mentais (PFURTSCHELLER; STANCÁK; EDLINGER, 1997; ANDREW; PFURTSCHELLER, 1997)

Todos esses resultados, discutidos e ilustrados por meio das Figuras 59 e 60, corroboram com o fato de que a banda de frequência específica do sujeito nem sempre está confinada entre os intervalos específicos de μ_r e β_r , podendo abranger frequências diferentes devido à discrepância fisiológica e anatômica entre os sujeitos. A responsividade do sistema em termos de frequência contribui para encontrar intervalos em que as características espectrais que definem a intenção motora do indivíduo são mais discriminantes.

Ademais, uma vez que a janela temporal usada na extração de épocas têm influência sobre a banda discriminativa do sujeito, conforme concluem Xu et al. (2014) e Wei e Wei (2016), a busca por uma combinação ótima entre a banda de frequência e as propriedades que definem a janela J é uma estratégias potencialmente eficaz para o reconhecimento de padrões de IM no contexto de ICM.

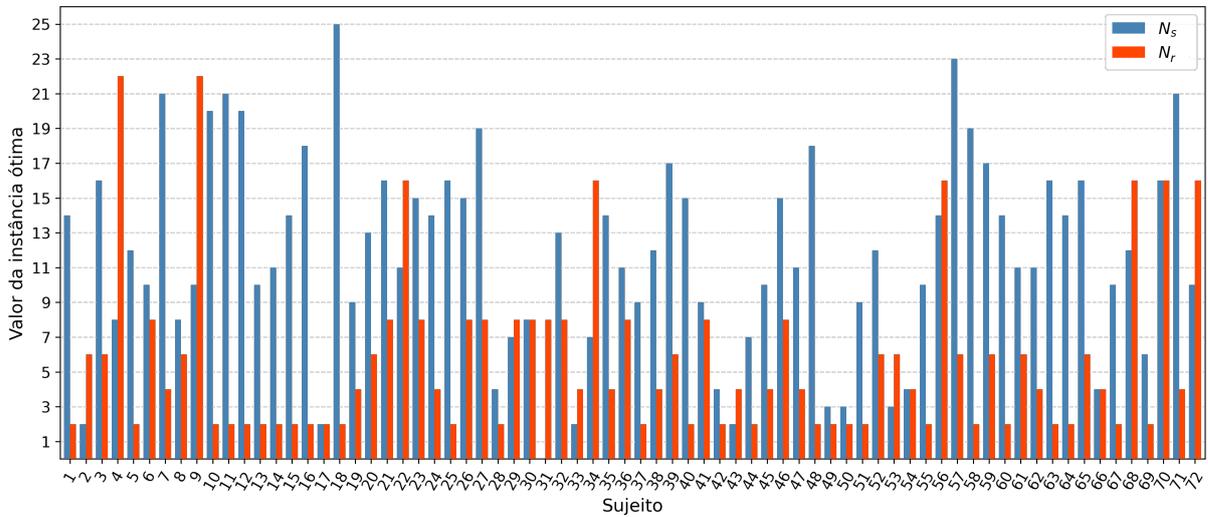
A maximização da acurácia dos modelos AS provocada pela remoção ou inclusão de componentes de frequência conforme as características de cada usuário mostraram que, a definição de um intervalo fixo pode, por vezes, ou significar a perda de informação relevante ou incorporar informações desnecessárias, as quais, do ponto de vista de classificação de IM, representam a adição de ruído. Outrossim, além de comprovar a correlação entre os hiperparâmetros temporais, espectrais e espaciais, as instâncias espectrais ótimas contribuíram principalmente com a melhoria substancial do desempenho do CSP e, por consequência, do classificador final.

Para complementar a análise dos hiperparâmetros associados à etapa de pré-processamento, a Figura 61 indica apresenta as instâncias ajustadas para o número de sub-bandas, N_s , e o número de filtros espaciais, N_r , referentes aos modelos AS de cada sujeito.

O primeiro ponto importante que pode ser evidenciado a partir dos quantitativos na Figura 61 é fato de apenas um dos modelos ótimos ser representado por uma cadeia de banda única. Este modelo, referente ao sujeito 31 pertencente à base de dados LE, mesmo com a estimação dos hiperparâmetros, continuou com baixa capacidade relativa de predição, com apenas 63% de acertos de classificação. Apesar desse percentual representar uma melhora importante no desempenho em relação à CMBU e CMSB, ambos com modelos aleatórios (i.e. 50% de acurácia), não foi suficiente para posicionar o sujeito como alfabetizado em ICM-IM, conforme critérios discutidos anteriormente.

Enquanto isso, a adesão pela cadeia de sub-bandas em 71 dos modelos ajustados no

Figura 61. Instâncias ótimas obtidas com o *auto setup* para os hiperparâmetros N_s e N_r , ao considerar dados dos 72 sujeitos avaliados



Fonte: Autoria própria

processo Bayesiano do *auto setup*, comprova a eficácia dessa abordagem proposta por Novi et al. (2007), na extração de características discriminativas de cada sujeito em relação à abordagem de banda única.

Acerca dos valores ótimos de N_s propriamente ditos, nota-se pelo gráfico da Figura 61 que o número mínimo de sub-bandas entre os modelos é $N_s = 2$ com quatro ocorrências entre os sujeitos, enquanto que o número máximo é $N_s = 25$ para o sujeito 18, base 2B. Uma vez que no referido modelo o intervalo de frequências ótimo selecionado corresponde à $\Delta_f = \{7; 44\}$, têm-se sub-bandas com intervalos uniformes de 3Hz, ao considerar uma sobreposição de 50% entre sub-bandas consecutivas. Encontrar esses intervalos usando o AS contribuiu para ganhos de 14% e 17,5% em relação às abordagens CMBU e CMSB, respectivamente.

As instâncias de N_s mais frequentes nos modelos são $N_s = 10$ e $N_s = 14$, contudo, devido a alta variância dos hiperparâmetros de frequência entre os modelos envolvidos não foi possível chegar a uma análise conclusiva sobre esses valores uma vez que o comprimento de sub-bandas depende da faixa de frequência específica dos respectivos sujeitos. Tanto os valores de máximo entre as instâncias de N_s , quanto os valores mais frequentes, guardam alguma semelhança com configurações típicas na literatura como as usadas por Ang et al. (2012a) e Novi et al. (2007), respectivamente.

Por outro lado, ao considerar as faixas discriminativas de todos os sujeitos, bem como as instâncias de N_s selecionadas, têm-se um comprimento médio de sub-bandas de $6,55 \pm 6,1$ Hz, levando-se em consideração a sobreposição de 50%. A dispersão em torno da média denota de forma numérica a variabilidade entre os sujeitos ilustrada nas Figura

59 e 61.

Em se tratando do hiperparâmetro N_r , por sua vez, as instâncias na Figura 61 apresentaram uma variabilidade menor em relação a N_s . No entanto, vale ressaltar que, para o conjunto de sujeitos de 2B, o número de filtros espaciais é fixo, $N_r = 2$, haja vista que nesses casos os sinais de EEG são obtidos de apenas $P = 3$ eletrodos posicionados no escalpo e a restrição sobre N_s ser obrigatoriamente um número inteiro e par, define o valor desse hiperparâmetro nos respectivos modelos AS.

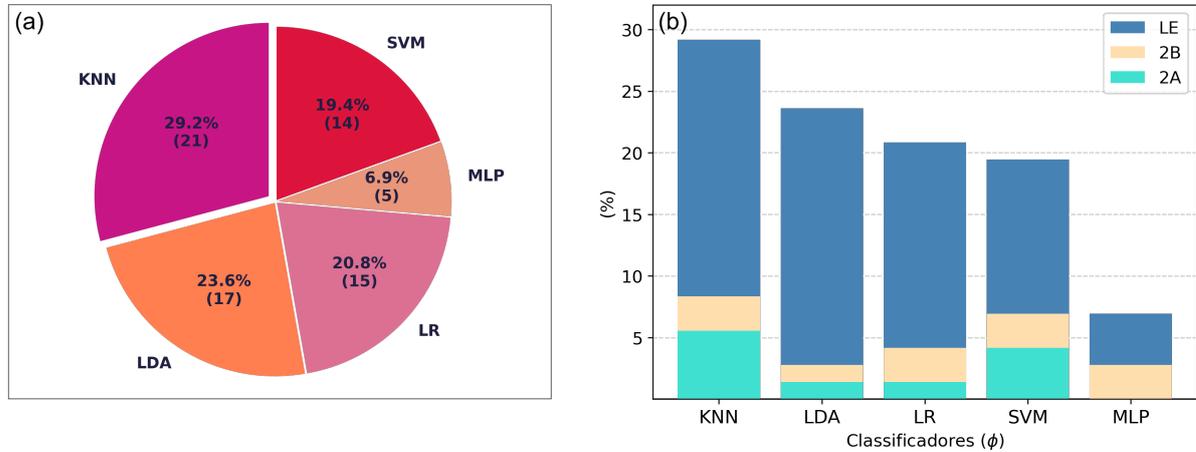
Ao tomar somente as demais 63 instâncias de N_r , notou-se que 87,3 dos modelos CSP consideraram até 4 pares de filtros espaciais para composição dos vetores de características dos sinais, $2 \leq N_r \leq 8$. Ainda que descartadas as instâncias de referentes aos modelos de 2B, a instância mais frequente continuou a ser $N_s = 2$, com 19 ocorrências entre as 63 instâncias remanescentes. As instâncias observadas estão dentro da margem de $N_s = 3$, sugerida por Lotte e Guan (2011) como a parametrização que tende a gerar melhores desempenhos.

No entanto, dois modelos relativos aos sujeitos 4 e 9 do conjunto 2A chamaram à atenção por generalizarem melhor com instâncias máximas dentro do espaço de hiperparâmetros de N_r , ou seja, $N_s = P = 22$. Para ambos os sujeitos a ampliação do número de pares de filtros CSP, de 4 em modelos de configuração manual para 11 no modelo AS, representou ganhos em acurácia de até 4,5%. A respeito dos sujeitos do conjunto do LE, seis modelos AS foram treinados a partir de $N_s = P = 16$, em que o número ótimo de pares de filtros dobra em relação à configurações típicas.

Para finalizar a análise individual dos hiperparâmetros pertencentes ao espaço de configuração do *auto setup*, a Figura 62 apresenta de forma gráfica a distribuição das técnicas de classificação entre as 72 instâncias ótimas obtidas para o hiperparâmetro ϕ . Enquanto a Figura 62-a apresenta a proporção geral das técnicas contempladas em \mathcal{H} , o histograma na Figura 62-b traz a porção de cada classificador entre os modelos correspondentes a cada conjunto de dados, onde é possível notar uma certa proporcionalidade entre as técnicas observado o número de sujeitos em cada base.

Os resultados no gráfico da Figura 62-a apontam o KNN como a técnica de classificação mais frequente entre as instâncias ótimas do hiperparâmetro ϕ , mesmo esta sendo considerada uma técnica menos sofisticada em relação às formulações não lineares do SVM, por exemplo. Ademais, as proporções na Figura 62-b indicam que o KNN foi majoritário em 2 dos 3 conjuntos de dados, 2A e LE, e dividiu a liderança em número de ocorrências no conjunto 2B com outras três técnicas, demonstrando a capilaridade do método entre os modelos ótimos associados a sujeitos das diferentes bases de dados. Dentre as hipóteses levantadas para explicar o desempenho do KNN estão:

Figura 62. Distribuição de classificadores pertencentes à \mathcal{H} entre as instâncias ótimas obtidas com o *auto setup* para os 72 sujeitos avaliados (a) e proporção dos três conjuntos de dados públicos na referida distribuição (b)



Fonte: Autoria própria

- I a baixa dimensionalidade dos vetores de características regida pelas instâncias ótimas de N_r associada ao número relativamente baixo de exemplos de treinamento, típica em ICM-IM, que juntas são frequentemente apontadas como propriedades que favorecem o uso de modelos baseados em instâncias como o KNN (FACELI et al., 2011; HASTIE; TIBSHIRANI; FRIEDMAN, 2017);
- II a estratificação igualitária entre as classes de MI no conjunto de treinamento $\mathcal{D}_{\mathcal{T}}$, a qual implica a mesma probabilidade à priori entre as classes na composição do espaço dos k -vizinhos mais próximos e consequentemente contribui para um cálculo justo sobre a classe majoritária que define a classe dos elementos de $\mathcal{D}_{\mathcal{V}}$;
- III uma vez que o KNN não depende do ajuste de parâmetros mas sim das instâncias do vetor de características nos exemplos de treinamento, a normalização das características de sub-bandas, realizada pelo meta-classificador *Bayesiano* na etapa de fusão de pontuações, evidenciando os pesos das sub-bandas mais discriminativas numa escala definida, pode contribuir para obtenção da similaridade no cálculo de distâncias que define a classificação.

Os valores de ϕ_{nn} para os números de vizinhos mais próximos variaram entre 2 e 18, sendo que três instâncias se destacaram como as mais frequentes, $\phi_{nn} = \{7, 14, 18\}$, todas com 3 ocorrências entre os 21 modelos AS baseados no KNN. Onze instâncias diferentes foram observadas para ϕ_{nn} , sendo $\phi_{nn} \approx 11(\pm 5)$ a instância ótima média. A amplitude entre as instâncias ótimas do número de vizinhos mais próximos para classificação das épocas assim como a dispersão entre essas instâncias sugerem a difícil tarefa de se definir um valor padrão para o hiperparâmetro em questão.

Em 11 das 21 ocorrências de modelos AS baseados no KNN (i.e. 52,4%) usaram a função euclidiana para medir as distâncias entre os elementos preditivos e os elementos previsores nos conjuntos de treinamento e validação, respectivamente. Enquanto que 4 usaram a função *manhattan* e 6 a função *cebyshev*. Além da variabilidade denotada pela ocorrência de todas as possíveis métricas, esses números apontam que apesar de possuir uma formulação matemática simples, a métrica euclidiana foi capaz de descrever a similaridade entre os exemplos de validação e os exemplos de treinamento com maior eficácia em relação às demais métricas no domínio de ϕ_m .

Além do KNN, o modelo proposto por *Fisher* (LDA), comprovou sua eficácia no contexto de ICM-IM ao representar a segunda técnica mais frequente entre as instâncias ótimas de ϕ , acompanhado de perto pela regressão logística (LR). Nos casos em que o LDA foi selecionado, a arquitetura do modelo AS foi composta por dois classificadores LDA, sendo o primeiro para pontuar as N_s sub-bandas e o segundo como classificador definitivo. Mais uma vez, estima-se que o bom desempenho da LR está relacionado com a suavização dos dados de entrada do classificador ao aplicar o meta-classificador *Bayesiano* na cadeia de sub-bandas, em que a transformação realizada pela equação Eq. (3.31), contribui para a eficácia da função sigmoide no processo de classificação por LR.

O SVM, por sua vez, apareceu em aproximadamente 1 entre 5 instâncias ótimas de ϕ , o que o coloca como a quarta técnica mais frequente entre os 72 modelos obtidos. Dentre as 14 ocorrências, 3 dos modelos baseados em SVM estão associados à sujeitos do conjunto 2A, sendo a segunda técnica mais frequente nesse conjunto, atrás apenas do KNN com 4 ocorrências. As formulações não lineares do SVM ocorreram em 12 dos 14 modelos AS baseados neste classificador, com destaque para a função *kernel* de base radial (*Gaussiana*) com 8 ocorrências (57,1%) entre as instâncias $\phi = SVM$.

A forma linear do SVM, usada na cadeia de CMSB e em estudos consagrados na literatura como em Novi et al. (2007) e Ang et al. (2008), foi responsável por modelos com maior capacidade de generalização em dados de apenas 2 dos 72 sujeitos avaliados, tais quais: 19 e 53. Apesar de sua aplicação em cadeias de sub-bandas com configurações manuais representarem um ganho significativo em relação à cadeias de banda única, onde não é aplicado (ver Tabela 4), a capacidade preditiva do SVM linear foi superada por outros classificadores em 97,2% dos experimentos.

Em contraponto, vale lembrar que um dos modelos ajustados com SVM linear, referente ao sujeito 53, já foi destacado anteriormente como o que registrou o maior ganho em acurácia entre os modelos de classificação obtidos com o *auto setup* em relação aos modelos de CMBU e CMSB, ressaltando que o ganho proporcionado pelo *auto setup* está em grande parte relacionado à combinação entre todos os componentes contemplados em sua estrutura e não apenas à técnica de classificação adotada no ajuste dos modelos.

Acerca de ϕ_c , o qual representa o parâmetro de regularização do SVM no espaço de configuração do *auto setup*, foi observada uma alta dispersão entre as instâncias ótimas desse hiperparâmetro, com os valores variando entre 10^{-6} e 1. Mesmo sendo observada uma tendência em torno de $\phi_c = 10^{-3}$, a alta variabilidade impossibilita qualquer conclusão sobre uma atribuição definitiva. Além disso, resultados de testes preliminares realizados ao longo desta pesquisa apontaram que pequenas perturbações em ϕ_c geram pouca ou nenhuma influência no desempenho de classificação de sistemas ICM-IM de sub-bandas.

Ao observar os 5 modelos obtidos com *auto setup* cujos classificadores finais representam Redes Neurais MLP, notou-se uma variação em ambos os hiperparâmetros condicionais associados a essa técnica, ϕ_{ne} e ϕ_{eta} . A quantidade de neurônios utilizados na camada oculta dessas redes variou de modo que $20 \leq \phi_{ne} \leq 90$, formando redes com densidades relativamente baixas se comparada a densidade máxima no domínio de ϕ_{ne} . Quanto à taxa de aprendizagem, 4 das 5 redes neurais foram treinadas com $\phi_{eta} = 10^4$ denotando esta como a configuração associada à MLP com melhores acurácias.

De acordo com o que aponta a Figura 62-b, a maior variabilidade observada entre as técnicas de classificação está nos modelos AS associados aos sujeitos do conjunto 2B, em que 4 das 5 técnicas possíveis para ϕ aparecem 2 vezes, com o LDA sendo a única técnica com apenas uma ocorrência. Tal observação indica que a escolha de uma técnica de classificação única, especialmente para os 9 sujeitos em 2B, tende a gerar modelos incapazes de explorar o espaço de características tão bem quanto o uso de uma definição heurística de ϕ .

Em busca de uma análise direcionada dos resultados no experimento de validação *off-line* e de modo a comparar esses resultados aos de outros trabalhos na literatura, as sub-seções a seguir tratam separadamente os três conjuntos de dados públicos de EEG e fornecem discussões particulares acerca do desempenho do método AS implementado na plataforma AutoBCI.

Os trabalhos considerados correlatos do ponto de vista de configuração hiperparamétrica e seleção de modelos em sistemas de ICM-IM aplicam diferentes técnicas de estimação e otimização, no entanto em grande parte dos estudos o grau de liberdade do espaço de configuração é limitado à hiperparâmetros de uma ou duas etapas da cadeia de processamento, em que o objetivo é a análise direcionada dos efeitos da variação desses hiperparâmetros específicos no desempenho de classificação.

Como exemplo podem ser citados alguns trabalhos cujo foco está na otimização da banda de frequência e conseqüentemente das características espectrais discriminativas do sujeito, tais quais: Kumar, Sharma e Tsunoda (2017), Wei e Wei (2015), Raza, Cecotti e Prasad (2015), Ang et al. (2012a), Ang et al. (2012b), Ang et al. (2008), Yang et al.

(2016), Luo et al. (2016), Wang (2011), Zhang et al. (2015), Zhang et al. (2017), Sun, Hu e Wu (2010), Mishuhina e Jiang (2018), Suk e Lee (2011) e Belizario (2017).

Além desses, estudos que abordam a estimação do número ideal de canais ou aplicam alguma estratégia de busca manual para correlacionar o número de eletrodos com o desempenho de classificação também podem ser encontrados, como Arvaneh et al. (2011), Lahiri, Rakshit e Konar (2017), Li e Koike (2011), Lal et al. (2004), Lopes et al. (2019).

Outrossim, alguns estudos se dedicam ao ajuste dos hiperparâmetros que definem a janela temporal usada na extração de épocas de treinamento como Dalponte, Bovolo e Bruzzone (2007), Wei e Wei (2016), Yang et al. (2017), Feng et al. (2018), Miao et al. (2017).

Alguns dos estudos supracitados avaliam seus métodos usando os dados nas mesmas bases públicas adotadas na avaliação da ferramenta proposta neste trabalho. Nesse sentido, os comparativos nas seções a seguir levam em consideração resultados de trabalhos cujos experimentos são compatíveis ao aqui realizado, ou seja, considerando os mesmos dados em relação aos sujeitos e pares de classes na formulação do problema de classificação.

7.1.1 Resultados para o conjunto de sujeitos 2A

Como descrito na seção 5.3.1, ao considerar somente os dados dos 9 sujeitos da base 2A, têm-se os respectivos conjuntos de validação, \mathcal{D}_V , cada qual com $N_A = 72$ ensaios associados à IM da mão esquerda e $N_B = 72$ ensaios associados à IM da mão direita, totalizando portanto $N_V = 144$ exemplos. As acurácias de validação dos três modelos de classificação, ajustados a partir de configurações manuais e automática, são obtidas com base nesses dados e comparadas por meio da Tabela 5.

Tabela 5. Comparativo entre acurácias individuais de generalização dos modelos associados aos sujeitos do conjunto 2A e ajustados usando os dois modos de configuração manual, CMSB e CMBU, e o *auto setup*

	AS_{ac_V}	$CMSB_{ac_V}$	$CMBU_{ac_V}$
1	95, 83	89, 58	90, 28
2	65, 97	55, 56	56, 94
3	97, 92	96, 53	98, 61
4	76, 39	71, 53	68, 06
5	95, 14	86, 81	61, 11
6	75, 00	67, 36	64, 58
7	97, 92	85, 42	72, 92
8	98, 61	95, 14	95, 83
9	93, 75	92, 36	93, 06
$\mu \pm \sigma$	88, 51 \pm 12, 5	82, 25 \pm 14, 2	77, 93 \pm 16, 4

Os resultados dos modelos individuais revelam que o ganho médio obtido com o *auto setup* para todo o conjunto 2A está distribuído entre os sujeitos. O uso da configuração automática durante a calibração do AutoBCI gerou modelos mais generalistas em relação à definição manual de hiperparâmetros para 8 dos 9 sujeitos avaliados. Apenas para o sujeito 3 o modelo AS foi incapaz de superar a configuração típica de banda única.

Um ponto de destaque, são os resultados relacionados ao sujeito 5, para o qual o uso da arquitetura de sub-bandas gera ganho expressivo de acurácia em relação à cadeia de banda única. A adoção de um espectro mais amplo e segmentado em 9 sub-bandas de frequências uniformemente distribuídas pode ajudar a explicar esse fenômeno uma vez que tende a contribuir para extração de informações espectrais mais discriminativas do sujeito. Além disso, ao tornar livres os hiperparâmetros nessa arquitetura e ajustá-los usando o *auto setup*, observou-se um ganho ainda mais expressivo, com 34,0% a mais de classificações corretas do modelo AS comparado com a CMBU.

Por outro lado, para alguns sujeitos como 1, 2, 8 e 9, a performance a partir da CMBU chega a ser melhor ou, no máximo, similar à performance do modelo baseado em sub-bandas, sugerindo que para esses sujeitos o uso da estrutura mais sofisticada de filtragem não representa diferença significativa em termos de desempenho de classificação em relação à cadeia de banda única. No entanto, o *auto setup* foi capaz de gerar modelos mais assertivos em todos eles.

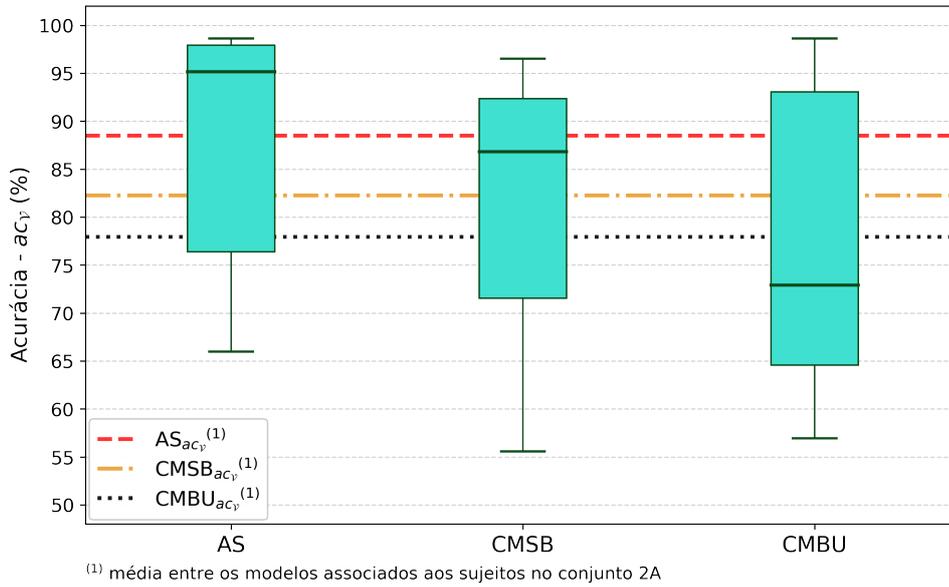
Ao considerar o limiar de analfabetismo em ICM proposto por Ahn et al. (2013), apenas o sujeito 2 manteve a acurácia abaixo dos 70% nos três modos de configuração, ainda que o ganho em acurácia com o *auto setup* tenha representado 28 classificações corretas a mais ao considerar as $N_V = 144$ épocas no conjunto de validação, i. e. 9%, em relação às demais abordagens de configuração manual.

Em geral, portanto, o desempenho da configuração automática do sistema proposto apresentou resultados promissores em todos os sujeitos, inclusive ao manter a alta taxa de classificação entre os dados do sujeito 3. Nesse contexto, a fim de evidenciar a dispersão entre as acurácias de validação nos diferentes modelos, expressa em números pelos respectivos desvios padrão na Tabela 5, a Figura 63 é apresentada.

Nota-se pela gráfico que a baixa performance relativa de alguns modelos, especialmente do correspondente ao sujeito 2, influenciaram negativamente a média geral do *auto setup* no conjunto 2A denotada pela linha tracejada em vermelho. Isso pode ser observado ao comparar a referida média com a mediana no *boxplot* correspondente, a qual mostra-se uma medida de centralidade mais representativa entre os outros 6 modelos AS em que as acurácias de validação foram próximas de 95%.

Além disso a dispersão entre os desempenhos dos modelos AS é substancialmente

Figura 63. Diagrama de caixas para as acurácias médias de validação dos modelos obtidos a partir dos três modos de configuração hiperparamétrica para os 9 sujeitos na base 2A



Fonte: Autoria própria

menor em relação às abordagens de referência devido, principalmente, à elevação do desempenho entre os sujeitos com acurácia abaixo de 70% nos modelos CMSB e CMBU. Uma menor dispersão entre as acurácias indica robustez do método de configuração automática ao produzir modelos capazes de generalizar bem a partir de dados de diferentes sujeitos.

Os resultados para cada um dos sujeitos estão associados à suas respectivas instâncias hiperparamétricas ótimas, as quais são discriminadas na Tabela 6.

Tabela 6. Instâncias ótimas do conjunto de hiperparâmetros obtidas com *auto setup* para os 9 sujeitos do conjunto 2A

<i>Suj.</i>	$F_l - F_u$ (Hz)	$J_d ; J_l$ (s)	N_s	N_r	ϕ	Parâmetros de ϕ
1	12 – 42	0,5 ; 2,5	14	2	KNN	$\phi_{nn} = 14$ $\phi_m = Chebyshev$
2	13 – 29	1,0 ; 3,0	2	6	KNN	$\phi_{nn} = 7$ $\phi_m = Euclidean$
3	01 – 38	0,5 ; 1,5	16	6	SVM	$\phi_c = 1$ $\phi_k = Polinomial$
4	10 – 40	0,5 ; 2,0	8	22	LR	–
5	07 – 36	0,0 ; 4,0	12	2	SVM	$\phi_c = 10^{-4}$ $\phi_k = Gaussiana$
6	03 – 22	0,0 ; 2,0	10	8	KNN	$\phi_{nn} = 8$ $\phi_m = Euclidean$
7	00 – 29	0,5 ; 2,5	21	4	KNN	$\phi_{nn} = 7$ $\phi_m = Chebyshev$
8	00 – 40	0,5 ; 3,0	8	6	SVM	$\phi_c = 10^{-3}$ $\phi_k = Sigmoidal$
9	10 – 36	0,5 ; 2,0	10	22	LDA	–

Ao analisar as instâncias ótimas de \mathbf{h} , nota-se que a faixa de frequência discriminativa encontrada para o sujeito 5, por exemplo, é, de fato, mais ampla se comparada ao padrão

de Δ_f na CMBU, porém, menor em relação à CMSB. Além disso, o número de sub-bandas usado na projeção do melhor desempenho também é maior que o tradicionalmente usado, o que diminui consideravelmente os intervalos de *bins* de frequências em cada sub-banda. À propósito, as instâncias ótimas de N_s apresentaram alta variabilidade entre os sujeitos, tal como os intervalos em cada uma das sub-bandas, denotando assim a discrepância entre as frequências discriminativas.

Ainda sobre o sujeito 5, o ganho expressivo de desempenho com o AS pode ser explicado por este proporcionar o aumento da informação temporal no treinamento do modelo, o que neste caso possibilitou a extração de novas informações úteis para discriminação, passando-se de um intervalo de 500 amostras por época de treinamento para 1000 amostras, dada a taxa de amostragem dos sinais da referida base, $F_s = 250\text{Hz}$.

Modelos ótimos associados aos sujeitos 2 e 8 também foram obtidos com base em uma adição na informação temporal, passando a 3 segundos (ou 750 amostras) enquanto que para os demais modelos a largura das épocas de treinamento variaram entre 1.5 a 2.5 segundos e estão próximas à largura tipicamente usada. A proximidade à dica também pode ser considerada um fator importante observado entre todos os sujeitos.

Do ponto de vista da técnica usada para classificação, o *kNN* foi escolhido em 4 dos 9 modelos ótimos, sendo a mais comum entre os sujeitos de 2A. Para além da variação na escolha da função métrica, ϕ_m , entre essas escolhas, excetuando-se o modelo associado ao sujeito 1, o qual utilizou a distância para $\phi_{nn} = 14$ pontos mais próximos no espaço de características na tomada de decisão sobre os rótulos de classe, os demais modelos *kNN* apresentaram uma normalidade em torno de $\phi_{nn} = 7$ no número de vizinhos mais próximos.

Um último ponto que chama a atenção entre os resultados apontados na Tabela 6, é o uso de toda a informação espacial disponível nos modelos AS associados aos sujeitos 4 e 9. Diferentemente dos demais modelos que usaram até 4 pares de filtros associados aos menores e maiores autovetores para projeção dos sinais, os modelos dos sujeitos 4 e 9 foram obtidos por $N_r = P = 22$ filtros espaciais (11 pares), gerando vetores de características de sub-bandas de dimensionalidade máxima uma vez que o processo de seleção de características foi nulo nestes casos. Apesar de se ter modelos de maior complexidade, este aspecto não representou *overfitting* dadas as acurácias de generalização apresentadas.

Outras observações poderiam ser feitas a partir da Tabela 6, como as definições em torno de $\phi = SVM$ e a baixa ocorrência do modelo de *Fisher* entre os sujeitos. No entanto, após a apresentação das instâncias ótimas de cada sujeito bem como a comparação interna entre as abordagens de configuração automática e manual, é importante projetar os resultados da configuração automática no AutoBCI em um âmbito mais geral, comparando-

os à outros estudos que também usaram os dados do conjunto 2A na validação de suas proposições.

A definição de um escopo de classificação binária entre as classes ME *vs.* MD, exclusivamente, também foi uma das restrições impostas para selecionar os estudos de referência na Tabela 7. Além de posicionar o trabalho no universo de estudos correlatos, a ideia com a comparação externa é validar a comparação interna baseada nas abordagens CMBU e CMSB.

Tabela 7. Comparativo entre a acurácia (%) dos modelos individuais obtidos com o *auto setup* (AS) e os melhores resultados em estudos citados ao longo deste trabalho os quais usaram o conjunto de dados 2A na avaliação de seus métodos, não necessariamente relacionados à otimização hiperparamétrica em ICM-IM

Suj.	AS _{acv}	Lotte e Guan (2010)	Lotte e Guan (2011)	Wei e Wei (2016)	Duarte (2017)	Silva (2017)
1	95,8	88,9	88,9	94,2	90,3	90,8
2	66,0	63,2	54,8	80,8	50,0	50,7
3	97,9	96,5	96,5	98,3	97,2	93,7
4	76,4	66,7	70,1	85,1	70,8	68,1
5	95,1	63,2	66,0	85,8	50,7	82,6
6	75,0	63,9	61,8	81,6	69,4	64,6
7	97,9	78,5	81,2	93,7	79,4	91,0
8	98,6	95,8	95,8	96,2	92,4	95,8
9	93,8	92,4	91,0	96,4	—	94,4
$\mu \pm \sigma$	88,5 ± 12,5	79,1 ± 14,3	79,4 ± 15,3	90,2 ± 5,7	75,0 ± 17,0	81,3 ± 15,3

Os resultados da Tabela 7, mostram que os modelos ajustados com o *auto setup* apresentaram maior capacidade de generalização que grande parte dos modelos nos trabalhos relacionados, sugerindo eficácia da abordagem também na comparação com a literatura. Ao tomar o estudo de Duarte (2017) por exemplo, cujo modelo foi obtido a partir da combinação clássica entre um filtro do tipo IIR + CSP + LDA, com configuração manual dos hiperparâmetros na cadeia de banda única, o ganho médio em acurácia do *auto setup* superou os 13%.

Da mesma forma, em relação aos estudos de Lotte e Guan (2010) e Lotte e Guan (2011), ambos amplamente reconhecidos no campo de ICM por compararem diferentes formas de regularização do método CSP, a média de acurácia de validação com o *auto setup* superou os modelos de regularização com melhores desempenhos nesses estudos em 9,4% e 9,1%, respectivamente, ambos baseados em uma configuração manual dos hiperparâmetros.

Em relação a um dos resultados reportados por Silva (2017), o qual, por sua vez, usou uma cadeia de sub-bandas baseada na arquitetura proposta por (NOVI et al., 2007)

e semelhante à adotada no escopo do AutoBCI, a performance do *auto setup* representou ganhos de 7,2% em média.

Vale destacar que o trabalho de Silva (2017) tem um campo de intersecção significativo em relação à este trabalho, uma vez que o autor também utiliza a aprendizagem BO na sintonia dos hiperparâmetros da cadeia de processamento porém com um espaço de configuração menor. Além disso, a proposição pelo uso da FFT como estratégia de filtragem no *auto setup* esteve calcada, principalmente, nos resultados já obtidos por Silva (2017) no uso de uma projeção dos sinais em base senoidal como alternativa à filtragem convencional. Por estes fatores, os ganhos observados na Tabela 7 são considerados importantes para avaliação dos resultados neste trabalho.

Por fim, na relação com os resultados de Wei e Wei (2016) foi observada uma inferioridade de 1,7% da capacidade preditiva do *auto setup* na média entre os sujeitos. Apesar de os resultados naquele trabalho terem sido obtidos de uma validação cruzada no conjunto \mathcal{D}_V correspondente, o que é diferente da abordagem de validação neste trabalho, a estratégia de busca estocástica baseada em modelo evolucionário assumida pelos autores na estimação de apenas três hiperparâmetros (localização da janela de EEG em relação à dica e frequências de corte inferior e superior) superou em acurácia o amplo espaço de configuração proposto no *auto setup* para 5 dos 9 sujeitos avaliados.

Os resultados sugerem uma maior influência dos hiperparâmetros considerados por (WEI; WEI, 2016) no desempenho de sistemas ICM-IM em relação à outros hiperparâmetros, pelo menos ao considerar o universo de sujeitos da base 2A. Essa hipótese pode ser validada em estudos futuros a partir da restrição do espaço de configuração do *auto setup* e de uma análise de correlação entre cada um dos hiperparâmetros e a performance dos modelos gerados.

Outros estudos, tidos como referências importantes no âmbito deste trabalho, como Ang et al. (2012a) e Bashashati, Ward e Bashashati (2016b), por exemplo, também utilizaram dados do conjunto 2A em seus experimentos de validação, contudo em contextos de classificação multi-classe, impossibilitando uma comparação justa entre os resultados por eles reportados e os obtidos com o *auto setup* cujo problema de classificação é estritamente binário.

Em Suk e Lee (2013), outro estudo cujos métodos adotados para estimação de hiperparâmetros em sistemas ICM-IM estão muito correlacionados com este trabalho e foram fundamentais para consolidação do *auto setup* e conseqüentemente da plataforma AutoBCI, faz uma análise baseada em classificação binária, ME vs. MD, dos dados do conjunto 2A. No entanto, o estudo reporta em números apenas a acurácia média entre os sujeitos, em que o método proposto pelos autores, com $83,80 \pm 13,09$ de taxa de acerto,

generalizou 4,7% pior em relação aos $88,5 \pm 12,5$ do *auto setup* na média entre os sujeitos. A intersecção com o *auto setup* no estudo de Suk e Lee (2013), está no uso da aprendizagem *Bayesiana* na proposição de um *framework* para otimização de filtros espaço-temporais em sistemas ICM-IM.

7.1.2 Resultados para o conjunto de sujeitos 2B

De maneira similar ao apresentado anteriormente para o conjunto 2A a Tabela 8 lista os desempenhos individuais dos modelos AS, agora considerando os 9 sujeitos do conjunto 2B. Neste caso, vale lembrar que o conjunto \mathcal{D}_Y contempla $N_\rho = 150$ ensaios por classe (ME *vs.* MD), com $N_Y = 300$ ensaios de validação.

Tabela 8. Comparativo entre acurácias individuais de generalização dos modelos associados aos sujeitos do conjunto 2B e ajustados usando CMSB, CMBU, e AS

	AS_{acY}	$CMSB_{acY}$	$CMBU_{acY}$
10	78, 43	59, 69	68, 13
11	63, 21	58, 57	58, 21
12	65, 31	54, 69	53, 44
13	97, 19	95, 94	96, 56
14	90, 63	87, 19	70, 00
15	87, 50	79, 69	79, 06
16	81, 88	76, 25	72, 19
17	93, 13	92, 18	89, 06
18	87, 50	70, 00	80, 94
$\mu \pm \sigma$	82, 75 \pm 11, 9	74, 91 \pm 15, 2	74, 18 \pm 13, 9

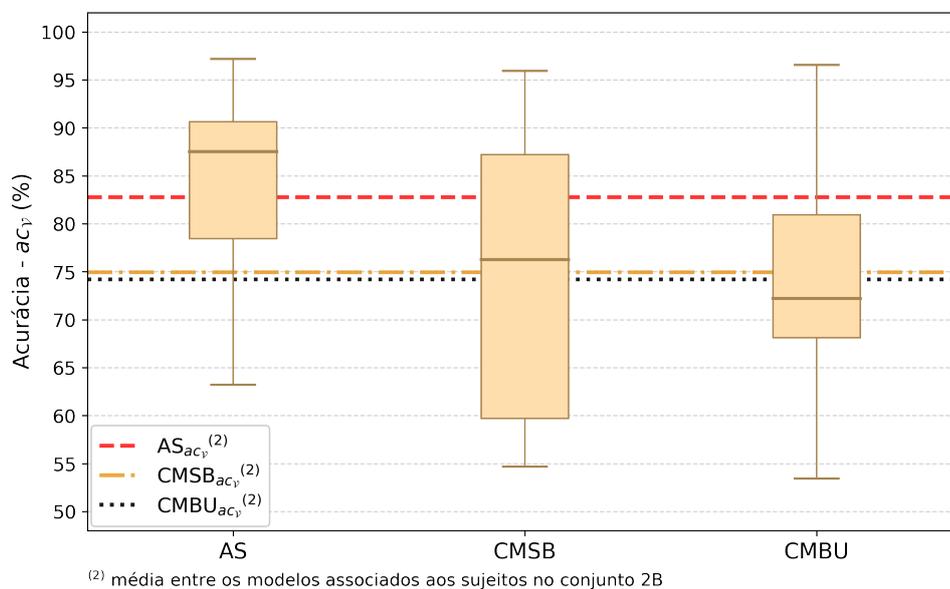
Os resultados na Tabela 8 mostram que, para todos os sujeitos em 2B, os modelos produzidos pela configuração automática superaram de maneira significativa a performance dos modelos oriundos de configurações manuais e típicas. Assim como na análise anterior para o conjunto 2A, o ganho médio de desempenho com o *auto setup* também foi observado para cada sujeito.

Os sujeitos 10 e 18, cujos modelos AS foram 18,7 e 17,5 mais assertivos, respectivamente, representaram os maiores ganhos em relação à abordagem CMSB ao passo que os modelos AS de 12 e 14, com acurácias 11,9% e 20,6% superiores às contrapartes CMBU são os de maior ganho entre esses dois modos de configuração. Para fins de referência, um ganho de desempenho de 20% representa 60 classificações corretas a mais, o que demonstra que a busca por uma arquitetura de processamento otimizada para esses sujeitos foi capaz de redefinir a capacidade do sistema em reconhecer os padrões que descrevem a IM nos dados de EEG.

Um aspecto interessante nos resultados é que, em se tratando da comparação entre a CMSB e CMBU, especificamente, os modelos ajustados sob uma cadeia de banda única obtiveram eficácia superior aos modelos de sub-bandas em 3 dos 9 sujeitos e para outros 3, as diferenças de acurácias entre os dois modos de configuração manual foram menores que 1,3%, aspecto que reflete na proximidade entre as médias obtidas para ambos. Novamente, esses casos sugerem que o uso da cadeia de sub-bandas com configurações típicas nem sempre define modelos de classificação com maior capacidade preditiva. Nos casos citados, a estimativa dos hiperparâmetros combinada ao uso de sub-bandas foi preponderante na definição desses modelos.

Nota-se que o aumento no número de classificações corretas a partir dos modelos *AS* em todos os sujeitos reduziu a dispersão entre as acurácias, no entanto, esta dispersão continua elevada uma vez que, para alguns sujeitos no conjunto 2B, o reconhecimento dos padrões de IM nos sinais de EEG continua ineficaz se comparado à outros sujeitos, mesmo com o *auto setup*. Logo, o *boxplot* na Figura 64 ajuda a evidenciar que alguns sujeitos têm dificuldade em modular a atividade cerebral a ponto de induzir os padrões de IM esperados, este aspecto reflete em modelos com baixa capacidade preditiva independente do tipo de configuração usada.

Figura 64. Diagrama de caixas para as acurácias médias de validação dos modelos obtidos a partir dos três modos de configuração hiperparamétrica para os 9 sujeitos na base 2B



Fonte: Autoria própria

Como nota-se, a diferença entre a média e a mediana das acurácias de validação do *auto setup* é significativa, muito pelo baixo desempenho relativos dos modelos associados aos sujeitos 11 e 12. Ao adotar a mediana como medida de centralidade, o ponto médio entre as acurácias obtidas com o *auto setup* é de 87,5%, uma diferença de 4,7% em relação

à média. Este cenário é diferente quando se trata das abordagens de configuração manual, em que os valores de média e mediana são menos discrepantes.

Para uma discussão mais específica dos modelos ótimos, os valores assumidos pelos múltiplos hiperparâmetros estão organizados na Tabela 9, onde a diversidade entre as configurações ótimas dos sujeitos é novamente evidente.

Tabela 9. Instâncias ótimas do conjunto de hiperparâmetros obtidas com *auto setup* para os 9 sujeitos do conjunto 2B

<i>Suj.</i>	$F_l - F_u$ (Hz)	$J_d ; J_l$ (s)	N_s	N_r	ϕ	Parâmetros de ϕ
10	00 – 39	0,0 ; 4,0	20	2	LDA	–
11	03 – 30	0,5 ; 3,0	21	2	LR	–
12	01 – 29	0,5 ; 1,5	20	2	SVM	$\phi_c = 10^{-1}$ $\phi_k = Gaussian$
13	07 – 39	0,5 ; 2,0	10	2	KNN	$\phi_{nn} = 15$ $\phi_m = Manhattan$
14	02 – 42	0,0 ; 3,5	11	2	MLP	$\phi_{ne} = 70$ $\phi_{eta} = 10^{-4}$
15	06 – 35	0,0 ; 4,0	14	2	MLP	$\phi_{ne} = 20$ $\phi_{eta} = 10^{-4}$
16	07 – 33	0,5 ; 3,5	18	2	SVM	$\phi_c = 10^{-3}$ $\phi_k = Linear$
17	05 – 23	0,5 ; 3,0	2	2	LR	–
18	07 – 44	0,5 ; 3,0	25	2	KNN	$\phi_{nn} = 11$ $\phi_m = Manhattan$

À exemplo do modelo referente ao sujeito 5 do conjunto 2A, os modelos AS dos sujeitos 10 e 15 foram treinados a partir de toda a informação temporal disponível. Ademais, em contraposição ao observado entre os sujeitos do conjunto 2A, a maioria dos modelos provenientes do *auto setup*, 7 de 9 são ajustados a partir de segmentos de EEG, pelo menos 50% maiores em relação à largura típica, i. e. $J_l \geq 3$.

Invariavelmente, uma janela temporal maior também implica aproximação da dica e juntos, esses aspectos sugerem a existência de informação útil do ponto de vista de classificação das intenções motoras fora do segmento de tempo convencional ($J = [0, 5; 2]$) para a maioria dos sujeitos na Tabela 9.

Assim como no domínio temporal, o espectro é amplamente explorado pelos modelos AS, conforme já havia ficado evidente na Figura 60. As otimizações para os sujeitos 10, 14 e 18 por exemplo, resultaram em um amplo intervalo de frequências usado na filtragem temporal enquanto que para o sujeito 17 esse intervalo é menor inclusive em relação ao intervalo comumente adotado na CMBU. Frequências de cortes mais esparsas e cadeias de processamento ótimas formadas por quantidades elevadas de sub-bandas sugerem uma maior distribuição da informação espectral discriminativa para a maior parte dos sujeitos no conjunto 2B.

Outro aspecto diz respeito à proporção entre os classificadores, com a ocorrência de todas as técnicas consideradas no domínio de ϕ em pelo menos uma entre as 9 instâncias

hiperparamétricas ótimas. O LDA, usado no modelo de classificação do sujeito 10 foi a única técnica com apenas uma ocorrência observada, uma constatação surpreendente dada a notória eficácia dos discriminantes lineares de *Fisher* na classificação de padrões de IM em sistemas ICM (LOTTE et al., 2007).

Em consonância com o que foi realizado no âmbito do conjunto 2A, a Tabela 10 apresenta o comparativo dos desempenhos de classificação obtidos com o *auto setup* no conjunto 2B aos desempenhos reportados em trabalhos correlatos. Dentre os trabalhos considerados estão algumas das principais referências usadas na idealização do método de configuração automática de hiperparâmetros.

Tabela 10. Comparativo entre o desempenho de classificação dos modelos obtidos com o *auto setup* e os melhores resultados em trabalhos validados usando os dados do conjunto 2B na avaliação de seus métodos

Suj.	AS_{acv}	Ang et al. (2012a)	Brodu, Lotte e Lécuyer (2012)	Bashashati et al. (2015)	Bashashati, Ward e Bashashati (2016b)	Kumar, Sharma e Tsunoda (2017)
10	78,4	70,0	77,5	61,4	67,2	80,8
11	63,2	60,4	56,4	56,3	61,8	58,4
12	65,3	60,9	51,9	56,1	59,3	56,0
13	97,2	97,5	93,4	93,8	93,4	99,4
14	90,6	92,8	96,9	65,6	71,5	90,5
15	87,5	80,7	87,8	76,1	79,5	82,0
16	81,9	77,5	70,6	59,1	74,6	88,9
17	93,1	92,5	80,0	92,2	91,6	89,5
18	87,5	87,2	78,8	78,0	83,8	83,7
$\mu \pm \sigma$	82,8 ± 11,9	79,9 ± 13,1	77,0 ± 14,5	70,9 ± 13,9	75,8 ± 11,5	81,0 ± 13,8

Nota-se pelas acurácias individuais na Tabela 10 que o desempenho do *auto setup* no conjunto 2B também foi satisfatório na comparação com os resultados de outros trabalhos. Para além de obter a melhor média de classificação entre os 9 sujeitos, a estratégia de configuração automática proposta proporcionou a geração de modelos mais generalistas em 4 dos 9 sujeitos, mesmo no comparativo com outras técnicas robustas de processamento. Ademais, ainda que tenha apresentado desempenhos inferiores em 5 comparações, os respectivos modelos AS mantiveram os níveis de acurácia nesses casos.

Vale pontuar que, para os sujeitos 11 e 12 destacados anteriormente, ainda que mantida a acurácia abaixo de 70%, os modelos providos pelo *auto setup* obtiveram o melhor desempenho entre todos os trabalhos de referência, o que mostra a eficácia do método proposto mesmo em casos em que a discriminação entre as classes de IM é historicamente ruim.

A respeito dos estudos considerados, na terceira coluna da Tabela 10 estão representadas as acurácias de validação reportadas por Ang et al. (2012a), tido como um

estudo consagrado na literatura de ICM-IM de sub-bandas ao ser referenciado em muitos trabalhos nessa linha. Os autores avaliaram diferentes algoritmos baseados em informação mútua para seleção automática da faixa de frequência discriminativa do sujeito enquanto configuraram os demais parâmetros do sistema de forma manual. Um método *Bayesiano* foi usado como único classificador final cujos desempenhos são mostrados na Tabela 10.

Na coluna 4 as acurácias provêm do estudo de Brodu, Lotte e Lécuyer (2012) que discutiram duas novas características para ICM-IM, uma baseada na medição da regularidade do sinal e outra no grau de complexidade preditiva da série temporal de EEG, cujas acurácias médias foram inferiores em relação ao uso de características típicas baseadas na potência de banda (PB). Nesse sentido, os resultados na Tabela 10 representam o melhor desempenho obtido na classificação de características PB usando o LDA.

Bashashati et al. (2015), por sua vez, utilizaram um processo de busca em grade semi-automática para sintonizar os hiperparâmetros da janela temporal usada na extração de características e do número de filtros CSP. Os autores compararam os resultados individuais para 2 tipos de características e 7 técnicas de classificação distintas. As acurácias na coluna 5 da Tabela 10 correspondem ao desempenho do LDA, classificador com melhor desempenho médio de classificação entre os sujeitos do conjunto 2B tendo PB como característica extraída dos sinais.

Em momento posterior, os mesmos autores propuseram um algoritmo totalmente automático, escalonável e computacionalmente barato que usa a otimização *Bayesiana* para ajustar esses hiperparâmetros em Bashashati, Ward e Bashashati (2016b). Em sua abordagem as saídas dos diferentes instâncias de classificadores treinados nas iterações foram considerados no ajuste de um classificador final. Diferentemente deste trabalho em que o algoritmo *TPE* proposto por (BERGSTRA et al., 2011) foi usado para estimar a distribuição posterior sobre a função objetivo na otimização *Bayesiana* do *auto setup*, os autores em Bashashati, Ward e Bashashati (2016b) usaram o método de Processo Gaussianos para o mesmo propósito.

Bashashati, Ward e Bashashati (2016b) usaram LR como classificador de instâncias e a regressão logística múltipla (MLP) como classificador final, ajustado a partir das meta-classificações geradas pelos classificadores de instâncias hiperparamétricas e compararam os resultados individuais para 2 tipos de características. As acurácias na coluna 6 da Tabela 10 correspondem ao desempenho tendo PB como a característica extraída dos sinais.

Por fim, em Kumar, Sharma e Tsunoda (2017), assim com no estudo de Ang et al. (2012a), o conceito de informação mútua também foi aplicado para seleção da banda de frequência discriminativa do sujeito em uma cadeia de processamento de sub-bandas. A ideia do método proposto foi utilizar as informações de todos os canais disponíveis

para selecionar efetivamente os bancos de filtros mais discriminativos de cada sujeito. O LDA foi mantido como meta-classificador de sub-banda e o SVM como classificador final, conforme arquitetura SBCSP padrão proposta em (NOVI et al., 2007). Os hiperparâmetros no sistema proposto foram ajustados manualmente a partir de configurações típicas e os experimentos também consideraram dados do conjunto 2B cujos resultados estão incluídos na Tabela 10.

Ao comparar os desempenhos individuais do *auto setup* com os desempenhos obtidos nos trabalhos supracitados, os modelos AS apresentaram uma capacidade de generalização inferior considerada significativa ($> 3\%$) em apenas dois sujeitos (14 e 16). Para o primeiro a perda em acurácia registrada é de 6,3% em relação ao desempenho obtido por Brodu, Lotte e Lécuyer (2012) e para o segundo essa perda esta na ordem de 7% em relação ao desempenho obtido por Kumar, Sharma e Tsunoda (2017). Para os demais sujeitos, os modelos AS generalizaram melhor ou tão bem quanto os demais modelos nos trabalhos de referência.

7.1.3 Resultados para o conjunto de sujeitos LE

Finalmente, para os 54 sujeitos do conjunto LE, os dados de validação \mathcal{D}_V contemplam $N_V = 200$ ensaios sendo $N_p = 100$ para cada classe (ME vs. MD). Devido ao número expressivo de sujeitos disponíveis, julgou-se inviável a apresentação de todos os desempenhos e hiperparâmetros ótimos obtidos.

Assim, as discussões a seguir concentram-se nos resultados mais relevantes regidos pelos maiores e menores ganhos de desempenho observados entre os modelos provenientes do *auto setup* e da abordagem de configuração manual mais sofisticada e de melhor desempenho médio entre os sujeitos de LE, ou seja, CMSB.

Isto posto, a Tabela 8 apresenta as acurácias de validação dos modelos associados à 12 dos 54 sujeitos. Como é possível observar, os sujeitos são apresentados na ordem decrescente dos valores na coluna 5, a qual representa o ganho em acurácia calculado pela diferença entre os desempenhos AS e CMSB apresentados nas colunas 2 e 4, respectivamente.

Conforme discutido anteriormente, o maior ganho médio em acurácia de validação do *auto setup* em relação às abordagens de referência considerando as 3 bases públicas foi observado entre os sujeitos de LE. Os desempenhos individuais nas primeiras linhas da Tabela 11, os quais revelam ganhos expressivos acima de 20%, ou seja, um acréscimo superior a 40 novas classificações corretas com o *auto setup*, torna ainda mais evidente a contribuição da busca por uma configuração hiperparamétrica ótima em alternativa às abordagens de configuração manual.

Por outro lado, nas linhas inferiores da Tabela 11 observa-se que, para alguns

Tabela 11. Acurácias de validação individuais dos modelos associados aos sujeitos do conjunto LE e ajustados usando CMSB, CMBU, e AS. As colunas 5 e 6 denotam os ganhos de desempenho obtidos com o AS em relação às contrapartes de configuração manual

Suj.	AS_{acv}	$CMSB_{acv}$	$CMBU_{acv}$	$(AS_{acv} - CMSB_{acv})\downarrow$	$(AS_{acv} - CMBU_{acv})$
53	97,0	62,5	59,5	34,5	37,5
48	83,5	52,5	62,5	31,0	21,0
61	92,5	62,0	63,0	30,5	29,5
24	88,5	58,5	59,5	30,0	29,0
63	95,5	66,5	65,5	29,0	30,0
23	91,0	63,0	71,0	28,0	20,0
35	72,5	48,0	47,5	24,5	25,0
19	85,0	63,5	62,0	21,5	23,0
26	73,0	54,0	61,5	19,0	11,5
⋮	⋮	⋮	⋮	⋮	⋮
47	99,5	96,5	96,5	3,0	3,0
69	57,0	54,0	52,5	3,0	4,5
71	54,5	54,5	49,5	0,0	5,0
$\mu \pm \sigma$	75,9 ± 14,7	62,1 ± 13,8	61,4 ± 12,3	13,8 ± 8,1	14,5 ± 8,9

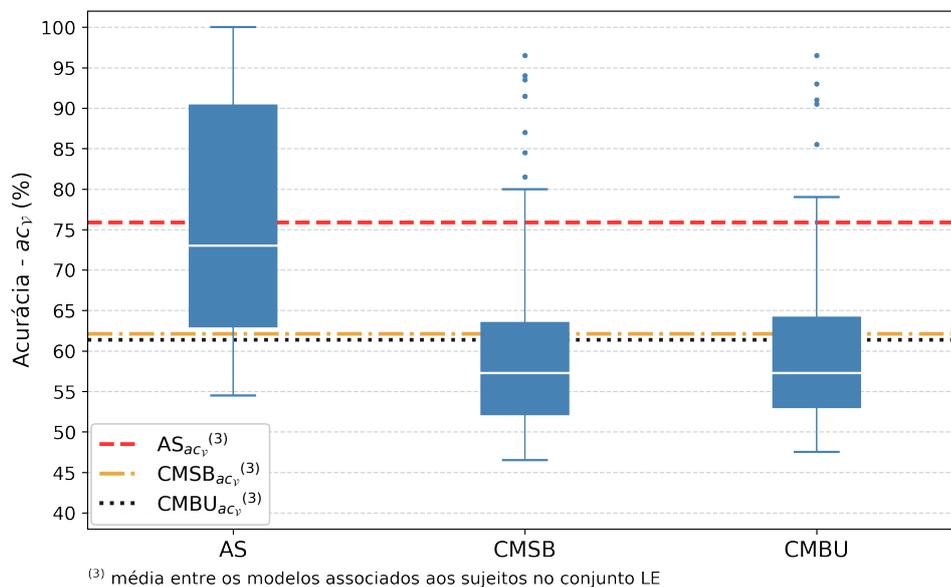
sujeitos a medida do aumento de desempenho com o *auto setup* não foi tão expressiva, em parte pela notória dificuldade constatada nos modelos nos três tipos de configuração em reconhecer os padrões discriminativos dos respectivos sujeitos, identificados em outro estudo como analfabetos em ICM-IM (LEE et al., 2019).

Seguindo o padrão de visualização usado na análise das bases 2A e 2B, a Figura 65 ilustra a dispersão entre os desempenhos obtidos com cada um dos modos de configuração nos dados de todos os 54 sujeitos da base LE.

Diferentemente das demais bases de públicas análises, a média é maior que a mediana entre as acurácias associadas aos modelos AS ao contrário das acurácias nos modelos CMSB e CMBU. Essa característica na centralidade dos desempenhos indica que para a maior parte dos sujeitos os respectivos modelo AS generalizaram abaixo da média entre todos os sujeitos, havendo compensação a partir dos sujeitos relacionados aos altos ganhos demonstrados na Tabela 11.

Para uma visão mais abrangente desse aspecto, o gráfico na Figura 66 mostra a dispersão das acurácias de validação dos 54 modelos nos três modos de configuração por outro prisma. Para facilitar a visualização dos dados, os índices dos sujeitos foram reorganizados em ordem crescente com base na acurácia de validação no *auto setup*. A curva sólida em vermelho representa as acurácias de validação obtidas via *auto setup* (denotadas pelos pontos na curva) e os demais pontos fora desta curva denotam as acurácias obtidas a partir das abordagens de configuração manual dos hiperparâmetros, CMSB e CMBU.

Figura 65. Diagrama de caixas para as acurácias médias de validação dos modelos obtidos a partir dos três modos de configuração hiperparamétrica para os 54 sujeitos na base LE



Fonte: Autoria própria

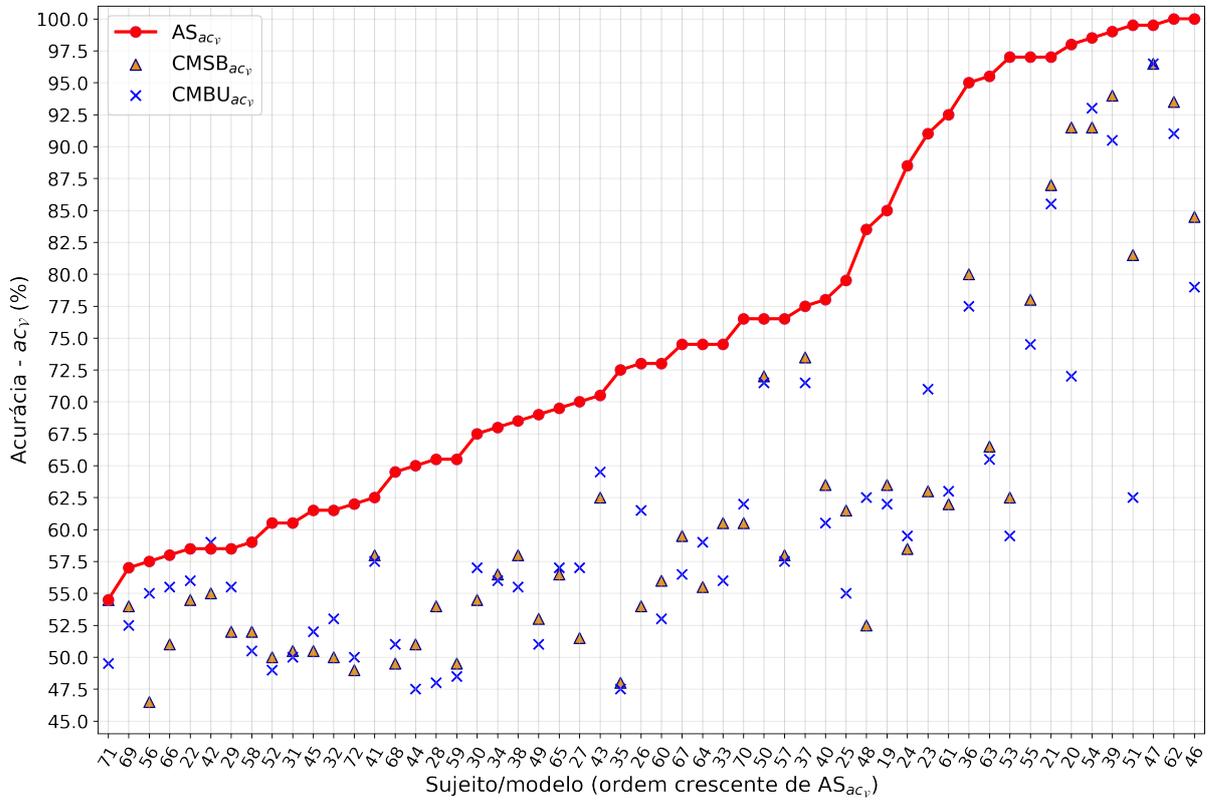
A Figura 65 ressalta dois aspectos principais. O primeiro diz respeito aos erros entre os pontos que representam CMSB e CMBU para os pontos que representam AS, os quais mostram graficamente que a busca pelas instâncias ótimas dos hiperparâmetros é viável para praticamente todos os sujeitos. No entanto, o segundo aspecto evidenciado corresponde ao fato de que a maioria das acurácias obtidas com o *auto setup* (31 de 54) está abaixo da média de 75,9% comprovando que o desempenho geral do AS se deve, em grande medida, aos modelos associados aos 23 sujeitos sobressalentes.

A fim de demonstrar as instâncias hiperparamétricas ótimas associadas aos desempenhos da Tabela 8, a Tabela 12, por sua vez, é apresentada seguindo o mesmo padrão de ordenação entre os sujeitos.

Em contraponto ao padrão observado no universo completo de sujeitos LE, onde o KNN obteve o maior número de ocorrências, entre os modelos AS que apresentaram os maiores ganhos em acurácia comparado aos modelos CMSB, o classificador SVM foi o mais comum, assumindo tanto formas lineares quanto não lineares e diferentes valores para os parâmetros de regularização. Um outro padrão observado na Tabela 12 consiste na manutenção do número de filtros espaciais próximo aos 3 pares o que corrobora com os valores sugeridos por Lotte e Guan (2011) ao hiperparâmetro N_r .

Dois conjuntos ótimos de hiperparâmetros chamam a atenção na Tabela 12, o primeiro associado a sujeito 63 cuja janela temporal usada na extração das épocas de treinamento do modelo estão mais longe da dica em relação aos demais sujeitos onde a localização da informação temporal útil pode indicar um atraso no engajamento do sujeito

Figura 66. Dispersão das acurácias de validação dos modelos associados aos 54 sujeitos do conjunto LE e obtidos usando o *auto setup* (pontos na curva sólida em vermelho) e as abordagens de configuração manual do sistema. Os sujeitos estão posicionados no eixo horizontal em ordem crescente das acurácias do modelo AS para uma melhor comparação entre os desempenhos individuais



Fonte: Autoria própria

em reação à dica visual apresentada no protocolo experimental de coleta.

O segundo ponto diz respeito aos valores assumidos pelos hiperparâmetros que definem o intervalo de frequências, Δ_f , os quais correspondem à todo o espectro disponível no domínio de configuração. Tais definições podem indicar que há informação discriminativa nas frequências mais altas (ritmo γ_r) e mais baixas (ritmo δ_r).

Uma vez que a publicação dos dados do conjunto LE é relativamente recente (LEE et al., 2019; KWON et al., 2019), no momento da escrita deste documento ainda são escassos os trabalhos que aplicam seus métodos nesses dados. Sendo assim, a comparação externa dos resultados obtidas com o *auto setup* seria possível apenas em relação ao próprio trabalho que deu publicidade aos dados de EEG.

Ainda assim, como o procedimento experimental adotado em Lee et al. (2019) possui diferenças importantes comparado ao experimento de validação *off-line* do AutoBCI usando o conjunto LE, especialmente no que tange ao número e à disposição dos canais usados nos dois experimentos, sendo $P = 20$ vs. $P = 16$, respectivamente, a comparação

Tabela 12. Instâncias ótimas do conjunto de hiperparâmetros responsáveis pelos maiores e melhores ganhos de desempenho ao aplicar o *auto setup* em relação às configurações manuais entre os sujeitos da base pública LE

<i>Suj.</i>	$F_l - F_u$ (Hz)	$J_d ; J_l$ (s)	N_s	N_r	ϕ	Parâmetros de ϕ
53	00 – 37	0,5 ; 2,5	3	6	SVM	$\phi_c = 10^{-3}$ $\phi_k = linear$
48	11 – 30	0,5 ; 3,5	18	2	SVM	$\phi_c = 10^{-6}$ $\phi_k = Gaussian$
61	03 – 36	0,5 ; 3,0	11	6	KNN	$\phi_{nn} = 18$ $\phi_m = Manhattan$
24	00 – 45	0,5 ; 3,0	14	4	LDA	–
63	05 – 30	1,5 ; 2,5	16	2	SVM	$\phi_c = 10^{-4}$ $\phi_k = Sigmoidal$
23	10 – 38	0,5 ; 3,0	15	8	LDA	–
35	03 – 35	1,0 ; 2,5	14	4	SVM	$\phi_c = 10^{-6}$ $\phi_k = Gaussian$
19	11 – 25	0,5 ; 2,5	9	4	SVM	$\phi_c = 10^{-3}$ $\phi_k = linear$
26	00 – 29	0,5 ; 1,5	15	8	KNN	$\phi_{nn} = 18$ $\phi_m = Euclidean$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
47	03 – 44	1,5 ; 2,5	11	4	MLP	$\phi_{ne} = 90$ $\phi_{eta} = 10^{-2}$
69	13 – 26	0,0 ; 4,0	6	2	LR	–
71	03 – 38	0,5 ; 2,0	21	4	SVM	$\phi_c = 10^{-2}$ $\phi_k = Gaussian$

entre os dois trabalhos não foi considerada integralmente justa.

Destarte, de modo a tornar o trabalho *auto* contido, optou-se por representar na Tabela 13, apenas os desempenhos médios entre os 54 sujeitos obtidos nas 4 arquiteturas avaliadas em (LEE et al., 2019) e o erro entre esses desempenhos médios e o desempenho médio do *auto setup*.

Tabela 13. Comparativo entre a acurácia (%) dos modelos individuais obtidos com o *auto setup* e os melhores resultados em estudos citados ao longo deste trabalho os quais usaram o conjunto de dados LE na avaliação de seus métodos, não necessariamente relacionados à otimização hiperparamétrica em ICM-IM

	AS_{acm_V}	CSP ¹	CSSP ¹	SBCSP ¹	BSSFO ¹
$\mu \pm \sigma$	75,9 ± 14,7	68,6 ± 17,4	69,7 ± 18,4	70,6 ± 18,4	71,0 ± 18,7
Ganho AS		+7,3	+6,2	+5,3	+4,9

Guardadas as controvérsias entre os experimentos, o que se pode inferir a partir dos resultados na Tabela 13 é que o uso do *auto setup* proporcionou uma melhora importante no desempenho médio de classificação em referência às quatro estratégias por Lee et al. (2019) sem se distanciar muito do padrão de desempenho reportado. No entanto, não foi possível determinar o quanto os ganhos representados são influenciados pelas diferenças nos experimentos.

¹ Lee et al. (2019)

7.1.4 Análise de eficiência computacional: FFT *vs.* filtro convencional IIR

Ainda no contexto de validação *off-line*, além do comparativo de desempenho entre os modos de configuração, testes adicionais foram realizados com o intuito de analisar o desempenho do *auto setup* quanto à eficiência no treinamento dos modelos. O objetivo desta vez é validar eficiência da estratégia baseada no uso da FFT na etapa de filtragem de sinais, justificada na seção 5.2.6.1.3, a qual foi incorporada ao *auto setup* a fim de minimizar a elevação do tempo de ajuste dos modelos de classificação inerente à cadeias de sub-bandas.

Nesse sentido, durante a execução da busca *Bayesiana* no *auto setup*, as $N_{iter} = 100$ instâncias do conjunto de hiperparâmetros foram registradas juntamente com os respectivos modelos de classificação ajustados a fim de que posteriormente fossem usados na classificação das épocas de validação em \mathcal{D}_V . O objetivo foi obter para cada um dos 72 sujeitos, além da acurácia de validação do modelo ótimo proveniente do *auto setup*, \mathcal{M}_{h_*} , as outras 99 acurácias de validação dos modelos candidatos, \mathcal{M}_{h_i} , associadas ao uso da FFT como instrumento de filtragem temporal.

Com o registro das instâncias hiperparamétricas ótima e candidatas foi possível aplica-las na configuração de novas cadeias de processamento similares, porém, desta vez, usando uma filtragem convencional, comumente adotada na literatura, e que consiste na aplicação de um banco de filtros passa-faixa de modelo *butterworth* de 5ª ordem. As novas configurações geraram novos modelos de classificação a partir dos dados de treinamento, \mathcal{D}_V , que, por sua vez, foram aplicados nos dados de validação \mathcal{D}_V , obtendo-se 100 acurácias de validação associadas ao uso do IIR como instrumento de filtragem temporal.

Além das acurácias de validação de ambos os métodos de filtragem, foram contabilizados os tempo de duração do ajuste de cada modelo em segundos, a fim de que fosse possível a comparação entre a adoção dos coeficientes da FFT e dos sinais filtrados pelo IIR nas etapas subsequentes das cadeias de processamento tanto do ponto de vista de desempenho quanto de custo computacional.

Nota-se que as cadeias se diferem unicamente pela técnica de filtragem empregada e como forma de garantir uma comparação justa, buscou-se manter a condição de isonomia entre as abordagens de filtragem, no que tange ao monitoramento do ambiente e dos recursos computacionais utilizados durante os experimentos.

A Tabela 14 apresenta as acurácias médias de validação, acm , e os tempos de ajuste médios, tm , para as duas abordagens de filtragem considerando somente as instâncias ótimas de hiperparâmetros dos 72 sujeitos nas 3 bases públicas de dados incorporadas ao AutoBCI.

Os resultados na Tabela 14 apontam que a aplicação do algoritmo da FFT na etapa

Tabela 14. Acurácias médias de validação e tempos médios de ajuste dos modelos de classificação usando as instâncias ótimas de hiperparâmetros de cada sujeito nos três conjuntos de dados e considerando os dois métodos de filtragem temporal: FFT e IIR.

	acm_{FFT} (%)	acm_{IIR} (%)	tm_{FFT} (s)	tm_{IIR} (s)
2A	88, 51 ± 12, 5	85, 71 ± 14, 0	0, 99 ± 0, 93	3, 76 ± 2, 29
2B	82, 75 ± 11, 9	80, 45 ± 14, 9	1, 06 ± 1, 01	2, 30 ± 1, 86
LE	75, 86 ± 14, 7	72, 02 ± 15, 8	0, 95 ± 0, 90	2, 35 ± 1, 59
Todos	78, 30 ± 14, 7	75, 23 ± 16, 1	0, 97 ± 0, 94	2, 51 ± 1, 79

de filtragem, além de requerer um tempo em média 2,5 vezes menor para ajuste do modelo de classificação, ainda representou uma melhora de aproximadamente 3% na acurácia média em relação ao banco de filtros IIR. Outrossim, as vantagens no uso da FFT se estendem aos 3 conjuntos de dados individualmente indicando a robustez dos resultados.

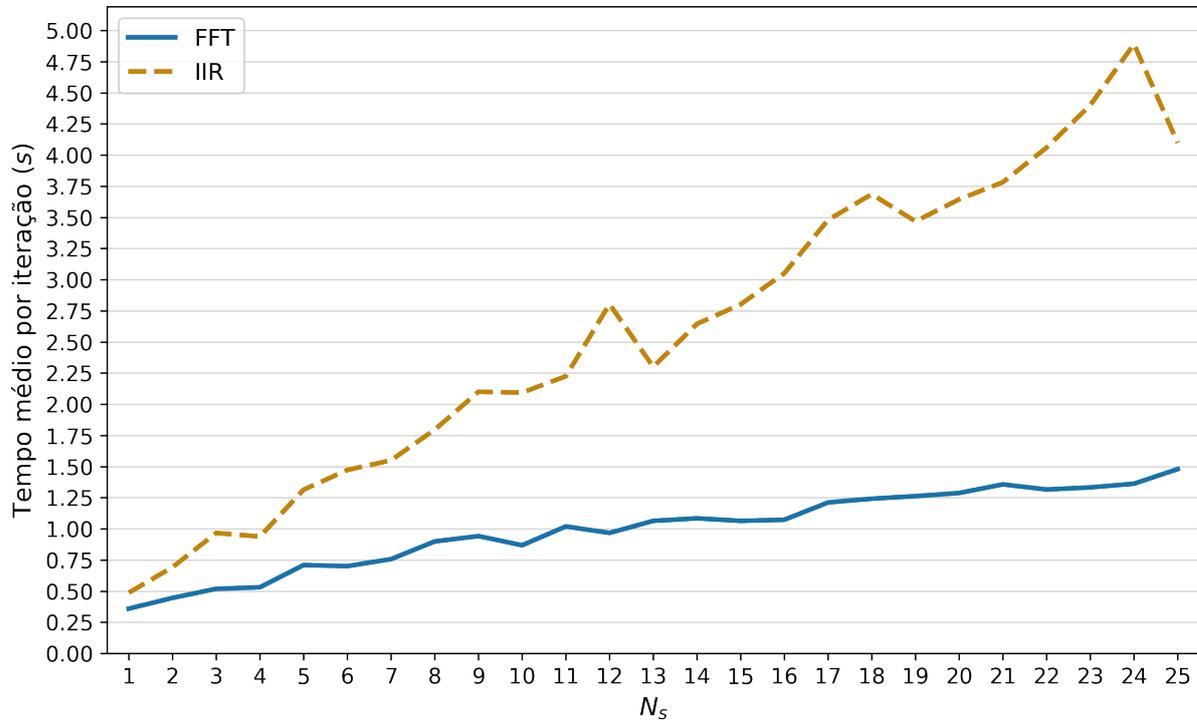
Os números da comparação entre as duas abordagens de filtragem sugere que, apesar de ser muito mais compacta se comparada aos sinais oriundos da filtragem convencional, a matriz de coeficientes complexos resultantes da FFT bem como a decomposição das sub-bandas a partir dos bins de frequências associados à esses coeficientes, não só mantém como ressaltam a informação espectral útil a ponto de se ter vetores de características mais discriminativos. Esses resultados corroboram com a análise realizada no experimento preliminar no apêndice A, porém, agora considerando um universo maior de dados e de sujeitos.

Tendo em vista que na filtragem a partir da FFT a transformação nos sinais de entrada para cálculo dos coeficientes é realizada uma única vez enquanto que com o banco de filtros IIR o número de transformações é proporcional ao número de sub-bandas (N_s) definido em cada instância hiperparamétrica, o gráfico na Figura 67 representa as médias dos tempos de ajuste em função do número de sub-bandas de todos os 7200 ($72 \times N_{iter}$) modelos treinados para cada abordagem de filtragem, FFT e IIR.

Os erros entre os pontos nas curvas do gráfico na Figura 67 mostra a discrepância entre o tempo de ajuste dos modelos usando a FFT (curva sólida na cor azul) e o IIR (curva tracejada na cor laranja). Além disso, conforme o esperado, observa-se um acréscimo progressivo entre os erros a medida em que o número de sub-bandas na cadeia de processamento aumenta (i.e. o valor do hiperparâmetro N_s).

A maior diferença entre os tempos médios de treinamento por número de sub-bandas é observada no ajuste de modelos baseados em cadeias de processamento com $N_s = 24$ sub-bandas, em que decompor os sinais na fase de *Fourier* representa uma redução média expressiva no tempo de ajuste de aproximadamente 3,5 segundos sobre filtrar digitalmente os sinais usando o IIR. Enquanto isso, o menor erro médio no tempo de ajuste de 0,13 (ou

Figura 67. Comparativo do tempo médio de ajuste dos modelos de classificação em função do número de sub-bandas ao filtrar os sinais usando IIR ou FFT. As curvas denotam média entre os tempos de ajuste nas 7.200 iterações do *auto setup* de todos os sujeitos



Fonte: Autoria própria

128 milissegundos) segundos é visto quando $N_s = 1$ equivalente à cadeia de banda única quando a redução do custo de treinamento com a FFT em relação ao IIR é praticamente desprezível.

Ao considerar a diferença média geral entre os métodos no tempo de ajuste dos modelos entre todos os valores de N_s e todos os 7.200 modelos de instâncias têm se uma redução média de aproximadamente 1,6 segundos por modelo ao usar a FFT em alternativa ao IIR. Ao replicarmos esse valor na condição em que as $N_{iter} = 100$ iterações do *auto setup* são executadas para um determinado sujeito usando as duas abordagens de filtragem, tal diferença no tempo de ajuste individual implicaria uma economia média de 2 minutos e 40 segundos ao usar a FFT em detrimento do uso do IIR na busca pela instância ótima do conjunto de hiperparâmetros.

Vale salientar, portanto, que a redução do tempo de computação dos modelos é importante especialmente em cenários de otimização em que múltiplos modelos são avaliados a fim de se encontrar em um deles a melhor acurácia esperada, como é o caso da otimização realizada pelo método *auto setup*.

Nesse sentido, é notório que a proposição da FFT na etapa de filtragem como alternativa à elevação do tempo de processamento de sub-bandas mostrou-se viável uma

vez que, além de ter sido mais eficiente no treinamento dos modelos de classificação, foi capaz de preservar a informação útil para classificação dos padrões de IM nos sinais de EEG com uma eficácia maior que a abordagem típica de filtragem. Além disso, considera-se que a estratégia tende a contribuir para ampliação da usabilidade do AutoBCI e de sistema ICM-IM em geral, haja vista que um dos objetivos desses sistemas é a obtenção de saídas confiáveis o mais rápido possível.

7.2 Resultados dos testes de simulação *on-line*

Em consonância com o procedimento descrito na seção 5.3.2, o objetivo desta seção é apresentar os resultados obtidos com a validação da plataforma desenvolvida em um cenário *on-line* a partir de simulações de controle de um cursor virtual. Os dados públicos de EEG dos mesmos 72 sujeitos considerados nos experimentos anteriores 72, foram utilizados para simular o controle de uma aplicação virtual a partir da tradução das saídas dos classificadores em comandos.

O principal objetivo do experimento é verificar o grau de influência dos ganhos de acurácia apresentados pelo uso do *auto setup* no controle efetivo da aplicação. Assim como na validação *off-line*, a base de referência para o *auto setup* na experimentação *on-line* são as abordagens de configuração manual de banda única e sub-bandas uma vez que elas refletem configurações típicas encontradas na literatura.

Nesse sentido, para fins de comparação, os testes de operação *on-line* foram realizados com a plataforma AutoBCI configurada tanto usando o *auto setup* quanto com valores fixados manualmente a partir de ambas as abordagens de configuração manual, CMBU e CMSB. Os modelos obtidos durante a fase de calibração foram usados na classificação de segmentos de sinais fornecidos em tempo real pelo sistema de aquisição simulada descrito na seção 5.2.4 durante tentativas de controle da aplicação virtual incorporada ao AutoBCI e descrita na seção 5.3.2.1.

Cada um dos 3 modelos de classificação obtidos a partir dos dados nos 72 sujeitos foram usados em 5 sessões de 20 tentativas de controle da aplicação, totalizando 100 tentativas de controle por modo de configuração e, conseqüentemente, 300 tentativas por sujeito, em que as saídas dos modelos era convertida em comando para o cursor virtual de acordo com a estratégia definida na seção 5.2.7.1. A partir das pontuações obtidas durante as sessões do experimento e do tempo decorrido em cada uma delas, foram calculadas 4 métricas para cada sujeito e modo de configuração, tais quais:

1. Taxa média de acerto ao alvo (acm_{hit}): definida por $acm_{hit} = \frac{1}{5} \sum_{s=1}^5 ac_{hit_s}$ onde $ac_{hit_s} = \frac{p_s}{20}$ representa a taxa de acerto do alvo pelo cursor em uma das 5 sessões do experimento de controle simulado. No contexto da aplicação ICM Space Game, essa

métrica indica o número médio de vezes em que a nave foi desviada do asteroide a partir dos comandos gerados com base nas saídas dos modelos.

2. Taxa média de acerto do comando (acm_{com}): representa a taxa em que os comandos gerados foram correspondentes para o cursor tendo em vista os alvos em cada tentativa de controle. Na prática, para tentativas em que o alvo está posicionado à direita da tela esperava-se comandos de direcionamento da nave para a direita e vice-versa (ver Figura 37). A média entre as razões do número de comandos correspondentes ao alvo pelo número de comandos gerados em cada sessão define acm_{com} .
3. ITR média baseado no alvo ($ITRm_{hit}$): definida por $ITRm_{hit} = \frac{1}{5} \sum_{s=1}^5 ITR_{hit_s}$ em que ITR_{hit_s} representa a média de acertos ao alvo por minuto na sessão s e é calculada com base em Eq. (3.35) para $\bar{P} = ac_{hit_s}$, $\bar{N} = 2$ e $\bar{M} = \frac{20}{t_s}$, este último representando o número de tentativas realizadas por minuto uma vez que t_s é o tempo decorrido entre o início da 1ª e o fim da 20ª tentativa em uma sessão. Em suma, a $ITRm_{hit}$ mede a média de acertos ao alvo por minuto considerando as ITRs individuais nas 5 sessões de controle.
4. ITR média baseado no comando ($ITRm_{com}$): equivalente à $ITRm_{hit}$ porém para $\bar{P} = ac_{com_s}$ no cálculo das ITRs individuais por sessão. Sendo assim, $ITRm_{com}$ representa a média de acertos no envio de comandos por minuto considerando as ITRs individuais das sessões.

Tendo como base essas métricas, a Tabela 15 compara a média dos resultados obtidos nos testes de controle *on-line* da aplicação virtual para os três modos de configuração hiperparamétrica utilizados.

Tabela 15. Comparativo entre os resultados da simulação de controle *on-line* usando as médias nas quatro métricas definidas e calculadas com base nos dados de operação obtidos de cada um dos 72 sujeitos e modos de configuração da plataforma AutoBCI

Métrica	Unidade	AS	CMSB	CMBU
acm_{hit}	%	61, 90 ± 23, 7	58, 28 ± 22, 6	54, 78 ± 21, 3
acm_{com}	%	70, 59 ± 19, 6	63, 35 ± 21, 8	63, 09 ± 18, 4
$ITRm_{hit}$	<i>bits</i> /min	1, 10 ± 1, 52	0, 9 ± 1, 4	0, 7 ± 1, 3
$ITRm_{com}$	<i>bits</i> /min	6, 2 ± 7, 4	5, 1 ± 7, 5	4, 1 ± 6, 8

Os resultados apontam que nas tentativas de controle usando os modelos de classificação obtidos com a configuração automática do sistema, em média os sujeitos controlaram o cursor de forma mais assertiva se comparado ao modelos provenientes das configurações manuais.

As melhoras nas taxas médias de acerto nos envios dos comandos e de acerto aos alvos sugerem que o *auto setup* tende a proporcionar um controle mais satisfatório da aplicação, possivelmente devido à uma composição do *buffer* de decisão *d* com uma proporção maior de classificações corretas. Os ganhos médios em ITR, apesar de baixos, também corroboram com essa análise.

No entanto, a dispersão nos resultados e os baixos índices de acerto por minuto medidos, especialmente pelas ITRs, sugere que para muitos sujeitos o tipo de configuração não foi determinante para um do controle da aplicação, sendo que a controlabilidade foi ruim independentemente do modelo usado para classificação.

A fim de investigar a alta dispersão nas médias apresentadas na Tabela 15, a Figura 68 foi idealizada para projetar as ITRs médias associados à configuração automática do AutoBCI nas respectivas ITRs médias associadas às configurações CMSB e CMBU para cada um dos sujeitos. Os pontos de média são correspondentes aos listados nas duas últimas linhas da Tabela 15.

Ao comparar os pontos na Figura 68, nota-se que, de fato, para alguns sujeitos não foram observadas melhoras na controlabilidade do cursor mesmo com o uso dos modelos de classificação que já haviam demonstrado eficácia na validação *off-line*.

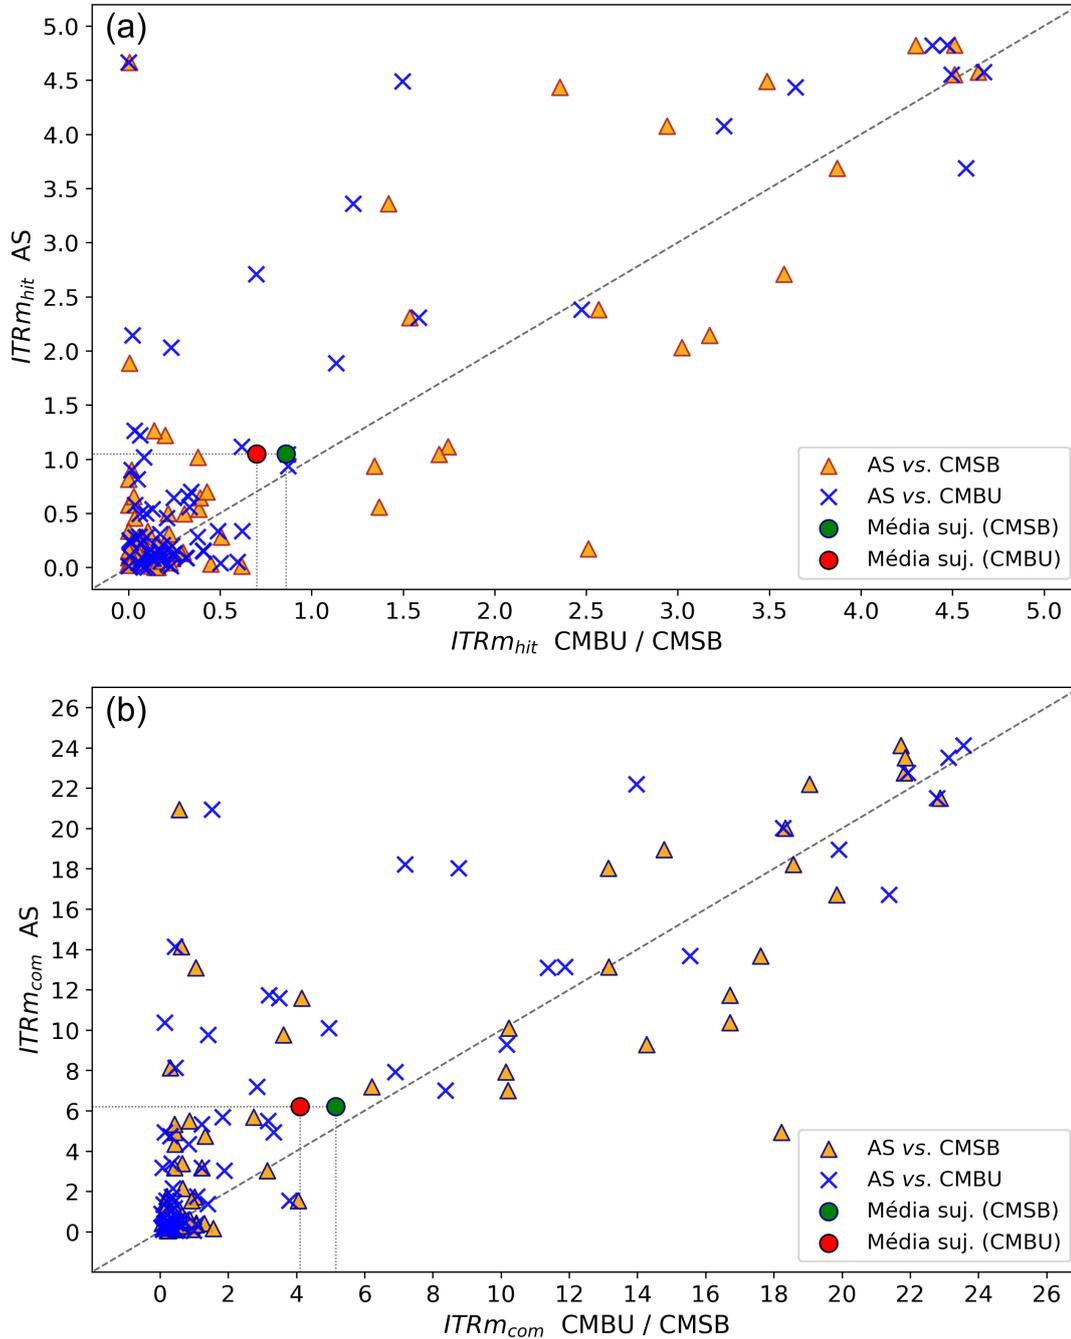
A concentração dos pontos em regiões onde os respectivos ITRs é baixo nas Figuras 68-a e 68-b explica a alta taxa de erros durante as tentativas de controle da aplicação virtual. Além disso, há alta incidência de casos em que o uso de modelos de configurações manuais superam os acertos por minuto usando os modelos de maior acurácia na validação *off-line* corrobora com a baixa correlação entre o tipo de configuração e a efetividade do controle da aplicação no experimento simulado.

Para ressaltar este último ponto, a Tabela 16 apresenta o ranqueamento dos sujeito pela diferença das ITRs calculadas a partir dos dados de controle usando o modelo proveniente do *auto setup* em comparação às ITRs calculadas para os dados de controle enquanto o sistema estava configurado manualmente com cadeia de sub-bandas típica (CMSB).

Ao olhar para as duas últimas colunas nas Tabela 16 nota-se que para a maioria dos sujeitos listados a diferença entre as taxas de sucesso por minuto na condução do cursor até os alvos ao longo das tentativas de controle é inexpressiva. Por inferência, a mesma conclusão pode ser expandida para os 44 sujeitos não listados na Tabela 16, em que os erros entre as ITRs dos três modos de configuração tendem a ser ainda menores.

Em suma, apesar dos ganhos médios obtidos com o AS durante o controle da aplicação todos os aspectos analisados a partir dos resultados nas Tabelas 15 e 16 e na Figura 68 dificultam a inferência sobre o verdadeiro impacto da configuração automática

Figura 68. Comparativo entre as taxas médias de acerto ao alvo (a) e taxas médias de acerto de comando (b) calculadas a partir das tentativas de controle do cursor virtual usando o *auto setup* e as configurações manual da plataforma AutoBCI. Os pontos representam a projeção das ITRs médias obtidas para os 72 sujeitos usando o CMSB e CMBU nas respectivas ITRs médias associadas ao *auto setup*



Fonte: Autoria própria

no controle efetivo da aplicação virtual durante a simulação *on-line*.

Tabela 16. Relação das maiores e menores diferença entre as taxas médias de acerto ao alvo ($ITRm_{hit}$) associadas ao uso do *auto setup* e ao uso representaram aumento em relação às os maiores e menores ganhos em ITR da abordagem AS em relação às abordagens de configuração manual.

<i>Suj.</i>	acm_{hit} (%)	acm_{com} (%)	$ITRm_{com}$ (bits/min)	$ITRm_{hit}$ (bits/min)		
	AS	AS	AS	AS	AS vs. CMSB ↓	AS vs. CMBU
53	100,0 ± 0,0	98,1 ± 0,1	20,9 ± 1,6	4,7 ± 0,1	4,6 ± 0,1	4,6 ± 0,1
1	100,0 ± 0,0	96,7 ± 2,2	18,9 ± 2,7	4,4 ± 0,2	2,1 ± 0,8	0,8 ± 0,8
46	96,0 ± 4,2	97,0 ± 2,6	18,0 ± 2,0	3,4 ± 0,8	1,9 ± 0,9	2,1 ± 1,1
18	87,0 ± 9,1	93,1 ± 2,3	13,1 ± 1,7	1,9 ± 0,9	1,9 ± 0,8	0,8 ± 1,1
9	98,0 ± 4,5	98,1 ± 1,5	20,0 ± 1,9	4,1 ± 1,0	1,1 ± 1,7	0,8 ± 1,1
⋮	⋮	⋮	⋮	⋮	⋮	⋮
36	70,0 ± 10,6	91,1 ± 3,7	10,1 ± 2,1	0,6 ± 0,5	-0,8 ± 0,6	0,2 ± 0,6
7	93,0 ± 2,7	98,2 ± 0,8	18,2 ± 1,3	2,7 ± 0,5	-0,9 ± 0,9	2,0 ± 0,7
13	89,0 ± 6,5	90,4 ± 3,3	11,7 ± 2,2	2,0 ± 0,8	-1,0 ± 1,1	1,8 ± 0,8
5	88,0 ± 8,4	86,7 ± 2,9	10,4 ± 2,0	2,1 ± 1,2	-1,0 ± 1,3	2,1 ± 1,1
20	62,0 ± 2,7	79,8 ± 3,0	4,9 ± 0,9	0,2 ± 0,1	-2,3 ± 0,5	0,0 ± 0,2
$\mu \pm \sigma$	61,9 ± 23,7	70,6 ± 19,6	6,2 ± 7,4	1,1 ± 1,5	0,2 ± 1,0	0,4 ± 1,0

8 CONCLUSÕES E PERSPECTIVAS FUTURAS

Conforme discutido ao longo desta dissertação, uma vez que as respostas cerebrais que definem a intenção motora variam muito de indivíduo para indivíduo assim como para um mesmo indivíduo ao longo do tempo, identificar as variações na atividade eletrofisiológica do cérebro provocadas por tarefas mentais específicas continua sendo uma tarefa difícil (SHAHRIARI et al., 2016; LOTTE et al., 2018). Para que a comunicação provida pela ICM entre o cérebro e a aplicação seja confiável, a seleção das técnicas usadas no processamento é tão importante para a ICM-IM quanto a capacidade do usuário em gerar os padrões cerebrais adequados (CLERC; BOUGRAIN; LOTTE, 2016a).

Não obstante, na fase de treinamento é comum que a configuração da cadeia de processamento seja realizada de forma manual e conforme a experiência do operador, ainda que seja sujeita à imprecisão humana e implique esforço hercúleo, tendendo à produzir modelos incapazes de capturar as características discriminativas de diferentes indivíduos (WEI; WEI, 2016; FENG et al., 2018). Nesse sentido, a estimativa dos hiperparâmetros na ICM-IM é tida como uma abordagem determinante no desenvolvimento de sistemas mais eficazes (BASHASHATI; WARD; BASHASHATI, 2016b; MIAO et al., 2017; ANG et al., 2012a).

Muitos trabalhos tem se dedicado a propor formas de otimizar a sintonia dos hiperparâmetros em sistemas de ICM-IM a fim de que seja possível extrair as particularidades de cada sujeito. Kumar e Sharma (2018), Miao et al. (2017), Wei e Wei (2016), Feng et al. (2018) e Bashashati, Ward e Bashashati (2016a) são alguns dos muitos estudos nesse sentido. Porém, em regra o processo de otimização hiperparamétrica nesses estudos está restrito a etapas específicas do processamento como segmentação, filtragem ou extração de características, por exemplo, e não compreende a cadeia de processamento como um todo.

Diante do exposto, este trabalho propôs uma estrutura baseada em aprendizado *Bayesiano* para configuração automática de hiperparâmetros incorporada à uma nova plataforma computacional ICM-IM de código aberto. Dentre as principais contribuições do estudo está o fornecimento de um ambiente experimental completo e de uso descomplicado que, com base em uma arquitetura de processamento personalizável, favorece o projeto de sistemas mais eficazes e eficientes no reconhecimento dos padrões de IM particulares do usuário e, por consequência, na geração de sinais de comando confiáveis.

Após a revisão bibliométrica apresentada nos primeiros capítulos desta dissertação, em que foram levantados os aspectos teóricos e práticos que envolvem o desenvolvimento de sistemas de ICM-IM, os componentes da plataforma proposta, o AutoBCI, foram descritos. Tais componentes incluem, além dos três módulos típicos da arquitetura de ICM-IM, o método intitulado *auto setup* o qual foi implementado com o propósito de abstrair do

usuário a tarefa de configuração manual dos hiperparâmetros, de modo a descomplicar sua operacionalização, ampliar sua usabilidade e ao mesmo tempo promover melhora na capacidade preditiva do sistema.

Conforme abordado por Stegman et al. (2020), um grande número de softwares para projeto experimental de ICM estão disponíveis. No entanto, apesar da contribuição inequívoca de alguns desses softwares para a popularização e difusão das ICM, sua operacionalização nem sempre é simples e, normalmente, exige de seus usuários uma alta carga de trabalho e um conhecimento específico do contexto multidisciplinar de ICM tanto durante o projeto quanto no uso cotidiano.

Ainda são poucas as plataformas de código aberto com viés prático, escalável e que, ao mesmo tempo, integrem alguma estratégia de otimização hiperparamétrica para facilitar o processo de configuração dos sistemas. Mesmo as opções que atendem à parte dessas características, como a caixa de ferramentas *MatLab* recentemente proposta por Lee et al. (2019), é comum que sejam implementadas usando tecnologias proprietárias, o que tende a restringir seu uso a um grupo menor de usuários e dificultar a incorporação de novas técnicas de processamento e a adaptação a cenários experimentais diversos.

Ao propor uma plataforma própria, modular e escalável neste trabalho, para além de disponibilizar um ambiente *open source* integrado com sistema de aquisição de baixo custo *OpenBCI*, foi possível incorporar múltiplas técnicas de reconhecimento de padrões e compor um amplo espaço de configuração, o qual se provou fundamental na busca por instâncias hiperparamétricas ótimas que levaram ao ajuste de modelos com maior capacidade preditiva. Além disso, os módulos do AutoBCI propiciaram um ambiente controlado para investigação dos efeitos da otimização de hiperparâmetros no desempenho de sistemas de ICM-IM.

Com uma arquitetura menos rígida foi possível realizar uma comparação justa entre a abordagem de configuração automática e as abordagens de configuração manual, com valores típicos da literatura, tanto a partir de cadeias mais sofisticadas baseadas em sub-bandas quanto a partir de banda única, em um só ambiente. Protocolos experimentais de três conjuntos públicos de sinais de EEG foram incorporados à plataforma e os dados dos 72 sujeitos neles disponíveis foram usados em simulações que avaliaram o desempenho de classificação *off-line* e o controle *on-line* da aplicação virtual também disponível no AutoBCI.

Uma melhora expressiva na acurácia de validação foi observada nos modelos produzidos pelo *auto setup* em relação às abordagens de configuração manual. Em média, ao considerar os dados de todos os 72 sujeitos avaliados, os modelos provenientes do processo de configuração automática de hiperparâmetros proporcionaram ganhos de desempenho

de $13,3\% \pm 9,0\%$ e de $12,1\% \pm 7,9\%$ em relação à CMBU e CMSB, respectivamente. A melhora também foi observada na maioria dos modelos individuais dos sujeitos.

Os resultados indicam que a configuração de hiperparâmetros baseada nas características do sujeito tende a minimizar o impacto da variabilidade da atividade cerebral no processo de classificação de IM e a estabelecer um sistema mais generalista. A existência de informação relevante fora dos intervalos comumente usados no ajuste dos modelos de classificação também é evidenciada. Ao redefinir e personalizar esses intervalos por um método de estimativa dos hiperparâmetros, foi possível encontrar e incluir essas informações no processo de extração de características e obter padrões que melhor descrevem a intenção motora de cada indivíduo.

Em cadeias de processamento configuradas com intervalos mais rígidos, definidos independentemente do sujeito, a chance dessas informações serem descartadas é maior quando comparada à cadeias personalizadas automaticamente no AutoBCI. Este aspecto passa a ser relevante, uma vez que os resultados também sugerem que a eficácia da técnica de classificação definida para um determinado usuário depende da extração das características discriminativas do sujeito, as quais, ao serem mapeadas ao espaço de decisão, contribuem para uma maior separabilidade entre as classes.

Destarte, avalia-se que a inclusão das cinco técnicas de classificação e seus respectivos hiperparâmetros no espaço de busca do *auto setup* foi crucial na melhora do desempenho na maioria dos sujeitos, haja vista que, ao comparar com resultados reportados em um dos trabalhos correlatos, Bashashati, Ward e Bashashati (2016b), que também utilizaram a otimização *Bayesiana* em condições similares porém com classificador fixo, o ganho médio em acurácia com o *auto setup* é de 7% para os sujeitos do conjunto 2B. Isso também é observado na diversidade das instâncias ótimas do classificador, com 4 das 5 técnicas ocorrendo em mais de 10 modelos resultantes do *auto setup*.

Ao mesmo tempo em que demonstram a eficácia do *auto setup*, os resultados expressam o desempenho satisfatório do AutoBCI na adaptação da cadeia de processamento conforme os padrões cognitivos de cada usuário e na facilitação do processo de ajuste do sistema, propiciando a obtenção de modelos de classificação mais eficazes em relação à cadeias de processamento rígidas e inespecíficas do sujeito. Em outras palavras, ao reduzir a imprecisão do ajuste manual e a dependência da configuração à expertise do projetista, especialmente para arquiteturas mais sofisticadas, o *auto setup* tende a contribuir, inclusive, na ampliação da usabilidade do sistema.

Muito embora não tenha sido observado melhora significativa para alguns sujeitos no desempenho de generalização com o *auto setup*, a aplicação do método não incorreu em prejuízo nesse sentido e a manutenção da acurácia independentemente do modo

de configuração pode estar associada a dois fatores nesse caso. Primeiro, ao fato de a configuração típica manual já produzir modelos capazes de capturar eficazmente os padrões discriminativos do sujeito. O segundo fator diz respeito aos casos em que alguns sujeitos possuem uma dificuldade natural em gerar os padrões cerebrais necessários para que o sistema, seja configurado manualmente ou de forma automática, consiga separar os padrões que descrevem a IM do fundo ruidoso nos sinais de EEG e classificar a intenção motora.

Um ponto que poderia ser visto como uma desvantagem no processo de configuração automática do *auto setup* é que ele exige um número importante de iterações para que seja possível encontrar as instâncias ótimas de hiperparâmetros. Porém, ao analisar pelo prisma da alta variabilidade entre os sujeitos comprovada pela discrepância entre as instâncias hiperparamétricas ótimas observado o grande número de combinações possíveis, não é difícil inferir que encontrar os mesmos conjuntos de instancias ótimas por meio de configurações manuais, além de improvável seria uma tarefa notadamente inviável.

Ainda assim, a escolha pelo algoritmo FFT na etapa de filtragem temporal no *auto setup* em alternativa ao uso dos filtros digitais convencionais provou-se eficiente não somente por reduzir consideravelmente a elevação do tempo médio de ajuste dos modelos de classificação baseados em cadeias de sub-bandas como também por contribuir com o ganho em acurácia do sistema. Mesmo com uma representação muito mais compacta dos coeficientes resultantes da FFT em relação aos sinais filtrados por IIR nas diferentes sub-bandas, ainda assim a informação espectral útil para classificação foi mantida e, em muitos casos, ressaltada nos coeficientes, o que também pode ser citado como uma das principais contribuições do trabalho.

Com isso, a estrutura proposta para configuração automática dos hiperparâmetros ICM-IM no AutoBCI diferencia-se de outros estudos que aplicam a otimização *Bayesiana* no mesmo contexto em dois pontos principais. Primeiro, no emprego da decomposição em frequência via FFT e uso dos coeficientes resultantes para delimitar as sub-bandas o que, como apontam os resultados na seção 7.1.4, tornam mais eficiente o pré-processamento dos sinais em cada iteração e, por consequência, a busca *Bayesiana* em geral. O segundo ponto refere-se ao aumento da dimensionalidade do espaço de configuração a partir das múltiplas técnicas de classificação e de seus respectivos hiperparâmetros próprios, viabilizado justamente pela suavização do custo de processamento.

Outro diferencial deste trabalho é o número de sujeitos considerados na validação do método, que supera em quantidade todas as amostras usadas em estudos correlatos. A adoção por um grupo maior e mais diverso de sujeitos visou adicionar robustez e confiabilidade aos resultados, afinal, conforme declaram Bashashati et al. (2015), as descobertas em estudos realizados em grupos pequenos de indivíduos podem não generalizar de maneira satisfatória para outros indivíduos.

Apesar do bom desempenho do sistema na validação *off-line* usando a configuração automática, seja na comparação interna com os modos de configuração manual ou na comparação com outros estudos, não foi possível chegar a uma conclusão final sobre o real impacto da otimização dos hiperparâmetros no controle efetivo da aplicação a partir dos resultados nos testes de simulação *on-line* realizados.

Embora tenha sido observada uma melhora sutil nas taxas médias de acerto de comando e de transferência de informação, as altas dispersões observadas para os modos de configuração manual e automática geram incerteza sobre a melhora promovida pelo uso dos modelos AS durante o controle simulado. O que se pode inferir é que a maior assertividade dos modelos obtidos com *auto setup* tendem a contribuir para um controle mais eficaz da aplicação, especialmente para sujeitos considerados aptos a gerar os padrões adequadas para operação de ICMs, uma vez que a chance de o limiar de comando ser atingido é maior à medida que os padrões de IM são classificados corretamente.

Após os testes *off-line*, o cronograma inicial de pesquisa incluía a realização de sessões *on-line* com aquisição de EEG em tempo real usando a placa *OpenBCI Cyton*. No entanto, a experimentação com pessoas foi abortada em virtude da pandemia da Covid-19. Ainda assim, a simulação *on-line* a partir de um grande volume de dados de EEG adquiridos anteriormente, apesar de não ser o procedimento ideal, foi útil para validar a integração entre os módulos do sistema bem como a estratégia de tradução da saída do classificador em sinais de comandos para a aplicação virtual.

Nesse sentido, a validação da plataforma AutoBCI durante um teste de operação com pessoas é sugerido para trabalhos futuros. Isso possibilitaria análise e inferência quanto ao desempenho de classificação e usabilidade de um usuário quando afetado por variáveis como desconforto e perda de engajamento durante o controle *on-line* real.

Para trabalhos futuros também é sugerida a investigação mais aprofundada da influência de cada hiperparâmetro no desempenho de classificação do sistema. Os resultados apresentados no Capítulo 7 sugerem que os hiperparâmetros ótimos mais determinantes para a melhora no desempenho são os associados à janela temporal (J_d e J_l), conforme também avaliam Wei e Wei (2016), assim como a técnica de classificação. Vale ressaltar que, para uma conclusão definitiva sobre esse aspecto, a investigação dos efeitos de um hiperparâmetro em específico exige a fixação de outros o que pode resultar na descaracterização da proposta de integração do método *auto setup* aqui proposto.

A ampliação do espaço de busca do *auto setup* considerando novos graus de liberdade para as etapas de pré-processamento ou extração de características também pode ser investigada em trabalhos futuros. As opções incluem o uso da STFT (BASHAR; BHUIYAN, 2016) ou da Transformada *Wavelet* (KEVRIC; SUBASI, 2017) na etapa de filtragem,

assim como a inclusão de novas abordagens para extração de características como incitam Bashashati et al. (2015).

Da mesma forma, a inclusão de técnicas diferentes de classificação como as baseadas nas métricas de *Riemann* também pode ser explorada (SILVA et al., 2016; YGER; BERAR; LOTTE, 2017). No entanto, é importante ressaltar que a medida que a dimensionalidade do espaço de hiperparâmetros aumenta, o número de iterações necessárias para convergência da busca *Bayesiana* aumenta exponencialmente, o que incorre no aumento do tempo de treinamento do sistema. Assim sugere-se que a inclusão de novos graus de liberdade seja avaliada também na perspectiva do custo.

Como exemplo, testes preliminares baseados no uso de sub-bandas com intervalos não uniformes foram realizados. Porém, seus resultados foram descartados ao apontarem uma redução no desempenho médio de classificação a qual, presume-se, esteja relacionada ao aumento da dimensionalidade e da complexidade do problema de otimização. Uma investigação mais específica acerca do uso de intervalos não uniformes associada à redução do domínio de sub-bandas é recomendada.

No escopo deste trabalho, o valor de P (quantidade de canais de EEG) não foi considerado um hiperparâmetro ajustável pela busca *Bayesiana* do *auto setup* haja vista que uma das intenções era verificar o comportamento do sistema conforme a opção pelo uso do módulo extensor *dayse*, mantendo nas simulações os cenários de aquisição sem a placa *dayse* (conjunto 2B) e com a placa *dayse* (conjunto LE) que seriam avaliados nos testes reais. Dado que na literatura há muitos estudos que propõe formas de otimização também do número de canais de EEG, como em Arvaneh et al. (2011), Lahiri, Rakshit e Konar (2017) e Lopes et al. (2019), por exemplo, a inclusão deste grau de liberdade é incentivada para versões futuras do AutoBCI.

Outra proposta para versões futuras é a expansão para problemas de classificação quaternária, adicionando novas aplicações virtuais (ou reais) com mais graus de liberdade, em que, para além de movimentos horizontais a partir de sinais de comando associados à IM da mão direita e da mão esquerda, possam responder à comandos associados a mais classes de IM. Naturalmente, esta nova abordagem exigiria novas perspectivas de discriminação entre as classes haja vista que algumas técnicas, como o SVM, são apropriadas no primeiro momento para classificação binária. Estratégias comumente usadas nesse sentido são um-contrum ou um-contratodos (XU et al., 2011), por exemplo, porém outras abordagens podem ser experimentadas (YANG et al., 2017; GE; WANG; YU, 2014; ANG et al., 2012a; KRISHNA; PASHA; SAVITHRI, 2016).

Enfim, são amplas as possibilidades de continuação deste trabalho. Considerar outros tipos de respostas neurais usando os potenciais visualmente evocados em conjunto com a IM

para formatação de uma ICM híbrida, por exemplo, pode ser incluída como sugestão para projetos futuros (AMIRI; FAZEL-REZAI; ASADPOUR, 2013a; WANG et al., 2019). Novas estratégias de otimização baseadas em algoritmos evolucionários (NICOLAS-ALONSO; GOMEZ-GIL, 2012), como a proposta por Wei e Wei (2016), também podem ser exploradas em novas implementações. Todas as propostas e perspectivas futuras supracitadas são viabilizadas com a livre disponibilização do código da plataforma AutoBCI em ambiente público, estando acessível à toda a comunidade científica e apta a receber contribuições.

9 PUBLICAÇÕES

A seguir estão listadas as publicações realizadas no decorrer do trabalho:

- Artigo completo publicado: VILAS-BOAS, Vitor Mendes; SILVA, Cleison Daniel. Configuração Automática de Hiperparâmetros em Sistemas MI-BCI de Sub-bandas. In: **XXXVIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais - SBrT'20**. Florianópolis, SC, Brasil, 2020. Disponível em: <<http://www.sbrt.org.br/sbrt2020/papers/1570655427.pdf>>
- Artigo completo publicado: VILAS-BOAS, Vitor Mendes; DA SILVA JORGE, Vitor; SILVA, Cleison Daniel. Towards ideal time window for classifying motor imagery in brain-computer interfaces. In: **Anais do VIII Symposium on Knowledge Discovery, Mining and Learning**. SBC, 2020. p. 73-80. Disponível em: <<https://doi.org/10.5753/kdmile.2020.11961>>.
- Artigo completo publicado: LOPES, T. D. J., Machado, W., Calvinho, J. V., Vilas-Boas, V. M., Silva, C. D. Interface Cérebro-Máquina baseada em Imagética Motora: Estudo comparativo da quantidade de canais de EEG. In: **XIV Congresso Brasileiro de Inteligência Computacional - CBIC**. Belém, PA, Brasil, 2019. Disponível em: <<http://dx.doi.org/10.21528/CBIC2019-62>>.
- Resumo disponível no apêndice A, submetido e aceito na conferência internacional *ICAH 2020: International Conference on Augmented Human*¹. Por razões logísticas não foi possível a participação no referido evento ocorrido nos dias 03 e 04 de Fevereiro de 2020 em Melbourne, Austrália. Uma vez não publicado, o artigo completo intitulado *Frequency Decomposition Approach for Sub-Band Common Spatial Pattern Methods for Motor Imagery Based Brain-Computer Interface* será submetido em breve em nova conferência qualificada a ser definida.

¹ <https://waset.org/conference/2020/02/melbourne/ICAH>

REFERÊNCIAS

- ABDULKADER, S. N.; ATIA, A.; MOSTAFA-SAMI, M. M. Brain computer interfacing: Applications and challenges. **Egyptian informatics Journal**, v. 16, n. 2, p. 213–230, Jul. 2015. ISSN 1110-8665. Disponível em: <<https://doi.org/10.1016/j.eij.2015.06.002>>.
- ABIRI, R. et al. A comprehensive review of EEG-based brain – computer interface paradigms. **Journal of neural engineering**, v. 16, n. 1, 2019. ISSN 1741–2552. Disponível em: <<https://doi.org/10.1088/1741-2552/aaf12e>>.
- ACUNZO, D. J.; MACKENZIE, G.; van Rossum, M. C. Systematic biases in early ERP and ERF components as a result of high-pass filtering. **Journal of Neuroscience Methods**, v. 209, n. 1, p. 212 – 218, 2012. ISSN 0165-0270. Disponível em: <<https://doi.org/10.1016/j.jneumeth.2012.06.011>>.
- AGUILAR, J. M.; CASTILLO, J.; ELIAS, D. EEG signals processing based on fractal dimension features and classified by neural network and support vector machine in motor imagery for a BCI. In: BRAIDOT, A.; HADAD, A. (Ed.). **VI Latin American Congress on Biomedical Engineering CLAIB 2014, Paraná, Argentina 29, 30 & 31 October 2014**. Springer International Publishing, 2015. p. 615–618. ISBN 978-3-319-13117-7. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-319-13117-7_157>.
- AHN, M. et al. High theta and low alpha powers may be indicative of BCI-illiteracy in motor imagery. **PloS one**, Public Library of Science, v. 8, n. 11, p. e80886, 2013. Disponível em: <<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0080886>>.
- ALLISON, B. Z. et al. Toward a hybrid brain–computer interface based on imagined movement and visual attention. **Journal of neural engineering**, IOP Publishing, v. 7, n. 2, p. 026007, Mar. 2010. ISSN 1741-2560. Disponível em: <<http://dx.doi.org/10.1088/1741-2560/7/2/026007>>.
- ALLISON, B. Z.; NEUPER, C. Could anyone use a BCI? In: **Brain-computer interfaces**. Springer, 2010. p. 35–54. ISBN 978-1-8499-6272-8. Disponível em: <http://dx.doi.org/10.1007/978-1-84996-272-8_3>.
- ALSHBATAT, A. I. N.; DONG, L.; VIAL, P. J. Airserver: a mind-controlled assistive quadrotor drone aided by an intelligent fuzzy PD controller. **Jordan Journal of Electrical Engineering**, , v. 2, n. 3, p. 181–198, 2016. ISSN 2409-9619. Disponível em: <<https://bit.ly/2jXuXZP>>.
- ALVARENGA JÚNIOR, W. J. D. **Métodos de otimização hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação binária**. Orientador: Andre Paim Lemos. 81 p. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal de Minas Gerais (UFMG), Belo Horizonte, 2018. Disponível em: <<https://repositorio.ufmg.br/handle/1843/BUBD-AX2NLF>>. Acesso em: 29 jul. 2020.
- AMIRI, S.; FAZEL-REZAI, R.; ASADPOUR, V. A review of hybrid brain-computer interface systems. **Advances in Human-Computer Interaction**, v. 2013, p. 8, 2013a. Disponível em: <<http://dx.doi.org/10.1155/2013/187024>>.

- AMIRI, S. et al. A review of P300, SSVEP, and hybrid P300/SSVEP brain computer interface systems. In: FAZEL-REZAI, R. (Ed.). **Brain Computer Interface Systems—Recent Progress and Future Prospects**. Rijeka: IntechOpen, 2013b. cap. 10. ISBN 978-953-51-1134-4. Disponível em: <<http://dx.doi.org/10.5772/56135>>.
- ANDREW, C.; PFURTSCHELLER, G. On the existence of different alpha band rhythms in the hand area of man. **Neuroscience Letters**, v. 222, n. 2, p. 103 – 106, 1997. ISSN 0304-3940. Disponível em: <[https://doi.org/10.1016/S0304-3940\(97\)13358-4](https://doi.org/10.1016/S0304-3940(97)13358-4)>.
- ANG, K. K. et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b. **Frontiers in neuroscience**, v. 6, p. 39, Mar. 2012a. ISSN 1662-453X. Disponível em: <<https://doi.org/10.3389/fnins.2012.00039>>.
- ANG, K. K. et al. Filter bank common spatial pattern (fbcsp) in brain-computer interface. In: IEEE. **2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)**. 2008. p. 2390–2397. Disponível em: <<https://doi.org/10.1109/IJCNN.2008.4634130>>.
- ANG, K. K. et al. Mutual information-based selection of optimal spatial–temporal patterns for single-trial EEG-based BCIs. **Pattern Recognition**, v. 45, n. 6, p. 2137–2144, 2012b. ISSN 0031-3203. Disponível em: <<https://doi.org/10.1016/j.patcog.2011.04.018>>.
- ANG, K. K.; 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, 2016. ISSN 1558-0210. Disponível em: <<https://doi.org/10.1109/TNSRE.2016.2646763>>.
- ARVANEH, M. et al. Optimizing the channel selection and classification accuracy in EEG-Based BCI. **IEEE Transactions on Biomedical Engineering**, , v. 58, n. 6, p. 1865–1873, Jun. 2011. ISSN 0018-9294. Disponível em: <<https://doi.org/10.1109/TBME.2011.2131142>>.
- BAILLET, S.; MOSHER, J. C.; LEAHY, R. M. Electromagnetic brain mapping. **IEEE Signal Processing Magazine**, v. 18, n. 6, p. 14–30, Nov 2001. ISSN 1053-5888. Disponível em: <<https://doi.org/10.1109/79.962275>>.
- BALAKRISHNAN, D.; PUTHUSSERYPADY, S. Multilayer perceptrons for the classification of brain computer interface data. In: **Proceedings of the IEEE 31st Annual Northeast Bioengineering Conference, 2005**. [s.n.], 2005. p. 118–119. Disponível em: <<https://doi.org/10.1109/NEBC.2005.1431953>>.
- BARROS, E. S. **Um Método de Classificação de Movimento Imaginado dos Braços Utilizando Emotiv EPOC+ e Openvibe**. Orientador: Nelson Cruz Sampaio Neto. 50 p. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal do Pará (UFPA), Belém, 2018. Disponível em: <<https://bit.ly/3mZA3PA>>. Acesso em: 5 mai. 2020.
- BASHAR, S. K.; BHUIYAN, M. I. H. Classification of motor imagery movements using multivariate empirical mode decomposition and short time fourier transform based hybrid method. **Engineering Science and Technology, an International Journal**, v. 19, n. 3, p. 1457 – 1464, 2016. ISSN 2215-0986. Disponível em: <<https://doi.org/10.1016/j.jestch.2016.04.009>>.

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, p. R32–57, 2007. ISSN 1741-2560. Disponível em: <<https://iopscience.iop.org/article/10.1088/1741-2560/4/2/R03>>.

BASHASHATI, H.; WARD, R. K.; BASHASHATI, A. Bayesian optimization of BCI parameters. In: IEEE. **2016 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)**. 2016. p. 1–5. Disponível em: <<https://doi.org/10.1109/CCECE.2016.7726801>>.

BASHASHATI, H.; WARD, R. K.; BASHASHATI, A. User-customized brain computer interfaces using bayesian optimization. **Journal of neural engineering**, IOP Publishing, v. 13, n. 2, p. 026001, Jan 2016. ISSN 1741-2552. Disponível em: <<http://dx.doi.org/10.1088/1741-2560/13/2/026001>>.

BASHASHATI, H. et al. Comparing different classifiers in sensory motor brain computer interfaces. **PloS one**, Public Library of Science San Francisco, CA USA, v. 10, n. 6, p. e0129435, 2015. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4474725/>>.

BASTOS, N. S.; ADAMATTI, D. F.; BILLA, C. Z. Discovering patterns in brain signals using decision trees. **Computational Intelligence and Neuroscience**, , v. 2016, p. 10, 2016. ISSN 1687-5273. Disponível em: <<http://dx.doi.org/10.1155/2016/6391807>>.

BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. **Neurociências: desvendando o sistema nervoso**. 4. ed. Porto Alegre: Artmed, 2017. 878 p. ISBN 978-85-8271-433-1.

BELIZARIO, P. A. B. **Seleção de bandas de frequência na classificação de eletroencefalogramas de imagética motora**. Orientador: João Luis Garcia Rosa. 73 p. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) — Universidade Federal de São Paulo (USP), São Carlos, 2017. Disponível em: <<https://repositorio.usp.br/item/002852109>>. Acesso em: 29 mai. 2020.

BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. **The Journal of Machine Learning Research**, JMLR. org, v. 13, n. 1, p. 281–305, 2012. Disponível em: <<https://dl.acm.org/doi/abs/10.5555/2188385.2188395>>.

BERGSTRA, J.; YAMINS, D.; COX, D. D. Hyperopt: A python library for optimizing the hyperparameters of machine learning algorithms. In: CITESEER. **Proceedings of the 12th Python in science conference**. 2013. v. 13, p. 20. Disponível em: <<https://bit.ly/34PzGRv>>.

BERGSTRA, J.; YAMINS, D.; COX, D. D. Making a science of model search: Hyperparameter optimization in hundreds of dimensions for vision architectures. *Jmlr*, 2013. Disponível em: <<http://proceedings.mlr.press/v28/bergstra13.html>>.

BERGSTRA, J. S. et al. Algorithms for hyper-parameter optimization. In: SHAWE-TAYLOR, J. et al. (Ed.). **Advances in Neural Information Processing Systems 24**. Curran Associates, Inc., 2011. p. 2546–2554. Disponível em: <<https://bit.ly/2Wsdjge>>.

BERNARDI, G. B. **Ferramenta Simplificada Para Testes de Algoritmos de Seleção de Características e Classificação em Sinais Cerebrais Captados com**

EEG para BCIs baseados em Imagética Motora. Orientador: Robson Luiz Moreno. 83 p. Dissertação (Mestrado em Ciência e Tecnologia em Computação) — Universidade Federal de Itajubá, Itajubá, MG, 2018. Disponível em: <<https://bit.ly/3noZon7>>. Acesso em: 12 ago. 2020.

BI, L.; FAN, X.-A.; LIU, Y. EEG-based brain-controlled mobile robots: a survey. **IEEE transactions on human-machine systems**, v. 43, n. 2, p. 161–176, 2013. ISSN 2168-2291. Disponível em: <<https://doi.org/10.1109/TSMCC.2012.2219046>>.

BILLINGER, M.; BRUNNER, C.; MÜLLER-PUTZ, G. R. Single-trial connectivity estimation for classification of motor imagery data. **Journal of Neural Engineering**, IOP Publishing, v. 10, n. 4, p. 046006, Jun. 2013. ISSN 1741-2552. Disponível em: <<https://doi.org/10.1088/1741-2560/10/4/046006>>.

BIRBAUMER, N. et al. A spelling device for the paralysed. **Nature**, , v. 398, n. 6725, p. 297–298, Mar. 1999. ISSN 1476-4687. Disponível em: <<https://doi.org/10.1038/18581>>.

BISHOP, C. M. **Pattern recognition and machine learning**. [S.l.]: springer, 2006.

BISHOP, C. M. et al. **Neural networks for pattern recognition**. Oxford university press, 1995. Disponível em: <<https://bit.ly/3aMv2Yk>>.

BLANKERTZ, B. et al. The non-invasive berlin brain–computer interface: Fast acquisition of effective performance in untrained subjects. **NeuroImage**, , v. 37, n. 2, p. 539–550, 2007. ISSN 1053–8119. Disponível em: <<https://doi.org/10.1016/j.neuroimage.2007.01.051>>.

BLANKERTZ, B. et al. The berlin brain-computer interface: Accurate performance from first-session in BCI-naive subjects. **IEEE Transactions on Biomedical Engineering**, , v. 55, n. 10, p. 2452–2462, Out. 2008b. ISSN 0018-9294. Disponível em: <<https://doi.org/10.1109/TBME.2008.923152>>.

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, Jun. 2006. ISSN 1534-4320. Disponível em: <<https://doi.org/10.1109/TNSRE.2006.875642>>.

BLANKERTZ, B. et al. Optimizing spatial filters for robust EEG single-trial analysis. **IEEE Signal Processing Magazine**, , v. 25, n. 1, p. 41–56, 2008a. ISSN 1053-5888. Disponível em: <<https://doi.org/10.1109/MSP.2008.4408441>>.

BONNET, L.; LOTTE, F.; LÉCUYER, A. Two brains, one game: design and evaluation of a multiuser BCI video game based on motor imagery. **IEEE Transactions on Computational Intelligence and AI in games**, v. 5, n. 2, p. 185–198, 2013. ISSN 1943-0698. Disponível em: <<https://doi.org/10.1109/TCIAIG.2012.2237173>>.

BOUSSETA, R. et al. EEG based brain computer interface for controlling a robot arm movement through thought. **IRBM**, v. 39, n. 2, p. 129–135, 2018. ISSN 1959-0318. Disponível em: <<https://doi.org/10.1016/j.irbm.2018.02.001>>.

BRASIL, I. Instituto brasileiro de geografia e estatística. **Censo demográfico**, v. 2010, 2010. Disponível em: <<https://censo2010.ibge.gov.br/resultados.html>>. Acesso em: 12 ago. 2020.

- BROCHU, E.; CORA, V. M.; FREITAS, N. D. A tutorial on bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. **arXiv preprint arXiv:1012.2599**, 2010. Disponível em: <<https://arxiv.org/abs/1012.2599>>.
- BRODU, N.; LOTTE, F.; LÉCUYER, A. Exploring two novel features for EEG-based brain-computer interfaces: Multifractal cumulants and predictive complexity. **Neurocomputing**, v. 79, p. 87 – 94, 2012. ISSN 0925-2312. Disponível em: <<https://doi.org/10.1016/j.neucom.2011.10.010>>.
- BRUNNER, C. et al. BCI competition 2008 – graz data set a. **Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces)**, Graz University of Technology, Austria, v. 16, 2008. Disponível em: <http://www.bbci.de/competition/iv/desc_2a.pdf>.
- BUENO, L. **Interface Cérebro-Computador Baseada em EEG Utilizando Redes Neurais Auto-Organizadas**. Orientador: Teodiano Freire Bastos Filho. 144 p. Tese (Doutorado em Engenharia Elétrica) — Universidade Federal do Espírito Santo (UFES), Vitória, 2017. Disponível em: <<http://repositorio.ufes.br/handle/10/9689>>. Acesso em: 2 nov. 2020.
- BURGES, C. J. A tutorial on support vector machines for pattern recognition. **Data mining and knowledge discovery**, Springer, v. 2, n. 2, p. 121–167, 1998. Disponível em: <<https://link.springer.com/article/10.1023/A:1009715923555>>.
- CARLETTA, J. Assessing agreement on classification tasks: The kappa statistic. **Comput. Linguist.**, MIT Press, Cambridge, MA, USA, v. 22, n. 2, p. 249–254, jun. 1996. ISSN 0891-2017. Disponível em: <<http://dl.acm.org/citation.cfm?id=230386.230390>>.
- CHANG, C.-C.; LIN, C.-J. LIBSVM: a library for support vector machines. **ACM Transactions on Intelligent Systems and Technology (TIST)**, ACM, v. 2, n. 3, p. 27, 2011. Disponível em: <<https://doi.org/10.1145/1961189.1961199>>.
- CHAUDHARY, U.; BIRBAUMER, N.; CURADO, M. Brain-machine interface (bmi) in paralysis. **Annals of physical and rehabilitation medicine**, Elsevier, v. 58, n. 1, p. 9–13, 2015. Disponível em: <<https://doi.org/10.1016/j.rehab.2014.11.002>>.
- CHAUMON, M.; BISHOP, D. V.; BUSCH, N. A. A practical guide to the selection of independent components of the electroencephalogram for artifact correction. **Journal of Neuroscience Methods**, v. 250, p. 47 – 63, 2015. ISSN 0165-0270. Cutting-edge EEG Methods. Disponível em: <<https://doi.org/10.1016/j.jneumeth.2015.02.025>>.
- CHEN, X.; HE, C.; PENG, H. Removal of muscle artifacts from single-channel EEG based on ensemble empirical mode decomposition and multiset canonical correlation analysis. **Journal of Applied Mathematics**, Hindawi Publishing Corporation, v. 2014, p. 10, Jun. 2014. ISSN 1687-0042. Disponível em: <<http://dx.doi.org/10.1155/2014/261347>>.
- CHEN, X. et al. High-speed spelling with a noninvasive brain-computer interface. **Proceedings of the national academy of sciences**, National Academy of Sciences, v. 112, n. 44, p. E6058–E6067, Nov. 2015. ISSN 0027-8424. Disponível em: <<https://doi.org/10.1073/pnas.1508080112>>.

- CHO, H. et al. EEG datasets for motor imagery brain-computer interface. **GigaScience**, v. 6, n. 7, p. gix034, 2017. ISSN 2047-217X. Disponível em: <<https://doi.org/10.1093/gigascience/gix034>>.
- CHOI, I. et al. A systematic review of hybrid brain-computer interfaces: Taxonomy and usability perspectives. **PloS one**, v. 12, n. 4, p. e0176674, 2017. ISSN 1932-6203. Disponível em: <<https://doi.org/10.1371/journal.pone.0176674>>.
- CINCOTTI, F. et al. Comparison of different feature classifiers for brain computer interfaces. In: **First International IEEE EMBS Conference on Neural Engineering, 2003. Conference Proceedings**. [s.n.], 2003. p. 645–647. Disponível em: <<https://doi.org/10.1109/CNE.2003.1196911>>.
- CLERC, M.; BOUGRAIN, L.; LOTTE, F. (Ed.). **Brain-Computer Interfaces 1: Foundations and methods**. London, ISTE, 2016a. 317 p. ISBN 978-1-8482-1826-0. Disponível em: <<https://bit.ly/3mPKgOn>>.
- CLERC, M.; BOUGRAIN, L.; LOTTE, F. (Ed.). **Brain-Computer Interfaces 2: Technology and application**. [S.l.]: London, ISTE, 2016b. 367 p. ISBN 978-1-8482-1963-2.
- CORSI, M.-C. et al. Integrating EEG and MEG signals to improve motor imagery classification in brain-computer interface. **International journal of neural systems**, World Scientific, v. 29, n. 01, p. 1850014, 2019. Disponível em: <<https://doi.org/10.1142/S0129065718500144>>.
- COYLE, D. **Brain-computer interfaces: lab experiments to real-world applications**. 1. ed. Elsevier B.V., 2016. 434 p. ISBN 978-0-12-804216-8. Disponível em: <<https://bit.ly/2kpbtgS>>.
- COYLE, D.; MCGINNITY, T. M.; PRASAD, G. Improving the separability of multiple EEG features for a BCI by neural-time-series-prediction-preprocessing. **Biomedical Signal Processing and Control**, v. 5, n. 3, p. 196 – 204, 2010. ISSN 1746-8094. Disponível em: <<https://doi.org/10.1016/j.bspc.2010.03.004>>.
- DALPONTE, M.; BOVOLO, F.; BRUZZONE, L. Automatic selection of frequency and time intervals for classification of EEG signals. **Electronics Letters**, IET, v. 43, n. 25, p. 1406–1408, 2007.
- DEMUTH, H. B. et al. **Neural network design**. Martin Hagan, 2014. Disponível em: <<https://dl.acm.org/doi/book/10.5555/2721661>>.
- DENOEU, T. A k-nearest neighbor classification rule based on dempster-shafer theory. In: **Classic works of the Dempster-Shafer theory of belief functions**. Springer, 2008. p. 737–760. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-540-44792-4_29>.
- DUARTE, R. M. **Low cost brain computer interface system for AR.Drone control**. Orientador: Alexandre Trofino Neto. 102 p. Dissertação (Mestrado em Engenharia de Automação e Sistemas) — Universidade Federal de Santa Catarina (UFSC), Florianópolis, 2017. Disponível em: <<https://repositorio.ufsc.br/handle/123456789/180243>>. Acesso em: 29 mai. 2020.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification** // **this should be curled beta,ication**. [S.l.]: John Wiley & Sons, 2012.

EDLINGER, G.; GUGER, C. A hybrid brain-computer interface for improving the usability of a smart home control. In: **2012 ICME International Conference on Complex Medical Engineering (CME)**. IEEE, 2012. p. 182–185. ISBN 978-1-4673-1618-7. Disponível em: <<https://doi.org/10.1109/ICCME.2012.6275714>>.

EGGENSPERGER, K. et al. Towards an empirical foundation for assessing bayesian optimization of hyperparameters. In: **NIPS workshop on Bayesian Optimization in Theory and Practice**. [s.n.], 2013. v. 10, p. 3. Disponível em: <<https://www.cs.ubc.ca/~hoos/Publ/EggEtAl13.pdf>>.

FACELI, K. et al. **Inteligência Artificial: Uma abordagem de aprendizagem de máquina**. 1. ed. Rio de Janeiro: Rio de Janeiro: LTC, 2011. 394 p. ISBN 978-85-216-1880-5.

FATOURECHI, M. et al. EMG and EOG artifacts in brain computer interface systems: A survey. **Clinical Neurophysiology**, v. 118, n. 3, p. 480 – 494, 2007. ISSN 1388-2457. Disponível em: <<https://doi.org/10.1016/j.clinph.2006.10.019>>.

FELZER, T. On the possibility of developing a brain-computer interface (bci). **Technical University of Darmstadt**, Department of Computer Science, Darmstadt, 2001. Disponível em: <<https://bit.ly/2WTQaUl>>.

FENG, J. et al. Towards correlation-based time window selection method for motor imagery BCIs. **Neural Networks**, v. 102, p. 87–95, 2018. ISSN 0893-6080. Disponível em: <<https://doi.org/10.1016/j.neunet.2018.02.011>>.

FERREIRA, A. **Uma proposta de interface cérebro-computador para comando de cadeiras de rodas**. Orientador: Teodiano Freire Bastos Filho. 136 p. Tese (Doutorado em Engenharia Elétrica - Automação) — Universidade Federal do Espírito Santo (UFES), Vitória, 2008. Disponível em: <<http://repositorio.ufes.br/handle/10/9700>>. Acesso em: 13 jun. 2020.

FEURER, M.; HUTTER, F. Hyperparameter optimization. In: _____. **Automated Machine Learning: Methods, Systems, Challenges**. Cham: Springer International Publishing, 2019. p. 3–33. ISBN 978-3-030-05318-5. Disponível em: <https://doi.org/10.1007/978-3-030-05318-5_1>.

FREITAS, D. R. R. d. **Plataforma para análise do sinal de EEG aplicado ao ERD/ERS no reconhecimento em tempo real da imaginação do movimento**. Orientador: Marco Aurélio Benedetti Rodrigues. 139 p. Tese (Doutorado em Engenharia Elétrica) — Universidade Federal de Pernambuco (UFPE), Recife, 2017. Disponível em: <<https://repositorio.ufpe.br/handle/123456789/34166>>. Acesso em: 23 jul. 2020.

GANDHI, V. et al. Evaluating quantum neural network filtered motor imagery brain-computer interface using multiple classification techniques. **Neurocomputing**, v. 170, p. 161–167, 2015. ISSN 1872-8286. Disponível em: <<http://dx.doi.org/10.1016/j.neucom.2014.12.114>>.

GE, S.; WANG, R.; YU, D. Classification of four-class motor imagery employing single-channel electroencephalography. **PLoS one**, Public Library of Science, v. 9, n. 6, p. e98019, 2014. Disponível em: <<https://bit.ly/3rvxVCK>>.

- GHRISSI, M.; CHERIF, A. Comparison of IIR filterbanks and FFT filterbanks in cochlear implant speech processing strategies. **Journal of Electrical Systems, Engineering and Scientific Research Groups**, v. 8, n. 1, p. 76–84, 2012. Disponível em: <<https://bit.ly/3pv4lvb>>.
- GIL, A. C. et al. **Como elaborar projetos de pesquisa**. [S.l.]: Atlas São Paulo, 2002. v. 4.
- GIOVANINI, R. de M. **SSVEP-EEG signal pattern recognition system for real-time brain-computer interfaces applications**. Orientador: Aparecido Augusto de Carvalho. 89 p. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Estadual Paulista (UNESP), Ilha Solteira, 2017. Disponível em: <<https://repositorio.unesp.br/handle/11449/151710>>. Acesso em: 25 ago. 2020.
- GÖHRING, D. et al. Semi-autonomous car control using brain computer interfaces. In: LEE, S. et al. (Ed.). **Intelligent Autonomous Systems 12**. Berlin, Heidelberg: Springer, 2013. p. 393–408. ISBN 978-3-642-33932-5. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-642-33932-5_37>.
- GRAIMANN, B.; ALLISON, B. Z.; PFURTSCHELLER, G. (Ed.). **Brain-computer interfaces: Revolutionizing human-computer interaction**. Springer Science & Business Media, 2010. 396 p. ISBN 9-7836-420-2090-2. Disponível em: <<https://bit.ly/2zcN9Ct>>.
- GRANDINI, J. N. **Interface Cérebro Máquina de Baixo Custo como Tecnologia Assistiva**. Orientador: Fabio Rodrigues de La Rocha. 89 p. Trabalho de Conclusão de Curso (Bacharelado em Engenharia da Computação) — Universidade Federal de Santa Catarina (UFSC), Araranguá, 2017. Disponível em: <<https://repositorio.ufsc.br/handle/123456789/182174>>. Acesso em: 1 jun. 2020.
- GRAPS, A. An introduction to wavelets. **IEEE Computational Science and Engineering**, v. 2, n. 2, p. 50–61, 1995. Disponível em: <<https://doi.org/10.1109/99.388960>>.
- GUBERT, P. H. **Contribuição à Matriz de Informações em Sistemas de Imagética Motora Baseadas no Método de CSP**. Orientador: Márcio Holsbach Costa, Coorientador: Alexandre Trofino Neto. 125 p. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal de Santa Catarina (UFSC), Florianópolis, 2019. Disponível em: <<https://bit.ly/3amfEBu>>. Acesso em: 25 mar. 2020.
- GUGER, C. et al. How many people could use an SSVEP BCI? **Frontiers in neuroscience**, v. 6, p. 169, Nov. 2012. ISSN 1662-4548. Disponível em: <<https://doi.org/10.3389/fnins.2012.00169>>.
- HASELSTEINER, E.; PFURTSCHELLER, G. Using time-dependent neural networks for EEG classification. **IEEE Transactions on Rehabilitation Engineering**, v. 8, n. 4, p. 457–463, 2000. Disponível em: <<https://doi.org/10.1109/86.895948>>.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data mining, inference and prediction**. 2. ed. Stanford: Springer Seriesn in Statistics, 2017. 746 p. ISBN 0387848576. Disponível em: <<https://web.stanford.edu/~hastie/Papers/ESLII.pdf>>. Acesso em: 5 jun. 2020.

- HAYKIN, S. S. et al. **Neural networks and learning machines/Simon Haykin**. [S.l.]: New York: Prentice Hall, 2009.
- HOLZ, E. M. et al. Brain-computer interface controlled gaming: Evaluation of usability by severely motor restricted end-users. **Artificial Intelligence in Medicine**, v. 59, n. 2, p. 111–120, Out. 2013. ISSN 0933-3657. Special Issue: Brain-computer interfacing. Disponível em: <<https://doi.org/10.1016/j.artmed.2013.08.001>>.
- HONG, K.-S.; KHAN, M. J. Hybrid brain-computer interface techniques for improved classification accuracy and increased number of commands: A review. **Frontiers in Neurobotics**, , v. 11, p. 35, 2017. ISSN 1662-5218. Disponível em: <<https://www.frontiersin.org/article/10.3389/fnbot.2017.00035>>.
- HSU, C.-W. et al. **A practical guide to support vector classification**. Taipei, 2003. Disponível em: <<https://bit.ly/2WRbgCF>>.
- HUANG, J. et al. FOCUS: enhancing children’s engagement in reading by using contextual BCI training sessions. In: **Proceedings of the SIGCHI Conference on Human Factors in Computing Systems**. ACM, 2014. p. 1905–1908. ISBN 978-1-4503-2473-1. Disponível em: <<https://doi.org/10.1145/2556288.2557339>>.
- HUTTER, F.; HOOS, H. H.; LEYTON-BROWN, K. Sequential model-based optimization for general algorithm configuration. In: COELLO, C. A. C. (Ed.). **Learning and Intelligent Optimization**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 507–523. ISBN 978-3-642-25566-3. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-642-25566-3_40>.
- HUTTER, F.; LÜCKE, J.; SCHMIDT-THIEME, L. Beyond manual tuning of hyperparameters. **KI-Künstliche Intelligenz**, Springer, v. 29, n. 4, p. 329–337, 2015. Disponível em: <<https://link.springer.com/article/10.1007/s13218-015-0381-0>>.
- IFEACHOR, E. C.; JERVIS, B. W. **Digital signal processing: a practical approach**. [S.l.]: Pearson Education, 2002.
- ISHFAQUE, A. et al. Evaluation of ANN, LDA and decision trees for EEG based brain computer interface. In: **2013 IEEE 9th International Conference on Emerging Technologies (ICET)**. IEEE, 2013. p. 1–6. ISBN 978-1-4799-3457-7. Disponível em: <<https://doi.org/10.1109/ICET.2013.6743513>>.
- ISLAM, M. K.; RASTEGARNIA, A.; YANG, Z. Methods for artifact detection and removal from scalp EEG: A review. **Neurophysiologie Clinique/Clinical Neurophysiology**, v. 46, n. 4, p. 287 – 305, 2016. ISSN 0987-7053. Disponível em: <<https://doi.org/10.1016/j.neucli.2016.07.002>>.
- JAFARIFARMAND, A. et al. A new self-regulated neuro-fuzzy framework for classification of EEG signals in motor imagery BCI. **IEEE Transactions on Fuzzy Systems**, , v. 26, n. 3, p. 1485–1497, Jun. 2018. ISSN 1063-6706. Disponível em: <<https://doi.org/10.1109/TFUZZ.2017.2728521>>.
- JAMES, G. et al. **An introduction to statistical learning**. [S.l.]: Springer, 2013. v. 112.

- JAS, M. et al. Autoreject: Automated artifact rejection for MEG and EEG data. **NeuroImage**, v. 159, p. 417 – 429, 2017. ISSN 1053-8119. Disponível em: <<https://doi.org/10.1016/j.neuroimage.2017.06.030>>.
- JASPER, H. H. The ten-twenty electrode system of the international federation. **Electroencephalogr. Clin. Neurophysiol.**, v. 10, p. 370–375, 1958. Disponível em: <<https://ci.nii.ac.jp/naid/10017996828/en/>>.
- JONES, D. R. A taxonomy of global optimization methods based on response surfaces. **Journal of global optimization**, Springer, v. 21, n. 4, p. 345–383, 2001. Disponível em: <<https://link.springer.com/article/10.1023/A:1012771025575>>.
- JUNG, T.-P. et al. Estimating alertness from the EEG power spectrum. **IEEE Transactions on Biomedical Engineering**, v. 44, n. 1, p. 60–69, 1997. Disponível em: <<https://doi.org/10.1109/10.553713>>.
- JURCAK, V.; TSUZUKI, D.; DAN, I. 10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems. **Neuroimage**, Elsevier, v. 34, n. 4, p. 1600–1611, Fev. 2007. ISSN 1053–8119. Disponível em: <<https://doi.org/10.1016/j.neuroimage.2006.09.024>>.
- KAPLAN, A. Y. et al. Adapting the p300-based brain–computer interface for gaming: A review. **IEEE Transactions on Computational Intelligence and AI in Games**, v. 5, n. 2, p. 141–149, 2013. ISSN 1943-0698. Disponível em: <<https://doi.org/10.1109/TCIAIG.2012.2237517>>.
- KEVRIC, J.; SUBASI, A. Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system. **Biomedical Signal Processing and Control**, v. 31, p. 398 – 406, 2017. ISSN 1746-8094. Disponível em: <<https://doi.org/10.1016/j.bspc.2016.09.007>>.
- KHALID, M. B. et al. Towards a brain computer interface using wavelet transform with averaged and time segmented adapted wavelets. In: IEEE. **2009 2nd International Conference on Computer, Control and Communication**. 2009. p. 1–4. Disponível em: <<https://doi.org/10.1109/IC4.2009.4909189>>.
- KHAN, M. A.; ISLAM, M. R.; MOLLA, M. K. I. Artifact suppression from electroencephalography signals using stationary subspace analysis. In: **2016 19th International Conference on Computer and Information Technology (ICCIT)**. IEEE, 2016. p. 252–256. ISBN 978-1-5090-4089-6. Disponível em: <<https://doi.org/10.1109/ICCITECHN.2016.7860204>>.
- KHAN, M. J.; HONG, K.-S. Hybrid EEG–fNIRS-Based eight-command decoding for BCI: Application to quadcopter control. **Frontiers in Neurobotics**, p. 6, Fev. 2017. ISSN 1662-5218. Disponível em: <<https://doi.org/10.3389/fnbot.2017.00006>>.
- KHUSHABA, R. N. et al. Consumer neuroscience: Assessing the brain response to marketing stimuli using electroencephalogram (EEG) and eye tracking. **Expert Systems with Applications**, v. 40, n. 9, p. 3803–3812, 2013. ISSN 0957-4174. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2012.12.095>>.

- KRISHNA, D. H.; PASHA, I.; SAVITHRI, T. S. Classification of EEG motor imagery multi class signals based on cross correlation. **Procedia Computer Science**, v. 85, p. 490 – 495, 2016. ISSN 1877-0509. International Conference on Computational Modelling and Security (CMS 2016). Disponível em: <<https://doi.org/10.1016/j.procs.2016.05.198>>.
- KRONEGG, J.; VOLOSHYNOVSKYY, S.; PUN, T. Information-transfer rate modeling of EEG-based synchronized brain-computer interfaces. 2005. ID: unige:48013. Disponível em: <<https://archive-ouverte.unige.ch/unige:48013>>.
- KUMAR, S.; SHARMA, A. A new parameter tuning approach for enhanced motor imagery EEG signal classification. **Medical & biological engineering & computing**, Springer, v. 56, n. 10, p. 1861–1874, 2018. Disponível em: <<https://link.springer.com/article/10.1007/s11517-018-1821-4>>.
- KUMAR, S.; SHARMA, A.; TSUNODA, T. An improved discriminative filter bank selection approach for motor imagery EEG signal classification using mutual information. **BMC bioinformatics**, Springer, v. 18, n. 16, p. 545, 2017. Disponível em: <<https://link.springer.com/article/10.1186/s12859-017-1964-6>>.
- KUMAR, S. U.; INBARANI, H. H. PSO-based feature selection and neighborhood rough set-based classification for BCI multiclass motor imagery task. **Neural Computing and Applications**, , v. 28, n. 11, p. 3239–3258, Nov. 2017. ISSN 1433-3058. Disponível em: <<https://doi.org/10.1007/s00521-016-2236-5>>.
- KWON, O. et al. Subject-independent brain-computer interfaces based on deep convolutional neural networks. **IEEE Transactions on Neural Networks and Learning Systems**, p. 1–14, 2019. Disponível em: <<https://doi.org/10.1109/TNNLS.2019.2946869>>.
- LAFLEUR, K. et al. Quadcopter control in three-dimensional space using a noninvasive motor imagery-based brain–computer interface. **Journal of neural engineering**, v. 10, n. 4, p. 046003, 2013. ISSN 1741-2552. Disponível em: <<http://dx.doi.org/10.1088/1741-2560/10/4/046003>>.
- LAHIRI, R.; RAKSHIT, P.; KONAR, A. Evolutionary perspective for optimal selection of EEG electrodes and features. **Biomedical Signal Processing and Control**, Elsevier, v. 36, p. 113–137, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.bspc.2017.03.022>>.
- LAL, T. N. et al. Support vector channel selection in BCI. **IEEE transactions on biomedical engineering**, IEEE, v. 51, n. 6, p. 1003–1010, 2004. Disponível em: <<https://doi.org/10.1109/TBME.2004.827827>>.
- LEE, M.-H. et al. EEG dataset and OpenBMI toolbox for three BCI paradigms: an investigation into BCI illiteracy. **GigaScience**, v. 8, n. 5, 01 2019. ISSN 2047-217X. Giz002. Disponível em: <<https://doi.org/10.1093/gigascience/giz002>>.
- LEE, W. T. et al. A brain computer interface for smart home control. In: **2013 IEEE International Symposium on Consumer Electronics (ISCE)**. IEEE, 2013. p. 35–36. ISBN 978-1-4673-6199-6. Disponível em: <<https://doi.org/10.1109/ISCE.2013.6570240>>.
- LEEB, R. et al. Bci competition 2008–graz data set b. **Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces)**, Graz University of

- Technology, Austria, p. 1–6, 2008. Disponível em: <http://www.bbc.de/competition/iv/desc_2b.pdf>.
- LEEB, R. et al. Platform for analyzing multi-tasking capabilities during BCI operation. In: **6th International Brain-Computer Interface Conference 2014**. [s.n.], 2014. Disponível em: <<http://dx.doi.org/10.3217/978-3-85125-378-8-67>>.
- LEEB, R. et al. Brain-computer communication: motivation, aim, and impact of exploring a virtual apartment. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, IEEE, v. 15, n. 4, p. 473–482, 2007. Disponível em: <<https://doi.org/10.1109/TNSRE.2007.906956>>.
- LEEB, R. et al. Towards independence: A BCI telepresence robot for people with severe motor disabilities. **Proceedings of the IEEE**, v. 103, n. 6, p. 969–982, 2015. ISSN 0018-9219. Disponível em: <<https://doi.org/10.1109/JPROC.2015.2419736>>.
- LI, P. et al. L1 norm based common spatial patterns decomposition for scalp EEG BCI. **Biomedical engineering online**, Springer, v. 12, n. 1, p. 77, 2013. Disponível em: <<https://link.springer.com/article/10.1186/1475-925X-12-77>>.
- LI, Y.; KOIKE, Y. A real-time BCI with a small number of channels based on CSP. **Neural Computing and Applications**, Springer, v. 20, n. 8, p. 1187–1192, 2011. Disponível em: <<https://link.springer.com/article/10.1007/s00521-010-0481-6>>.
- LIN, J.-S.; JIANG, Z.-Y. Implementing remote presence using quadcopter control by a non-invasive BCI device. **Computer Science and Information Technology**, Horizon Research Publishing, v. 3, n. 4, p. 122–126, May. 2015. ISSN 2331-6071. Disponível em: <<https://pdfs.semanticscholar.org/2b1a/af5ec8d69cea9e473e07a8326c4a5c95a223.pdf>>.
- LOPES, T. d. J. et al. Interface cérebro-máquina baseada em imagética motora: Estudo comparativo da quantidade de canais de EEG. **Anais do XIV Congresso Brasileiro de Inteligência Computacional - CBIC**, 2019. Disponível em: <<http://dx.doi.org/10.21528/CBIC2019-62>>.
- LOTTE, F. A tutorial on EEG signal-processing techniques for mental state recognition in brain-computer interfaces. In: **Guide to Brain-Computer Music Interfacing**. Springer, London, 2014. p. 133–161. ISBN 978-1-4471-6583-5. Disponível em: <<https://hal.inria.fr/hal-01055103>>.
- 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, p. 031005, 2018. ISSN 1741-2552. Disponível em: <<https://doi.org/10.1088/1741-2552/aab2f2>>.
- LOTTE, F. et al. A review of classification algorithms for EEG-based brain-computer interfaces. **Journal of Neural Engineering**, IOP Publishing, v. 4, n. 2, p. R1–R13, Jan. 2007. ISSN 1741-2552. Disponível em: <<https://iopscience.iop.org/article/10.1088/1741-2560/4/2/R01>>.
- LOTTE, F.; GUAN, C. Spatially regularized common spatial patterns for EEG classification. In: IEEE. **2010 20th International Conference on Pattern Recognition**. 2010. p. 3712–3715. Disponível em: <<https://doi.org/10.1109/ICPR.2010.904>>.

- LOTTE, F.; GUAN, C. Regularizing common spatial patterns to improve BCI designs: Unified theory and new algorithms. **IEEE Transactions on Biomedical Engineering**, v. 58, n. 2, p. 355–362, Fev. 2011. ISSN 0018-9294. Disponível em: <<https://doi.org/10.1109/TBME.2010.2082539>>.
- LOTZE, M.; COHEN, L. G. Volition and imagery in neurorehabilitation. **Cognitive and behavioral neurology**, , v. 19, n. 3, p. 135–140, Set. 2006. ISSN 1543-3633. Disponível em: <<https://bit.ly/2kepBcS>>.
- LU, N. et al. A deep learning scheme for motor imagery classification based on restricted boltzmann machines. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 25, n. 6, p. 566–576, 2017. Disponível em: <<https://doi.org/10.1109/TNSRE.2016.2601240>>.
- LUO, J. et al. Dynamic frequency feature selection based approach for classification of motor imageries. **Computers in Biology and Medicine**, v. 75, p. 45 – 53, 2016. ISSN 0010-4825. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0010482516300580>>.
- MAHMOUDI, B.; ERFANIAN, A. Electro-encephalogram based brain–computer interface: improved performance by mental practice and concentration skills. **Medical and Biological Engineering and Computing**, , v. 44, n. 11, p. 959–969, Nov. 2006. ISSN 1741-0444. Disponível em: <<https://doi.org/10.1007/s11517-006-0111-8>>.
- 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, June 2013. ISSN 1943-068X. Disponível em: <<https://doi.org/10.1109/TCIAIG.2013.2263555>>.
- MARSLAND, S. **Machine learning**: an algorithmic perspective. 2. ed. Chapman and Hall/CRC, 2014. 457 p. ISBN 978-1-4665-8333-7. Disponível em: <<https://www.taylorfrancis.com/books/9780429102509>>. Acesso em: 16 ago. 2020.
- MASKELIUNAS, R. et al. Consumer-grade EEG devices: are they usable for control tasks? **PeerJ**, , v. 4, n. 3, p. e1746, Mar. 2016. ISSN 2701-4511. Disponível em: <<https://doi.org/10.7717/peerj.1746>>.
- MCFARLAND, D. J.; SARNACKI, W. A.; WOLPAW, J. R. Electroencephalographic (eeg) control of three-dimensional movement. **Journal of neural engineering**, IOP Publishing, v. 7, n. 3, p. 036007, Mai. 2010. ISSN 1741-2552. Disponível em: <<http://iopscience.iop.org/1741-2552/7/3/036007>>.
- MCFARLAND, D. J.; WOLPAW, J. R. Brain-computer interfaces for communication and control. **Communications of the ACM**, v. 54, n. 5, p. 60–66, 2011. Disponível em: <<https://dx.doi.org/10.1145%2F1941487.1941506>>.
- MENG, J. et al. Noninvasive electroencephalogram based control of a robotic arm for reach and grasp tasks. **Scientific Reports**, Nature, v. 6, p. 38565, Dez. 2016. ISSN 2045-2322. Disponível em: <<https://www.nature.com/articles/srep38565>>.
- MIAO, M. et al. Discriminative spatial-frequency-temporal feature extraction and classification of motor imagery EEG: An sparse regression and weighted naïve bayesian

- classifier-based approach. **Journal of Neuroscience Methods**, v. 278, p. 13 – 24, 2017. ISSN 0165-0270. Disponível em: <<https://doi.org/10.1016/j.jneumeth.2016.12.010>>.
- MINGUILLON, J.; LOPEZ-GORDO, M. A.; PELAYO, F. Trends in EEG-BCI for daily-life: Requirements for artifact removal. **Biomedical Signal Processing and Control**, Elsevier BV, v. 31, p. 407–418, Jan. 2017. ISSN 1746-8094. Disponível em: <<https://doi.org/10.1016/j.bspc.2016.09.005>>.
- MISHUHINA, V.; JIANG, X. Feature weighting and regularization of common spatial patterns in EEG-based motor imagery BCI. **IEEE Signal Processing Letters**, IEEE, v. 25, n. 6, p. 783–787, 2018. Disponível em: <<https://doi.org/10.1109/LSP.2018.2823683>>.
- MORASH, V. et al. Classifying EEG signals preceding right hand, left hand, tongue, and right foot movements and motor imageries. **International Federation of Clinical Neurophysiology**, v. 119, n. 11, p. 2570–2578, 2008. ISSN 1388-2457. Disponível em: <<https://doi.org/10.1016/j.clinph.2008.08.013>>.
- MULDER, T. Motor imagery and action observation: cognitive tools for rehabilitation. **Journal of neural transmission**, v. 114, n. 10, p. 1265–1278, 2007. ISSN 0300-9564. Disponível em: <<https://link.springer.com/article/10.1007/s00702-007-0763-z>>.
- MÜLLER-PUTZ, G. et al. Chapter 2 - from classic motor imagery to complex movement intention decoding: The noninvasive Graz-BCI approach. In: COYLE, D. (Ed.). **Brain-Computer Interfaces: Lab Experiments to Real-World Applications**. Elsevier, 2016, (Progress in Brain Research, v. 228). p. 39 – 70. Disponível em: <<https://doi.org/10.1016/bs.pbr.2016.04.017>>.
- NAM, C. S.; NIJHOLT, A.; LOTTE, F. **Brain-computer interfaces handbook: technological and theoretical advances**. [S.l.]: CRC Press, 2018.
- NEUPER, C.; KLIMESCH, W. (Ed.). **Event-related dynamics of brain oscillations**. 1. ed. Elsevier, 2006. 464 p. ISBN 9-7800-804-6559-3. Disponível em: <<https://bit.ly/2ZgnXdc>>.
- NGUYEN, V. et al. Bayesian optimization in weakly specified search space. In: IEEE. **2017 IEEE International Conference on Data Mining (ICDM)**. 2017. p. 347–356. Disponível em: <<https://doi.org/10.1109/ICDM.2017.44>>.
- NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. **Sensors**, v. 12, n. 2, p. 1211–1279, 2012. ISSN 1424-8220. Disponível em: <<https://doi.org/10.3390/s120201211>>.
- NIDAL, K.; MALIK, A. S. (Ed.). **EEG/ERP Analysis: Methods and applications**. Crc Press, 2014. 334 p. ISBN 978-1-4822-2469-6. Disponível em: <<https://bit.ly/38FcGWI>>.
- NIEDERMEYER, E.; SILVA, F. H. L. da. **Electroencephalography: Basic principles, clinical applications, and related fields**. 5. ed. Lippincott Williams & Wilkins, 2005. 130 p. ISBN 0-7817-5126-8. Disponível em: <<https://bit.ly/2JoJqum>>.
- NOOH, A. A.; YUNUS, J.; DAUD, S. M. A review of asynchronous electroencephalogram-based brain computer interface systems. In: **2011 International Conference on Biomedical Engineering and Technology IPCBEE**. Singapore: IACSIT Press, 2011. p. 55–59. Disponível em: <<http://www.ipcbee.com/vol11/11-T025.pdf>>.

NOURMOHAMMADI, A.; JAFARI, M.; ZANDER, T. O. A survey on unmanned aerial vehicle remote control using brain–computer interface. **IEEE Transactions on Human-Machine Systems**, v. 48, n. 4, p. 337–348, 2018. ISSN 2168–2291. Disponível em: <<https://doi.org/10.1109/THMS.2018.2830647>>.

NOVI, Q. et al. Sub-band common spatial pattern (SBCSP) for brain-computer interface. In: **2007 3rd International IEEE/EMBS Conference on Neural Engineering**. IEEE, 2007. p. 204–207. ISBN 1-4244-0791-5. Disponível em: <<https://doi.org/10.1109/CNE.2007.369647>>.

NUNEZ, P. L.; SRINIVASAN, R. et al. **Electric fields of the brain: the neurophysics of EEG**. Oxford University Press, USA, 2006. 611 p. ISBN 978-0-195-05038-7. Disponível em: <<https://bit.ly/2ATBMnC>>.

OLIVAS-PADILLA, B. E.; CHACON-MURGUIA, M. I. Classification of multiple motor imagery using deep convolutional neural networks and spatial filters. **Applied Soft Computing**, v. 75, p. 461–472, 2019. ISSN 1568-4946. Disponível em: <<https://doi.org/10.1016/j.asoc.2018.11.031>>.

OPPENHEIM, A. V.; WILLSKY, A. S.; NAWAD, S. H. **Sinais e Sistemas**. 2. ed. São Paulo: Pearson Prentice, 2010. 592 p. ISBN 978-85-7605-504-4.

PALANIAPPAN, R. Brain computer interface design using band powers extracted during mental tasks. In: IEEE. **Conference Proceedings. 2nd International IEEE EMBS Conference on Neural Engineering, 2005**. 10.1109/CNE.2005.1419622, 2005. p. 321–324. Disponível em: <<https://doi.org/10.1109/CNE.2005.1419622>>.

PFURTSCHELLER, G.; NEUPER, C. Motor imagery and direct brain-computer communication. **Proceedings of the IEEE**, IEEE, v. 89, n. 7, p. 1123–1134, 2001. Disponível em: <<https://doi.org/10.1109/5.939829>>.

PFURTSCHELLER, G.; NEUPER, C.; BIRBAUMER, N. Human brain–computer interface. In: VAADIA, E.; RIEHLE, A. (Ed.). **Motor Cortex in Voluntary Movements: A Distributed System for Distributed Functions, Series: Methods and New Frontiers in Neuroscience**. London: CRC Press, 2005. p. 367–401. ISBN 0-8493-1287-6. Disponível em: <<https://b-ok.cc/book/2351402/6a6a3e>>.

PFURTSCHELLER, G.; SILVA, F. H. L. D. Event-related EEG/MEG synchronization and desynchronization: basic principles. **Clinical neurophysiology**, v. 110, n. 11, p. 1842–1857, 1999. ISSN 1388-2457. Disponível em: <[https://doi.org/10.1016/S1388-2457\(99\)00141-8](https://doi.org/10.1016/S1388-2457(99)00141-8)>.

PFURTSCHELLER, G.; STANČÁK, A.; EDLINGER, G. On the existence of different types of central beta rhythms below 30 hz. **Electroencephalography and Clinical Neurophysiology**, v. 102, n. 4, p. 316 – 325, 1997. ISSN 0013-4694. Disponível em: <[https://doi.org/10.1016/S0013-4694\(96\)96612-2](https://doi.org/10.1016/S0013-4694(96)96612-2)>.

PICHIORRI, F. et al. Brain–computer interface boosts motor imagery practice during stroke recovery. **Annals of Neurology**, v. 77, n. 5, p. 851–865, 2015. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/ana.24390>>.

- POHAR, M.; BLAS, M.; TURK, S. Comparison of logistic regression and linear discriminant analysis: a simulation study. **Metodoloski zvezki**, Anuska Ferligoj, v. 1, n. 1, p. 143, 2004. Disponível em: <<http://mrvar.fdv.uni-lj.si/pub/mz/mz1.1/pohar.pdf>>.
- PRADA, B. M. L. **Interface cérebro-computador não invasiva baseada em OpenVibe**. Orientadora: Petia Georgieva. 94 p. Dissertação (Mestrado em Engenharia Eletrônica e Telecomunicações) — Universidade de Aveiro, Aveiro, 2010. Disponível em: <<http://hdl.handle.net/10773/7524>>. Acesso em: 11 jun. 2020.
- PRODANOV, C. C.; FREITAS, E. C. de. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico-2ª Edição**. [S.l.]: Editora Feevale, 2013.
- PURVES, D. et al. (Ed.). **Neuroscience**. 3. ed. Sinauer, 2004. ISBN 0-87893-725-0. Disponível em: <<https://www.hse.ru/data/2011/06/22/1215686482/Neuroscience.pdf>>.
- RAKOTOMAMONJY, A.; GUIGUE, V. Bci competition iii: Dataset ii- ensemble of SVMs for BCI p300 speller. **IEEE Transactions on Biomedical Engineering**, v. 55, n. 3, p. 1147–1154, 2008. Disponível em: <<https://doi.org/10.1109/TBME.2008.915728>>.
- RAMOS-MURGUIALDAY, A. et al. Brain–machine interface in chronic stroke rehabilitation: a controlled study. **Annals of neurology**, , v. 74, n. 1, p. 100–108, Mar. 2013. ISSN 1531-8249. Disponível em: <<https://doi.org/10.1002/ana.23879>>.
- RAMOSER, H.; MULLER-GERKING, J.; PFURTSCHELLER, G. Optimal spatial filtering of single trial EEG during imagined hand movement. **IEEE Transactions on Rehabilitation Engineering**, , v. 8, n. 4, p. 441–446, Dez. 2000. ISSN 1063-6528. Disponível em: <<https://doi.org/10.1109/86.895946>>.
- RASCHKA, S. **Python machine learning**. 1. ed. Packt publishing ltd, 2015. 454 p. ISBN 9781783555147. Disponível em: <<https://bit.ly/3elpbHq>>.
- RASMUSSEN, C. E.; WILLIAMS, C. K. Gaussian processes for machine learning the MIT press. **Cambridge, Mass**, 2006.
- RAZA, H.; CECOTTI, H.; PRASAD, G. Optimising frequency band selection with forward-addition and backward-elimination algorithms in EEG-based brain-computer interfaces. In: **2015 International Joint Conference on Neural Networks (IJCNN)**. [S.l.: s.n.], 2015. p. 1–7.
- REUTER-LORENZ, P. A. et al. (Ed.). **The Cognitive Neuroscience of Mind: A tribute to michael s. gazzaniga**. Cambridge: MIT, 2010. 258 p. ISBN 978-0-262-01401-4. Disponível em: <<https://brainmaster.com/software/pubs/brain/Cognitive%20NeuroSci%20of%20the%20Mind.pdf>>.
- RIBE, A.; KROHN, K. H. **EEG-based Brain Computer Interface for Controlling a Drone: using machine learning, optimized for a battery powered device**. Orientador: Per Gunnar Kjeldsberg. 252 p. Dissertação (Master of Science in Electronics) — Norwegian University of Science and Technology (NTNU), Trondheim, 2018. Disponível em: <<https://ntnuopen.ntnu.no/ntnu-xmlui/handle/11250/2560785>>. Acesso em: 6 abr. 2020.

- ROCHA, R. d. L. **Redes neurais convolucionais aplicadas à inspeção de componentes do vagão ferroviário**. Orientador: Cleison Daniel Silva. 78 p. Dissertação (Mestrado Profissional em Computação Aplicada) — Universidade Federal do Pará (UFPA), Tucuruí, 2020. Disponível em: <<http://repositorio.ufpa.br:8080/jspui/handle/2011/12790>>. Acesso em: 07 ago. 2020.
- ROSCA, S. et al. Quadcopter control using a BCI. **IOP Conference Series: Materials Science and Engineering**, IOP Publishing, v. 294, p. 012048, Jan. 2018. ISSN 1757-899X. Disponível em: <<https://doi.org/10.1088/1757-899x/294/1/012048>>.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958. Disponível em: <<https://psycnet.apa.org/doi/10.1037/h0042519>>.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **nature**, Nature Publishing Group, v. 323, n. 6088, p. 533–536, 1986. Disponível em: <<https://doi.org/10.1038/323533a0>>.
- SANDERS, S.; GIRAUD-CARRIER, C. Informing the use of hyperparameter optimization through metalearning. In: **2017 IEEE International Conference on Data Mining (ICDM)**. [s.n.], 2017. p. 1051–1056. Disponível em: <<https://doi.org/10.1109/ICDM.2017.137>>.
- SANEI, S.; CHAMBERS, J. A. **EEG signal processing**. Chichester: John Wiley & Sons, 2007. 312 p. ISBN 978-0-4700-2581-9. Disponível em: <<https://bit.ly/30HSiyH>>.
- SANNELLI, C. et al. On optimal channel configurations for smr-based brain–computer interfaces. **Brain Topography**, , v. 23, n. 2, p. 186–193, Jun. 2010. ISSN 1573-6792. Disponível em: <<https://doi.org/10.1007/s10548-010-0135-0>>.
- SCHERER, R. et al. Brain–computer interfacing: more than the sum of its parts. **Soft Computing**, , v. 17, n. 2, p. 317–331, Feb. 2013. ISSN 1433-7479. Disponível em: <<https://doi.org/10.1007/s00500-012-0895-4>>.
- SCHLÖGL, A. et al. Evaluation criteria in BCI research. In: DORNHEGE, G. et al. (Eds.). **Toward brain-computer interfacing**. Cambridge, MA: The MIT Press, 2007. p. 327–342. ISBN 978-0-262-04244. Disponível em: <<https://bit.ly/2L2Kq7Q>>.
- SCHOMER, D. L.; SILVA, F. H. L. da. **Niedermeyer’s Electroencephalography: Basic principles, clinical applications, and related fields**. 7. ed. New York, NY: [s.n.], 2018. 1264 p. ISBN 978-0-1902-2848-4. Disponível em: <<https://bit.ly/3nUyzaA>>.
- SENA, M. L. d. R. **Desenvolvimento de um sistema BCI-SSVEP e testes preliminares no controle de um protótipo de cadeira de rodas**. Orientadora: Sarah Negreiros de Carvalho Leite. 40 p. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) — Instituto de Ciências Exatas e Aplicadas, Universidade Federal de Ouro Preto (UFOP), João Monlevade, 2018. Disponível em: <<https://www.monografias.ufop.br/handle/35400000/1020>>. Acesso em: 20 jun. 2020.
- SETHI, S.; UPADHYAY, R.; SINGH, H. S. Stockwell-common spatial pattern technique for motor imagery-based brain computer interface design. **Computers & Electrical Engineering**, v. 71, p. 492–504, 2018. ISSN 0045-7906. Disponível em: <<https://doi.org/10.1016/j.compeleceng.2018.07.056>>.

- SHAHRIARI, B. et al. Taking the human out of the loop: A review of bayesian optimization. **Proceedings of the IEEE**, v. 104, n. 1, p. 148–175, Jan 2016. ISSN 1558-2256. Disponível em: <<https://doi.org/10.1109/JPROC.2015.2494218>>.
- SHARBROUGH, F. American electroencephalographic society guidelines for standard electrode position nomenclature. **J clin Neurophysiol**, Raven Press, v. 8, p. 200–202, 1991. Disponível em: <<https://bit.ly/2MAAt0PD>>.
- SILVA, C. et al. Towards a LMI approach to feature extraction improvements and classification by Riemann distance. In: **2016 12th IEEE International Conference on**. IEEE, 2016. p. 990–995. ISBN 978-1-5090-1738-6. Disponível em: <<https://doi.org/10.1109/ICCA.2016.7505409>>.
- SILVA, C. D. **Processamento de sinais de EEG para classificação de tarefas motoras em sistemas de interface cérebro-máquina**. Orientador: Alexandre Trofino Neto. 189 p. Tese (Doutorado em Engenharia de Automação e Sistemas) — Universidade Federal de Santa Catarina (UFSC), Florianópolis, 2017. Disponível em: <<https://repositorio.ufsc.br/handle/123456789/179946>>. Acesso em: 25 mar. 2020.
- SILVERTHORN, D. U. **Fisiologia Humana: uma abordagem integrada**. 7. ed. [S.l.]: Porto Alegre: Artmed editora, 2017. ISBN 978-8-5388-0532-8.
- SINGH, H. et al. Classification and feature extraction strategies for multi channel multi trial BCI data. International Society for Bioelectromagnetism, 2007. Disponível em: <<http://hdl.handle.net/10044/1/53682>>.
- SNOEK, J.; LAROCHELLE, H.; ADAMS, R. P. Practical bayesian optimization of machine learning algorithms. In: PEREIRA, F. et al. (Ed.). **Advances in neural information processing systems**. Curran Associates, Inc., 2012. v. 25, p. 2951–2959. Disponível em: <<http://papers.nips.cc/paper/4522-practical-bayesian-optimization>>.
- SNOEK, J. et al. Scalable bayesian optimization using deep neural networks. In: **International conference on machine learning**. [s.n.], 2015. p. 2171–2180. Disponível em: <<http://proceedings.mlr.press/v37/snoek15.pdf>>.
- SONG, X. et al. A quadcopter controlled by brain concentration and eye blink. In: **2016 IEEE Signal Processing in Medicine and Biology Symposium (SPMB)**. [s.n.], 2016. p. 1–4. ISBN 978-1-5090-6713-8. Disponível em: <<https://doi.org/10.1109/SPMB.2016.7846875>>.
- STEGMAN, P. et al. Brain–computer interface software: A review and discussion. **IEEE Transactions on Human-Machine Systems**, v. 50, n. 2, p. 101–115, 2020. Disponível em: <<https://ieeexplore.ieee.org/document/8995646/>>.
- SUBHA, D. P. et al. EEG signal analysis: a survey. **Journal of medical systems**, , v. 34, n. 2, p. 195–212, Abr. 2010. ISSN 573-689X. Disponível em: <<https://doi.org/10.1007/s10916-008-9231-z>>.
- SUK, H.; LEE, S. A novel bayesian framework for discriminative feature extraction in brain-computer interfaces. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 35, n. 2, p. 286–299, 2013.

- SUK, H.-I.; LEE, S.-W. Subject and class specific frequency bands selection for multiclass motor imagery classification. **International Journal of Imaging Systems and Technology**, v. 21, n. 2, p. 123–130, 2011. Disponível em: <<https://doi.org/10.1002/ima.20283>>.
- SUN, G.; HU, J.; WU, G. A novel frequency band selection method for common spatial pattern in motor imagery based brain computer interface. In: **The 2010 International Joint Conference on Neural Networks (IJCNN)**. [s.n.], 2010. p. 1–6. Disponível em: <<https://doi.org/10.1109/IJCNN.2010.5596474>>.
- SUNNY, T. et al. Robotic arm with brain–computer interfacing. **Procedia Technology**, v. 24, p. 1089–1096, 2016. ISSN 2212-0173. Disponível em: <<https://doi.org/10.1016/j.protcy.2016.05.241>>.
- SWERSKY, K.; SNOEK, J.; ADAMS, R. P. **Freeze-Thaw Bayesian Optimization**. 2014. Disponível em: <<https://arxiv.org/abs/1406.3896>>.
- TAN, D.; NIJHOLT, A. Brain-computer interfaces and human-computer interaction. In: **Brain-Computer Interfaces**. [S.l.]: Springer, 2010. p. 3–19.
- TANGERMANN, M. et al. Review of the BCI competition iv. **Frontiers in Neuroscience**, v. 6, p. 55, 2012. ISSN 1662-453X. Disponível em: <<https://doi.org/10.3389/fnins.2012.00055>>.
- TEPLAN, M. Fundamentals of EEG measurement. **Measurement science review**, , v. 2, n. 2, p. 1–11, Jan. 2002. ISSN 1335-8871. Disponível em: <<https://bit.ly/3mWna94>>.
- THOMAS, E.; DYSON, M.; CLERC, M. An analysis of performance evaluation for motor-imagery based BCI. **Journal of Neural Engineering**, IOP Publishing, v. 10, n. 3, p. 031001, may 2013. ISSN 1741-2552. Disponível em: <<https://doi.org/10.1088/1741-2560/10/3/031001>>.
- THOMPSON, D. E.; BLAIN-MORAES, S.; HUGGINS, J. E. Performance assessment in brain-computer interface-based augmentative and alternative communication. **Biomedical engineering online**, Springer, v. 12, n. 1, p. 43, 2013. Disponível em: <<https://link.springer.com/article/10.1186/1475-925X-12-43>>.
- URIGÜEN, J. A.; GARCIA-ZAPIRAIN, B. EEG artifact removal—state-of-the-art and guidelines. **Journal of Neural Engineering**, IOP Publishing, v. 12, n. 3, p. 031001, apr 2015. Disponível em: <<https://doi.org/10.1088/1741-2560/12/3/031001>>.
- VAZ, Y. **Extração de características para a classificação de imagética motora em interfaces cérebro-computador**. Orientador: Rodrigo Fernandes de Mello. 91 p. Dissertação (Mestrado em Ciência da Computação e Matemática Computacional) — Universidade de São Paulo (USP), São Carlos, 2016. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-09112016-141922/en.php>>. Acesso em: 14 jun. 2020.
- VECCHIATO, G. et al. EEG analysis of the brain activity during the observation of commercial, political, or public service announcements. **Computational Intelligence and Neuroscience**, Hindawi Publishing Corporation, v. 2010, p. 1–7, 2010. ISSN 1687-5273. Disponível em: <<https://doi.org/10.1155/2010/985867>>.

- VELLOSO, B. P. **Atenção como critério de avaliação de objetos de ensino e aprendizagem baseado em suas características**. Orientadora: Alice Theresinha Cybis Pereira. 333 p. Tese (Doutorado em Engenharia e Gestão do Conhecimento) — Universidade Federal de Santa Catarina (UFSC), Florianópolis, 2014. Disponível em: <<https://repositorio.ufsc.br/handle/123456789/133062>>. Acesso em: 16 ago. 2020.
- VISHWANATH, R. M.; KUMAAR, S.; OMKAR, S. N. A real-time control approach for unmanned aerial vehicles using brain-computer interface. **CoRR**, , abs/1809.00346, Out. 2018. Disponível em: <<http://arxiv.org/abs/1809.00346>>.
- VOURVOPOULOS, A.; LIAROKAPIS, F.; CHEN, M.-C. The effect of prior gaming experience in motor imagery training for brain-computer interfaces: A pilot study. In: **2015 7th International Conference on Games and Virtual Worlds for Serious Applications (VS-Games)**. IEEE, 2015. p. 1–8. ISBN 978-1-4799-8102-1. Disponível em: <<https://doi.org/10.1109/VS-GAMES.2015.7295789>>.
- WANG, H. Optimizing spatial filters for single-trial EEG classification via a discriminant extension to CSP: the fisher criterion. **Medical & Biological Engineering & Computing**, , v. 49, n. 9, p. 997–1001, Set. 2011. ISSN 1741-0444. Disponível em: <<https://doi.org/10.1007/s11517-011-0766-7>>.
- WANG, M. et al. A wearable SSVEP-based BCI system for quadcopter control using head-mounted device. **IEEE Access**, , v. 6, p. 26789–26798, 2018. ISSN 2169-3536. Disponível em: <<https://doi.org/10.1109/ACCESS.2018.2825378>>.
- WANG, Y.; GAO, S.; GAO, X. Common spatial pattern method for channel selection in motor imagery based brain-computer interface. In: **2005 IEEE Engineering in Medicine and Biology 27th Annual Conference**. [s.n.], 2005. p. 5392–5395. ISBN 0-7803-8741-4. ISSN 1094-687X. Disponível em: <<https://doi.org/10.1109/IEMBS.2005.1615701>>.
- WANG, Z. et al. Towards a hybrid BCI gaming paradigm based on motor imagery and ssvep. **International Journal of Human-Computer Interaction**, Taylor & Francis, v. 35, n. 3, p. 197–205, 2019. Disponível em: <<https://doi.org/10.1080/10447318.2018.1445068>>.
- WEI, Q.; WEI, Z. Binary particle swarm optimization for frequency band selection in motor imagery based brain-computer interfaces. **Bio-medical materials and engineering**, IOS Press, v. 26, n. s1, p. S1523–S1532, 2015. Disponível em: <<https://bit.ly/2WOfwD7>>.
- WEI, Z.; WEI, Q. The backtracking search optimization algorithm for frequency band and time segment selection in motor imagery-based brain-computer interfaces. **Journal of Integrative Neuroscience**, v. 15, n. 3, p. 347–364, 2016. ISSN 0219-6352. Disponível em: <<http://dx.doi.org/10.1142/S021963521650022>>.
- WIDMANN, A.; SCHRÖGER, E.; MAESS, B. Digital filter design for electrophysiological data – a practical approach. **Journal of Neuroscience Methods**, v. 250, p. 34 – 46, 2015. ISSN 0165-0270. Cutting-edge EEG Methods. Disponível em: <<https://doi.org/10.1016/j.jneumeth.2014.08.002>>.
- WIERZGAJA, P. et al. Most popular signal processing methods in motor-imagery BCI: A review and meta-analysis. **Frontiers in Neuroinformatics**, v. 12, p. 78, 2018. ISSN 1662-5196. Disponível em: <<https://www.frontiersin.org/article/10.3389/fninf.2018.00078>>.

WOLPAW, J.; WOLPAW, E. W. **Brain–Computer Interfaces: principles and practice**. 1. ed. USA: Oxford University Press (OUP), 2012. 424 p. ISBN 978-0-195-38885-5. Disponível em: <<https://bit.ly/2MpGP3c>>.

WOLPAW, J. R. et al. Brain–computer interfaces for communication and control. **Clinical neurophysiology**, v. 113, n. 6, p. 767–791, Jun. 2002. ISSN 1388-2457. Disponível em: <[https://doi.org/10.1016/S1388-2457\(02\)00057-3](https://doi.org/10.1016/S1388-2457(02)00057-3)>.

WOLPAW, J. R. et al. EEG-based communication: improved accuracy by response verification. **IEEE Transactions on Rehabilitation Engineering**, v. 6, n. 3, p. 326–333, 1998. Disponível em: <<https://doi.org/10.1109/86.712231>>.

WORLD HEALTH ORGANIZATION; INTERNATIONAL SPINAL CORD SOCIETY. **International perspectives on spinal cord injury**. Geneva: WHO Press, 2013. ISBN 978-92-4-156466-3. Disponível em: <<https://bit.ly/2ZcLzLq>>. Acesso em: 15 ago. 2020.

WU, H. et al. Evaluation of motor training performance in 3D virtual environment via combining brain-computer interface and haptic feedback. **Procedia Computer Science**, v. 107, p. 256–261, 2017. ISSN 1877-0509. Proceedings of 7th International Congress of Information and Communication Technology (ICICT2017). Disponível em: <<https://doi.org/10.1016/j.procs.2017.03.096>>.

XU, P. et al. Using particle swarm to select frequency band and time interval for feature extraction of EEG based BCI. **Biomedical Signal Processing and Control**, v. 10, p. 289–295, 2014. ISSN 1746-8094. Disponível em: <<https://doi.org/10.1016/j.bspc.2013.08.012>>.

XU, P. et al. An enhanced probabilistic lda for multi-class brain computer interface. **PloS one**, Public Library of Science, v. 6, n. 1, p. e14634, 2011. Disponível em: <<https://bit.ly/3nRjCWY>>.

YANG, B. et al. Subject-based feature extraction by using fisher WPD-CSP in brain–computer interfaces. **Computer Methods and Programs in Biomedicine**, v. 129, p. 21 – 28, 2016. ISSN 0169-2607. Disponível em: <<https://doi.org/10.1016/j.cmpb.2016.02.020>>.

YANG, Y. et al. Subject-specific time-frequency selection for multi-class motor imagery-based BCIs using few laplacian EEG channels. **Biomedical Signal Processing and Control**, , v. 38, p. 302–311, 2017. ISSN 1746-8094. Disponível em: <<https://doi.org/10.1016/j.bspc.2017.06.016>>.

YGER, F.; BERAR, M.; LOTTE, F. Riemannian approaches in brain-computer interfaces: A review. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 25, n. 10, p. 1753–1762, 2017. Disponível em: <<https://ieeexplore.ieee.org/document/7740054/>>.

ZHANG, Y. et al. Sparse bayesian learning for obtaining sparsity of EEG frequency bands based feature vectors in motor imagery classification. **International journal of neural systems**, World Scientific, v. 27, n. 02, p. 1650032, 2017. Disponível em: <<https://doi.org/10.1142/S0129065716500325>>.

ZHANG, Y. et al. Optimizing spatial patterns with sparse filter bands for motor-imagery based brain-computer interface. **Journal of Neuroscience Methods**, v. 255, p. 85 – 91, 2015. ISSN 0165-0270. Disponível em: <<https://doi.org/10.1016/j.jneumeth.2015.08.004>>.

ŠKOLA, F.; LIAROKAPIS, F. Embodied VR environment facilitates motor imagery brain-computer interface training. **Computers & Graphics**, , v. 75, p. 59–71, Jun. 2018. Disponível em: <<https://www.researchgate.net/publication/325702969>>.

APÊNDICES

A Frequency Decomposition Approach for Sub-Band Common Spatial Pattern Methods for Motor Imagery based Brain-Computer Interface

Vitor. M. Vilas Boas, Cleison. D. Silva, Gustavo. S. Mafra, Alexandre Trofino Neto

Abstract— Motor Imagery (MI) based Brain-Computer Interfaces (BCI) uses Event-Related (de)Synchronization (ERS/ERD), typically recorded using electroencephalography (EEG), to translate brain electrical activity into control commands. To mitigate undesirable artifacts and noise measurements on EEG signals, methods based on band-pass filters defined by a specific frequency band (i.e. 8 – 30Hz), such as the Infinity Impulse Response (IIR) filters, are typically used. Spatial techniques, such as Common Spatial Patterns (CSP), are also used to estimate the variations of the filtered signal and extract features that define the imagined motion. The CSP effectiveness depends on the subject's discriminative frequency, and approaches based on the decomposition of the band of interest into Sub-Bands with smaller frequency ranges (SBCSP) have been suggested to EEG signals classification. However, despite providing good results, the SBCSP approach generally increases the computational cost of the filtering step in IM-based BCI systems. This paper proposes the use of the Fast Fourier Transform (FFT) algorithm in the IM-based BCI filtering stage that implements SBCSP. The goal is to apply FFT algorithm to reduce the computational cost of the processing step of these systems and to make them more efficient without compromising classification accuracy. The proposal is based on the representation of EEG signals in a matrix of coefficients resulting from the frequency decomposition performed by the FFT, which is then submitted to the SBCSP process. The structure of the SBCSP contemplates dividing the band of interest, initially defined between 0 and 40Hz, into a set of 33 sub-bands spanning specific frequency bands which are processed in parallel each by a CSP filter and an LDA classifier. A Bayesian meta-classifier is then used to represent the LDA outputs of each sub-band as scores and organize them into a single vector, and then used as a training vector of an SVM global classifier. Initially, the public EEG data set IIa of the BCI Competition IV is used to validate the approach. The first contribution of the proposed method is that, in addition to being more compact, because it has a 68% smaller dimension than the original signal, the resulting FFT matrix maintains the signal information relevant to class discrimination. In addition, the results showed an average reduction of 31.6% in the computational cost in relation to the application of filtering methods based on IIR filters, suggesting FFT efficiency when applied in the

filtering step. Finally, the frequency decomposition approach improves the overall system classification rate significantly compared to the commonly used filtering, going from 73.7% using IIR to 84.2% using FFT. The accuracy improvement above 10% and the computational cost reduction denote the potential of FFT in EEG signal filtering applied to the context of IM-based BCI implementing SBCSP. Tests with other data sets are currently being performed to reinforce such conclusions.

Keywords— Brain-computer interfaces, fast Fourier transform algorithm, motor imagery, sub-band common spatial patterns.

Vitor M. Vilas Boas is with the Amazon Development Center in Engineering, Federal University of Pará, NDAE/UFPA, Tucuruí, PA, Brazil (e-mail: vitormendesvilasboas@gmail.com).

Cleison D. Silva is with the Amazon Development Center in Engineering, Federal University of Pará, NDAE/UFPA, Tucuruí, PA, Brazil (e-mail: cleisond@gmail.com).

Gustavo S. Mafra was with the Department of Automation and Systems Engineering, Federal University of Santa Catarina, DAS/CTC/UFSC, Florianópolis, SC, Brazil (e-mail: gsenamafra@gmail.com).

Alexandre Trofino Neto is with the Department of Automation and Systems Engineering, Federal University of Santa Catarina, DAS/CTC/UFSC, Florianópolis, SC, Brazil (e-mail: alexandre.trofino@ufsc.br).