

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROJETO DE GRADUAÇÃO**

JORGE HENRIQUE POSSES NASCIMENTO

**INTERFACE CÉREBRO-COMPUTADOR PARA
REABILITAÇÃO DE MEMBROS INFERIORES ATRAVÉS
DO ACIONAMENTO DE UM PEDAL MOTORIZADO
COMANDADO PELA IMAGÉTICA MOTORA**

VITÓRIA
2021

JORGE HENRIQUE POSSES NASCIMENTO

**INTERFACE CÉREBRO-COMPUTADOR PARA REABILITAÇÃO DE
MEMBROS INFERIORES ATRAVÉS DO ACIONAMENTO DE UM
PEDAL MOTORIZADO PELA IMAGÉTICA MOTORA**

Parte manuscrita do Projeto de Graduação do aluno **Jorge Henrique Posses Nascimento**, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Orientador: Prof. Dr. Teodiano F. Bastos Filho

Coorientador: Prof. Dr. Denis Delisle Rodriguez

VITÓRIA
2021

JORGE HENRIQUE POSSES NASCIMENTO

**INTERFACE CÉREBRO-COMPUTADOR PARA REABILITAÇÃO DE
MEMBROS INFERIORES ATRAVÉS DO ACIONAMENTO DE UM
PEDAL MOTORIZADO COMANDADO PELA IMAGÉTICA MOTORA**

Parte manuscrita do Projeto de Graduação do aluno **Jorge Henrique Posses Nascimento**, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Aprovado em 14 de maio de 2021.

COMISSÃO EXAMINADORA:

Prof. Dr. Teodiano F. Bastos Filho
Universidade Federal do Espírito Santo
Orientador

Dr. Denis Delisle Rodriguez
Universidade Federal do Espírito Santo
Coorientador

Profa. Eliete Maria de Oliveira Caldeira
Universidade Federal do Espírito Santo
Examinador

Enga. MSc Letícia Araújo Silva
Universidade Federal do Espírito Santo
Examinador

RESUMO

Os acidentes vasculares cerebrais (AVCs) ocorrem, predominantemente, em pessoas adultas ou idosas, sendo um fator que impacta enormemente na qualidade de vida das pessoas acometidas. Visando atenuar a perda da qualidade de vida, técnicas convencionais de reabilitação vêm sendo utilizadas para a melhoria do equilíbrio, marcha e movimento dos membros afetados. Entretanto, um ponto negativo dessas técnicas é uma demora no processo de reabilitação e um custo elevado de sua implantação em clínicas e hospitais. Uma técnica moderna de reabilitação é através do uso de interfaces cérebro-computador (ICCs) para controlar dispositivos robóticos assistivos (exoesqueletos, andadores inteligentes ou pedais motorizados), com a finalidade de melhorar as atividades motoras dos indivíduos acometidos por AVC e diminuir o tempo de reabilitação. Neste projeto de Graduação é apresentada uma nova ICC que permite pacientes pós-AVC comandar um pedal motorizado através da imagética motora (IM), com o uso efetivo das regiões cerebrais relacionadas ao movimento dos membros inferiores. Vale salientar que a IM é uma técnica na qual um sujeito simula mentalmente uma determinada ação e se sente realizando-a. Para alcançar tal objetivo, foi feito um estudo sobre algoritmos de processamento de sinais de eletroencefalografia (EEG), focando no reconhecimento da IM e explorando novas implementações na etapa de extração de características de forma a melhorar o reconhecimento do padrão de pedalar. Aliado ao algoritmo proposto, também foi utilizado o cálculo de percentil para melhorar e escolher o sinal de interesse. Para a ICC proposta neste projeto de Graduação, observou-se na fase de calibração uma redução da acurácia e do índice Kappa quando comparada com os avanços obtidos pelo Núcleo de Tecnologia Assistiva (NTA) da UFES. Por outro lado, na fase de validação, notou-se que, para os classificadores utilizados, houve uma melhora de performance considerável para alguns sujeitos, além de ter aumentado o valor médio de acurácia do grupo de estudo. Os resultados obtidos nesta pesquisa demonstram um grande potencial para melhorar o reconhecimento do padrão de IM, devendo mais estudos serem conduzidos nessa área.

Palavras-chave: Eletroencefalograma. Interface Cérebro-Computador. Imagética Motora. Reabilitação de Membros Inferiores. Pedal Motorizado.

ABSTRACT

Stroke occur, predominantly, in adults or elderly, being a factor that has a huge impact on the quality of life of the people affected. To mitigate the loss of quality of life, conventional rehabilitation techniques have been used to improve balance, gait and movement of the affected limbs. However, a negative point of these techniques is a long delay in the rehabilitation process and a high cost of its implantation in clinics and hospitals. A modern rehabilitation technique is using brain-computer interfaces (BCIs) to control assistive robotic devices (exoskeletons, intelligent walkers or motorized pedals), in order to improve motor activities individuals and decrease the rehabilitation time. In this Graduation Project, a new BCI is introduced, which allows post-stroke patients to control a motorized pedal through motor imagery (MI), using the effective brain region related to the lower-limb movement. It is worth noting that MI is a technique in which a person mentally simulates a certain action and feels that it is being performed. To achieve this goal, a study was conducted on algorithms for electroencephalography (EEG) signals, focusing on the recognition of MI and exploring new implementations in the step of extracting features to improve the pedaling pattern recognition. In addition to the proposed algorithm, the percentile was also used to better choose the signal of interest. For the BCI proposed here, it was observed in the calibration phase a reduction in both accuracy and Kappa index when comparing the advances obtained by the Assistive Technology Group at UFES. On the other hand, in the validation phase, it was noted that, for the classifiers used, there was a considerable improvement in performance for some subjects as well as an increase in the mean accuracy of the study group. The results obtained in this research demonstrate a great potential to improve the recognition of MI patterns, which motivates further studies to be conducted in this area.

Keywords: Eletroencefalogram. Brain-Computer Interface. Motor Imagery. Lower-Limb Rehabilitation. Motorized Pedal.

LISTA DE FIGURAS

Figura 1 – Tipos de AVC. (a) AVC isquêmico e (b) AVC hemorrágico	13
Figura 2 – Terapia do espelho	14
Figura 3 – Terapia com esteira	15
Figura 4 – Tipos de robôs assistivos. (a) Pedal motorizado, (b) exoesqueleto robótico e (c) andador inteligente	17
Figura 5 – Interface cérebro-computador	23
Figura 6 – Diagrama de blocos para o algoritmo PEC	28
Figura 7 – Hiperplano separador para ADL	31
Figura 8 – Hiperplano separador para MVS.....	32
Figura 9 – ICC estudada	36
Figura 10 – Sistema de aquisição de sinal EEG	39
Figura 11 – Sistema internacional 10-20.....	40
Figura 12 – Protocolo usado no conjunto de calibração.....	40
Figura 13 – Acurácia das ICCs analisadas	43
Figura 14 – Kappa das ICCs analisadas	44
Figura 15 – Acurácia da ICC base para fase de validação	45
Figura 16 – Acurácia da ICC para a fase de validação.....	45

LISTA DE TABELAS

Tabela A1 – Resultados das interfaces cérebro-computador simuladas.....	54
---	----

LISTA DE ABREVIATURAS E SIGLAS

ACI	Análise de Componentes Independentes
ACP	Análise de Componentes Principais
ADL	Análise de Discriminante Linear
ADR	Análise de Discriminante Regularizado
ARCI	Análise Rápida de Componentes Independentes
AVC	Acidente Vascular Cerebral
AVD	Atividades da Vida Diária
BFPEC	Banco de Filtros de Padrão Espacial Comum
CCK	Coeficiente de Cohen Kappa
DRE	Dessincronização Relacionada a Eventos
EEG	Eletroencefalograma
EMGS	Eletromiografia de Superfície
ER	Exoesqueleto Robótico
FN	Falso Negativo
FP	Falso Positivo
GR	Geometria de Riemann
IBGE	Instituto Brasileiro de Geografia e Estatística
ICC	Interface Cérebro-Computador
ICM	Interface Cérebro-Máquina
IM	Imagética Motora
IMM	Interface Mente-Máquina
ITRF	Inversa da Transformada Rápida de Fourier
MC	Matriz de Confusão
NTA	Núcleo de Tecnologia Assistiva
OCB	<i>OpenBCI Cyton Board</i>
OMS	Organização Mundial da Saúde
PCRM	Potencial Cortical Relacionada ao Movimento
PEC	Padrão Espacial Comum
PNS	Pesquisa Nacional de Saúde
RMC	Referência de Média Comum
RML	Referência de Média Local
RMP	Referência pela Média Ponderada

RRMC	Razão de Rejeição de Modo Comum
SER	Sincronização Relacionada a Eventos
TE	Terapia do Espelho
TEs	Terapia com Esteira
TF	Transformada de Fourier
TMIR	Terapia de Movimento Induzida por Restrição
TRF	Transformada Rápida de Fourier
UFES	Universidade Federal do Espírito Santo
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

LISTA DE SÍMBOLOS

α	Ritmo <i>alpha</i>
β	Ritmo <i>beta</i>
δ	Ritmo <i>delta</i>
γ	Ritmo <i>gamma</i>
μ	Ritmo <i>mu</i>
θ	Ritmo <i>theta</i>
κ	Índice Cohen Kappa
ACC	Acurácia

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Motivação	12
1.2	Justificativa	18
2	OBJETIVOS	20
2.1	Objetivo Geral.....	20
2.2	Objetivos Específicos	20
3	EMBASAMENTO TEÓRICO	21
3.1	Eletroencefalograma	21
3.1.1	Potencial Oscilatório.....	21
3.1.2	Potencial Cortical Relacionado ao Movimento	22
3.2	Imaginação Motora	22
3.3	Interface Cérebro-Computador	23
3.3.1	Pré-processamento.....	23
3.3.2	Extração de Características.....	25
3.3.2.1	Geometria de Riemann	25
3.3.2.2	Padrão Espacial Comum.....	27
3.3.3	Classificação.....	31
3.3.4	Método de Análise de Dados.....	32
3.3.4.1	Acurácia.....	33
3.3.4.2	Coeficiente de Cohen Kappa	34
4	METODOLOGIA E MÉTODOS	35
4.1	Aspectos Metodológicos	35
4.2	Etapas da Interface Cérebro-Computador	35
4.3	Ponderação para o Vetor de Características	36
4.4	Probabilidade Baseada na Seleção de Padrões	38
4.5	Coleta de Sinal	39
4.6	Interface Cérebro-Computador Proposta	41
5	RESULTADOS.....	43
5.1	Análise da Fase de Calibração.....	43

5.2	Análise da Fase de Validação	45
6	CONCLUSÃO	47
	REFERÊNCIAS BIBLIOGRÁFICAS	48
	APÊNDICE A – RESULTADOS PARA CADA ICC	54

1 INTRODUÇÃO

1.1 Motivação


O Instituto Brasileiro de Geografia e Estatística (IBGE) realizou em 2019 a Pesquisa Nacional de Saúde (PNS), onde visitou cerca de 108 mil domicílios em mais de 2000 municípios de todo o país, e estimou que o Brasil tem 38,1 milhões de hipertensos, 34,3 milhões de pessoas com problemas na coluna e 3,1 milhões de adultos que já sofreram um acidente vascular cerebral (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2020). De acordo com a Organização Mundial de Saúde (OMS) o AVC é a segunda causa mais frequente de morte do mundo e a maior causa de deficiência no Brasil, com uma incidência anual de 108 por 100 mil habitantes. Ainda segundo a OMS, no mundo todo, 15 milhões de pessoas sofrem um AVC a cada ano, o que reduz a expectativa de vida em cerca de 1,5 anos (WORLD HEALTH ORGANIZATION, 2019).

O AVC é uma síndrome neurológica com predomínio em pessoas adultas e idosas, sendo uma das principais causas de fatalidade no mundo. Esse acidente vascular cerebral ocorre quando há interrupção do suprimento de sangue para o cérebro, geralmente porque um vaso sanguíneo é rompido (chamado AVC hemorrágico) ou bloqueado por um coágulo (chamado AVC isquêmico). Dessa forma, o tecido cerebral fica sem fornecimento de oxigênio e nutrientes. Os sintomas mais comuns do AVC são fraqueza repentina ou dormência do rosto, braço ou perna, normalmente em um dos lados do corpo. Outros indícios do AVC são confusão, dificuldade para falar e entender frases, dificuldade de andar, tontura, perda de coordenação e equilíbrio (HEALTHLINE, 2018).

De acordo com a American Stroke Association (2021), o AVC isquêmico ocorre quando não há fornecimento de sangue para o cérebro, sendo que normalmente essa interrupção se dá por um depósito de placa gordurosa no vaso sanguíneo. Quando o suprimento de sangue é interrompido por um tempo determinado, ocorre o AVC isquêmico transitório. Outro tipo de acidente vascular cerebral é o AVC hemorrágico, que acontece quando um vaso sanguíneo fragilizado rompe e sangra nos arredores do tecido cerebral, comprimindo células cerebrais e causando a sua morte. A causa mais comum desse AVC é a hipertensão arterial não controlada.

Desses tipos apresentados, o AVC isquêmico ocorre em 87% dos casos. A Figura 1 ilustra os dois tipos de AVC.

Figura 1 – Tipos de AVC. (a) AVC isquêmico e (b) AVC hemorrágico



Fonte: Hospital Encore (2021).

O AVC geralmente leva à perda do controle voluntário, uma vez que o cérebro regula a ativação muscular, o movimento seletivo das articulações, a coordenação, o equilíbrio e o tônus (ARYA; PANDIAN; KUMAR, 2019). Além disso, esse acidente vascular cerebral afeta os membros inferiores e, com isso, as ações de ficar em pé e caminhar são de difícil execução. Dessa forma, é comum que essas pessoas tenham dificuldade em efetuar atividades diárias por conta própria, tais como tomar banho, realizar a higiene pessoal e ir ao banheiro.

A reabilitação neurológica de pacientes pós-AVC tem um comportamento logarítmico (KWAKKEL; KOLLEN; TWISK, 2006), sendo que a maior parte da recuperação ocorre nos primeiros 3 meses após o acidente, embora a recuperação não esteja limitada a esse período. A melhora desses pacientes ocorre através de uma combinação complexa de processos espontâneos e dependentes de aprendizado, tais como restituição, substituição e compensação (KWAKKEL; KOLLEN; LINDEMAN, 2004). De uma forma geral, os objetivos primários da reabilitação de pacientes pós-AVC são fazer com que os pacientes sejam capazes de caminhar e poder efetuar as atividades da vida diária (AVD) de forma independente.


Uma das terapias utilizadas para a reabilitação de pacientes pós-AVC é a terapia de movimento induzida por restrição (TMIR), a qual é aplicada para reabilitar membros superiores, sendo a intervenção mais estudada nas últimas décadas (KWAKKEL; KOLLEN; TWISK, 2006). A

TMIR envolve a restrição dos órgãos superiores menos afetados por um período prolongado, em combinação com treinamento relacionado ao trabalho da área mais afetada (WANG et al., 2011). Esse método é eficiente, pois combate o desuso aprendido do membro afetado, o que acontece quando o cérebro esquece de como manuseá-lo, uma vez que o paciente para de usá-lo completamente (RICHARDS et al., 2008).

Outra forma de fazer reabilitação é com o uso de um programa tradicional de exercícios, que previne complicações de imobilização e melhora a realização das AVDs. Esses exercícios podem ser divididos em passivo e ativo. Na primeira modalidade, o terapeuta move as articulações passivamente por toda a amplitude do movimento e, dessa forma, ajuda a impedir a contratura e o desenvolvimento de posturas anormais. Para o movimento ativo, o paciente move as articulações de forma independente. Vale salientar que essa técnica ajuda na aprendizagem motora (NAIR; TALY, 2002).

Outra terapia comum é a terapia do espelho (TE), onde se utiliza um espelho para criar um reflexo do membro não parético superior ou inferior, dando ao paciente um *feedback* visual de movimento normal para a área afetada (THIEME et al., 2018). O uso da TE também auxilia na reabilitação motora, pois ativa a região do córtex pré-motor. Outro fator importante é que essa intervenção pode ajudar a reverter o desuso dos membros afetados, tanto em nível neurológico como psicológico (ALTSCHULER et al., 1999). A TE é observada na Figura 2.

Figura 2 – Terapia do espelho



Fonte: Vural e outros (2015).

A restauração da marcha requer técnicas diferentes e frequentemente exige assistência do terapeuta para ajudar o paciente no controle de equilíbrio. As técnicas convencionais de treino de marcha muitas vezes levam a um padrão assimétrico em muitos pacientes pós-AVC (CUNHA et al., 2002). De forma a melhorar o andar desses pacientes, utiliza-se a terapia com esteira (TEs), a qual consiste em suspender o corpo do paciente (através de correias) para melhorar o seu equilíbrio e peso enquanto sua caminhada é facilitada por uma esteira (Figura 3).

Figura 3 – Terapia com esteira



Fonte: Biodex (2021).

Outras terapias de reabilitação incluem o uso de dispositivos robóticos, sendo um deles o exoesqueleto robótico (ER), para melhora da capacidade motora. Essa técnica é utilizada quando é detectado que o paciente tem limitação motora, o que ocasiona uma redução da marcha e desequilíbrio do corpo. Estudos comprovam que o ER pode diminuir o tempo de reabilitação (VOGT et al., 2010). Além disso, pode-se citar a utilização de robôs sociais assistivos (RSA), que ajudam nesse processo fornecendo monitoramento, incentivo e lembretes ao paciente (MATARÍC et al., 2007) e também os robôs vestíveis (RV), que podem ser

classificados como uma tecnologia que estende, complementa, substitui ou melhora a função ou capacidade humana, ou substitui uma parte do membro onde é utilizada (PONS, 2008).

Uma das possibilidades de controle dos dispositivos robóticos é com o uso de eletromiografia de superfície (EMGS). Para tal, são posicionados eletrodos sobre o músculo, sendo que o sinal gerado equivale à soma algébrica de todos os sinais musculares captado pelos eletrodos, os quais são afetados por propriedades musculares, anatômicas e fisiológicas do músculo (BASMAJIAN; LUCA, 1985). Uma vez detectada uma contração ou flexão, o dispositivo robótico é estimulado, auxiliando o paciente a realizar um movimento de reabilitação mais natural (DIPIETRO et al., 2005). Outra possibilidade de controle de dispositivos robóticos é através do eletroencefalograma (EEG), que também é um método não-invasivo, no qual são colocados eletrodos sobre o escalpo do paciente, cujos sinais captados comandam o dispositivo robótico de reabilitação (ANG et al., 2015).


Uma interface cérebro-computador, também chamada de interface cérebro-máquina (ICM), pode fazer o uso do EEG, sendo que os sinais neurofisiológicos obtidos do paciente são transformados em comandos para o controle em tempo real do dispositivo robótico de reabilitação. Como a ICC permite fornecer aos terapeutas *feedback* sobre a atenção do paciente durante a reabilitação, esse método pode permitir ajustes, em tempo real, o que pode melhorar os resultados da terapia de pacientes pós-AVC (GOLDFINE; SCHIFF, 2011). Na robótica de reabilitação, as ICCs normalmente são utilizadas em conjunto com robôs assistivos, exoesqueletos e bicicletas ergométricas, com vista a melhorar a conexão entre cérebro e músculos, promovendo neuroplasticidade cerebral, e conseqüentemente restaurando as funções motoras prejudicadas.

Uma ICC pode basear-se na técnica de imagética motora, a qual é um processo cognitivo em que o paciente imagina a execução de um movimento (sem realmente mover ou tensionar o músculo, até mesmo porque se supõe que ele não pode mover tal músculo). Na IM há a ativação consciente de regiões do cérebro que também são envolvidas na preparação e execução do movimento (LOTZE; COHEN, 2006). Com essa prática mental, estudos de neuroimagem mostram que são detectadas ativações corticais nas áreas motoras, produzindo-se uma reorganização cortical em pessoas que sofreram AVC (GUEERA; LUCCHETTI; LUCCHETTI, 2017). A IM também pode ser observada na atividade do neurônio espelho, o

qual é excitado quando o paciente observa uma ação motora real de outra pessoa (KIM et al., 2014). Isto acontece porque a ação de observar uma pessoa realizando uma ação motora estimula a área motora do córtex, criando uma memória cinestésica, e também excitando o processo cognitivo quando relacionado ao aprendizado motor (MAEDA; KLEINER-FISMAN; PASCUAL-LEONE, 2002).

No Núcleo de Tecnologia Assistiva (NTA) da Universidade Federal do Espírito Santo (UFES) estão sendo feitos desenvolvimentos de sistemas robóticos de reabilitação de membros inferiores para pacientes pós-AVC, havendo sido implementada uma ICC em conjunto com um pedal motorizado, além de também ter sido construído um andador inteligente e um exoesqueleto robótico para o joelho, os quais são utilizados para ajudar os pacientes a melhorarem o equilíbrio e a marcha. Esses sistemas são ilustrados na Figura 4.

Figura 4 – Tipos de robôs assistivos. (a) Pedal motorizado, (b) exoesqueleto robótico e (c) andador inteligente



Fonte: Laiseca (2018), Villa-parra e outros (2017) e Hernández (2018).

Neste projeto de Graduação é proposta uma interface cérebro-computador baseada em EEG para reabilitação de membros inferiores através do acionamento de um pedal motorizado pela imagética motora, fazendo o uso das regiões cerebrais mais relacionadas ao movimento de pedalar. É importante salientar que objeto de pesquisa está relacionado ao processamento do sinal EEG, focando no reconhecimento da IM e explorando novas implementações na etapa de extração de características, de forma a melhorar o reconhecimento do padrão de pedalar. A ICC será avaliada por indicadores de desempenho e também comparando com avanços obtidos pelo NTA/UFES.

1.2 Justificativa

O padrão da atividade muscular durante o movimento de pedalar é muito semelhante a outras formas de locomoção, incluindo a marcha. Além disso, este movimento pode ser feito em um lugar controlado e seguro, possibilitando que outros pacientes com limitação motora possam também realizá-lo. Segundo Fujiwara, Liu e Chino (2003), pedalar é uma modalidade de treinamento potencialmente eficaz para reverter a fraqueza muscular e melhorar o desempenho motor dos pacientes. A ação de pedalar baseia-se em contrações rítmicas e funciona como um controle de caminhada, uma vez que a conclusão destas ações requer que os músculos agonistas e antagonistas sejam ativados alternadamente (CHEN et al., 2014). Outro ponto importante é que, para pacientes com pouco controle de equilíbrio e coordenação, este ato provê um suporte mais adequado para o tronco, ajudando-os a movimentarem seus membros inferiores (CHEN et al., 2005).

As terapias que se baseiam em ICCs podem utilizar a técnica de imagética motora para pacientes com afecção motora severa. A IM, que foi inicialmente empregada para melhorar a performance de atletas, tem sido adotada em programas de reabilitação para pacientes pós-AVC (CALLOW; HARDY, 2001). Um dos pontos mais importantes da IM é que ela pode ser utilizada para praticar cognitivamente habilidades físicas em segurança e de maneira repetitiva, uma vez que não requer saída motora. Pelos motivos abordados, a IM é a técnica preferencial em terapias de reabilitação utilizando ICCs, pois ela estimula a neuroplasticidade cerebral em paciente pós-AVC (BORTOLE et al., 2015).

A IM motora tem um papel importante para que a ICC tenha uma boa performance e, para tal, é necessário a utilização de uma metodologia para extração de características, como a geometria de Riemman (GR). A GR tem como atributos principais ser prática e simples, tanto algoritmicamente quanto computacionalmente, permitindo a decodificação de sinais em tempo real (CONGEDO; BARACHANT; BHATIA, 2017). Segundo Yger, Berar e Lotte (2016), a utilização desse algoritmo é importante pois é otimizada a classificação dos sinais EEG, e também é reduzido o tempo de calibração do sistema. Podem-se citar algumas pesquisas que obtiveram sucesso com esse método, como em Laiseca (2018) e Gaur e outros (2018).

Um estudo realizado por Delisle-Rodriguez e outros (2019) relata a relevância dos ritmos cerebrais de 8 a 12 Hz nos eletrodos Cz, C1, C2, C3 e C4 para o reconhecimento de tarefas mentais dos membros inferiores. Além disso, corroborando com a pesquisa apresentada, Laiseca e outros (2020), observou uma ativação cortical na região do pé, e uma diminuição da potência relativa com o eletrodo Cz na banda de 13 a 30 Hz. A utilização desse eletrodo, então, tem um papel importante para o reconhecimento da intenção motora, o qual é explorado neste trabalho para auxiliar o reconhecimento da IM.

Apesar dos avanços na área de robótica aplicada à reabilitação motora, os altos custos dos dispositivos robóticos ainda não possibilitam generalizar estes sistemas para clínicas de reabilitação para uso em pacientes pós-AVC. Assim, o desenvolvimento de sistemas robóticos de reabilitação de baixo custo, em conjunto com ICCs, é uma necessidade, já que estes sistemas poderiam ser disseminados em clínicas de reabilitação, tornando possível uma intervenção de baixo custo em pacientes pós-AVC com danos motores severos.

2 OBJETIVOS

2.1 Objetivo Geral

O objetivo deste trabalho é propor uma ICC que permita pacientes pós-AVC comandar um pedal motorizado através da técnica de IM, fazendo uso efetivo das regiões cerebrais de interesse relacionadas ao movimento dos seus membros inferiores.

2.2 Objetivos Específicos

De forma a alcançar o objetivo geral deste trabalho, os seguintes objetivos específicos foram determinados:

- Compreender o funcionamento de uma interface cérebro-computador;
- Conhecer qual a região cerebral está mais relacionada ao movimento de pedalar;
- Estabelecer novos algoritmos para melhorar a classificação de sinal pela ICC;
- Avaliar a nova ICC por meio de indicadores de desempenho, comparando-a com as ICCs existentes no NTA/UFES.

3 EMBASAMENTO TEÓRICO

3.1 Eletroencefalograma

O eletroencefalograma é um método de monitoramento eletrofisiológico para registro da atividade elétrica do cérebro. É um método não-invasivo, onde os eletrodos são colocados sobre o couro cabeludo. Como o sinal obtido pelo EEG possui baixa amplitude, da ordem de microvolts, é necessário o uso de amplificadores diferenciais com alta razão de rejeição de modo comum (RRMC), de forma a amplificar adequadamente o sinal e filtrar os ruídos e artefatos que contaminam o sinal de EEG. Os métodos utilizados para redução de interferência desse sinal são abordados nas próximas seções.

Com relação ao sinal EEG (VALIPOUR; SHALIGRAM; KULKARNI, 2014), suas principais faixas (ou ritmos) de frequências são:

- δ : frequência de 4 Hz ou inferior. Tende a ser o ritmo mais alto em amplitude e é normalmente observado em bebês e adultos quando dormem;
- θ : está no intervalo de frequência entre 4 a 8 Hz, sendo verificado na sonolência de criança e adultos;
- α : está no intervalo de 8 a 13 Hz. É normalmente verificado na região occipital quando as pessoas estão relaxadas e com os olhos fechados;
- μ : está no intervalo de 8 a 12 Hz e pode ser medido em áreas sensório-motoras na ausência de movimentos. Seu valor de amplitude cai quando o indivíduo se move ou imagina fazer um movimento;
- β : está no intervalo entre 13 e 30 Hz, sendo verificado sobre o lobos parietal e frontal em pessoas no estado de concentração ou alerta. Essa faixa de frequência é importante para o reconhecimento da intenção motora;
- γ : está no intervalo de 30 Hz a 100 Hz. É percebido durante a memória curta de reconhecimento de objetos, sons ou sensações táteis.

3.1.1 Potencial Oscilatório

Uma característica importante para as ICCs é a capacidade de o usuário controlar um ritmo cerebral específico, normalmente observado como potencial oscilatório do EEG em frequências

específicas. Esse fenômeno é classificado como dessincronização relacionada a eventos (DRE) ou sincronização relacionada a eventos (SRE). O DRE e o SRE são descritos pelas seguintes características: topografia razoavelmente localizada, comportamento de fase específico, e especificidade de frequência. Na primeira modalidade, quando um indivíduo imagina ou faz um movimento, a energia das faixas de baixa frequência como μ ou β diminuem. Quando há um aumento na energia, ocorre o SRE (RAO, 2011).

3.1.2 Potencial Cortical Relacionado ao Movimento

O potencial cortical relacionado ao movimento (PCRM) é um desvio de baixa frequência no sinal de EEG, entre 0,1 a 4 Hz (JIANG et al., 2015). Esse potencial tem sido empregado como uma modalidade de EEG para controle em tempo real de ICCs, particularmente em sistemas de neuromodulação (MRACHACZ-KERSTING et al., 2016). Uma particularidade do PCRM é a sua dificuldade em ser detectado, pois sua amplitude está, tipicamente, entre 5 a 30 μ V, sendo facilmente mascarado por outras atividades cerebrais (WRIGHT; HOLMES; SMITH, 2011). Estudos relatam que o uso do PCRM em ICCs induz o efeito de plasticidade, treinamento motor e aumento da amplitude de sinal (JOCHUMSEN et al., 2017).

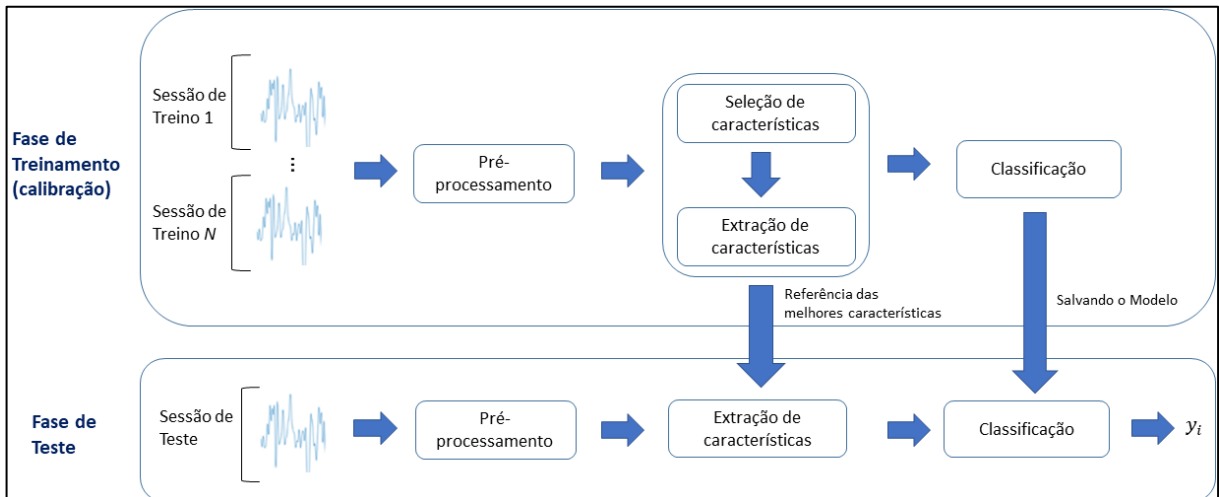
3.2 Imaginação Motora

A imaginação motora pode ser definida como um estado dinâmico durante o qual um sujeito simula mentalmente uma determinada ação e se sente realizando-a (DECETY, 1996), sendo que dois tipos de IM podem ser distinguidos: imaginação motora cinestésica (IMC) e imaginação motora visual (IMV). A primeira é descrita conforme Decety (1996), e a segunda depende principalmente da visualização da execução do movimento (RIMBERT et al., 2019). Essa técnica é amplamente utilizada para aprimorar o aprendizado motor e melhorar a reabilitação neurológica em pacientes pós-AVC, sendo que essa intervenção não é fisicamente exaustiva nem prejudicial (ZIMMERMANN-SCHLATTER et al., 2008). É importante ressaltar também que a terminologia “Intenção Motora” é um estado mental que causa a execução física de uma ação voluntária. A diferença entre as duas modalidades é que a IM não realiza o movimento físico.

3.3 Interface Cérebro-Computador

Uma ICC é um sistema de comunicação que detecta a atividade do sistema nervoso central (SNC) e a converte em uma saída artificial que substitui, restaura, aprimora, complementa ou melhora a saída natural do SNC e, assim, altera as interações contínuas entre o SNC e seus ambientes externos ou internos (WOLPAW; WOLPAW, 2012). Em uma interface cérebro-computador, os sinais cerebrais são capturados, amplificados e decodificados utilizando algoritmos de classificação em tempo real e, dessa forma, sua saída é utilizada para diversas aplicações, tais como: ativação de robôs assistivos, exoesqueletos ou pedal motorizado. A Figura 5 exemplifica os componentes de uma ICC através de um diagrama de blocos.

Figura 5 – Interface cérebro-computador



Fonte: Silva (2020).

Nota: Adaptado pelo autor.

3.3.1 Pré-processamento

O sinal de EEG, como abordado na seção 3.1, possui baixa amplitude, na ordem de microvolts, sendo necessário o uso de amplificadores diferenciais com alta razão de rejeição de modo comum para amplificar o sinal e filtrar os ruídos e artefatos, tais como: ruído de linha na frequência de 50 ou 60 Hz (LESKE; DALAL, 2019), movimentos e piscadas de olhos, atividades mioelétricas e cardíacas. Esses artefatos estão presentes na maioria dos registros de EEG e, devido à sua intensidade elétrica, corrompem todas as medições dos eletrodos, sendo alterados o padrão do sinal e sua distribuição de amplitude (KILICARSLAN; GROSSMAN;

CONTRERAS-VIDAL, 2016). Vale ressaltar que o desempenho da ICC depende diretamente da qualidade do sinal de EEG.

Para contornar esse problema, na etapa de pré-processamento são utilizados métodos para a redução de artefatos no sinal, tais como: análise de componentes independentes (ACI), análise rápida de componentes independentes (ARCI) e análise das componentes principais (ACP) (DELISLE-RODRIGUEZ et al., 2017). Por outro lado, para reduzir a interferência entre os eletrodos de EEG, exemplificam-se alguns filtros espaciais normalmente utilizados, tais como: referência de média comum (RMC), referência de média local (RML) e referência pela média ponderada (RMP).

Uma etapa importante do pré-processamento consiste em utilizar um filtro passa-banda (FPB), o qual seleciona uma faixa de frequências específicas para não atenuar o sinal. Seja \mathbf{x} , BW e F_s o sinal EEG dividido em n amostras de E canais, o vetor do filtro e frequência de amostragem, respectivamente. O sinal é filtrado conforme as equações (1) a (8) (SILVA, 2020).

$$\mathbf{L} = \text{size}(\mathbf{x}, 1) \quad (1)$$

$$\mathbf{f} = \frac{F_s \times \left(0 : \frac{\mathbf{L}}{2}\right)}{\mathbf{L}} \quad (2)$$

$$\mathbf{x}_{fft} = \text{fft}(\mathbf{x}, \mathbf{L}) \quad (3)$$

$$\mathbf{N}_{fft} = \text{size}(\mathbf{x}_{fft}, 1) \quad (4)$$

$$\mathbf{I} = \text{find}(\mathbf{f}(2:\text{end}) < BW(1) \mid \mathbf{f}(2:\text{end}) > BW(2)) \quad (5)$$

$$\mathbf{x}_{fft}(1 + \mathbf{I}, :) = 0 \quad (6)$$

$$\mathbf{x}_{fft}(\mathbf{N}_{fft} + 1 - \mathbf{I}, :) = 0 \quad (7)$$

$$\mathbf{X}_f = \text{ifft}(\mathbf{x}_{fft}, \mathbf{N}_{fft}), \quad (8)$$

Onde:

\mathbf{L} – Tamanho do vetor de entrada;

\mathbf{f} – Vetor de frequências;

fft – Operador da transformada rápida de Fourier (TRF);

\mathbf{x}_{fft} – Vetor com a TRF aplicada para o sinal de entrada;

\mathbf{N}_{fft} – Tamanho do vetor \mathbf{x}_{fft} ;

I – Vetor com as componentes a serem removidas;

$ifft$ – Operador da inversa da transformada rápida de Fourier (ITRF);

X_f – Vetor final com o filtro TRF aplicado.

3.3.2 Extração de Características

Esta é uma etapa importante para a ICC, pois é nesse processo que são identificadas características ou atributos importantes dos sinais e, caso tenha-se várias dimensões, esse processamento pode ser utilizado para a produção mais compacta e concisa dos dados, habilitando a interpretação por um ser humano ou um computador (WOLPAW; WOLPAW, 2012).

É comum a aplicação de FPB e filtros espaciais antes da extração de características. É importante ressaltar esta última modalidade, a qual consiste em combinar os sinais originais e melhorar a relação sinal-ruído, melhorando assim a performance da ICC. Algumas modalidades podem ser citadas para esse tipo de processamento de sinal, tais como: potência média da banda a partir da densidade espectral, padrão espacial comum (PEC), geometria de Riemann e banco de filtro espacial de padrão comum (BFEP) (SILVA, 2020).

3.3.2.1 Geometria de Riemann

A geometria de Riemann é utilizada para classificar dados multidimensionais, por ser considerada precisa e robusta em ICCs baseadas em EEG. Esse processamento de sinal se faz necessário para sinais de várias dimensões, pois é preservada a acurácia e também por agilizar os cálculos (CONGEDO et al., 2017). Para alcançar tais feitos, a GR é um método baseado em operações não supervisionadas, tais como: filtros temporais e estimação por covariância (BARACHANT et al., 2013). Vale ressaltar, também, que esse método reduz a interferência comum e melhora a razão de variância entre as sessões de coleta de EEG para diferentes tarefas motoras (DELISLE-RODRIGUEZ et al., 2019).

Seja $\mathbf{x}_i \in \mathbb{R}^{E \times t}$ o trecho de sinal i (também denominado “época”) com dados EEG sem tratamento, onde E representa o número de canais EEG e t o total de amostras. Então, o conjunto de treinamento $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i, \dots, \mathbf{x}_N\}$ formado por N épocas que correspondem às

classes c_1 e c_2 é utilizado na fase de calibração para computar a matriz simétrica e positiva, chamada de \mathbf{C}_{ref} . Logo, \mathbf{C}_{ref} é a média de todas as matrizes de covariância computadas, como demonstrada nas equações (9) e (10).

$$\mathbf{C}_p = \frac{1}{t-1} \mathbf{x}_i \mathbf{x}_i^T \quad (9)$$

$$\mathbf{C}_{ref} = \mu(\mathbf{C}_1, \dots, \mathbf{C}_p) = \frac{1}{P} \sum_{p=1}^P \mathbf{C}_p \quad (10)$$

Para a equação (9), $\mathbf{x}_i \in \mathbb{R}^{E \times t}$ e é correspondente à sessão da classe $y_p \in \{c_1, c_2\}$. Além disso, $\mathbf{C}_p \in \mathbb{R}^{E \times E}$ é a matriz de covariância amostral e T é operador de transposta para matriz. Todas as matrizes de covariância $\{\mathbf{C}_p\}_{p=1}^P$ podem ser projetadas no espaço tangente, sendo obtidas as inversas segundo as equações (11) e (12), respectivamente.

$$\mathbf{S}_p = \text{logm} \left(\mathbf{C}_{ref}^{-\frac{1}{2}} \mathbf{C}_p \mathbf{C}_{ref}^{-\frac{1}{2}} \right) \quad (11)$$

$$\mathbf{C}_p = \text{expm} \left(\mathbf{C}_{ref}^{\frac{1}{2}} \mathbf{S}_p \mathbf{C}_{ref}^{\frac{1}{2}} \right) \quad (12)$$

Onde:

\mathbf{S}_p – Vetor tangente;

\mathbf{C}_p – Vetor de covariâncias;

logm – Operador de logaritmo;

expm – Operador de exponencial.

Com isso, a distância riemanniana entre $\{\mathbf{C}_p\}_{p=1}^P$ e \mathbf{C}_{ref} e a média geométrica (MG) podem ser computadas pelas equações (13) e (14), respectivamente. É importante ressaltar que a MG é utilizada para projetar as matrizes de covariância no espaço tangente, e depois retorná-las para o espaço vetorial (DESLISLE-RODRIGUEZ, 2019; SILVA, 2020).

$$\delta_R(\mathbf{C}_p, \mathbf{C}_{ref}) = \|\log(\mathbf{C}_{ref}^{-1}, \mathbf{C}_p)\|_F = \left[\sum_{i=1}^E \log^2 \lambda_i \right]^{\frac{1}{2}} \quad (13)$$

$$\xi(\mathbf{C}_1, \dots, \mathbf{C}_p) = \underset{\mathbf{C}_{ref}}{\operatorname{argmin}} (\mathbf{C}_{ref}^{-1}, \mathbf{C}_p) \sum_{p=1}^P \delta_R^2(\mathbf{C}_p, \mathbf{C}_{ref}) \quad (14)$$

Onde:

δ_R – Distância de Riemann entre \mathbf{C}_p e \mathbf{C}_{ref} ;

ξ – Média geométrica de \mathbf{C}_1 até \mathbf{C}_p ;

λ – Autovalores reais.

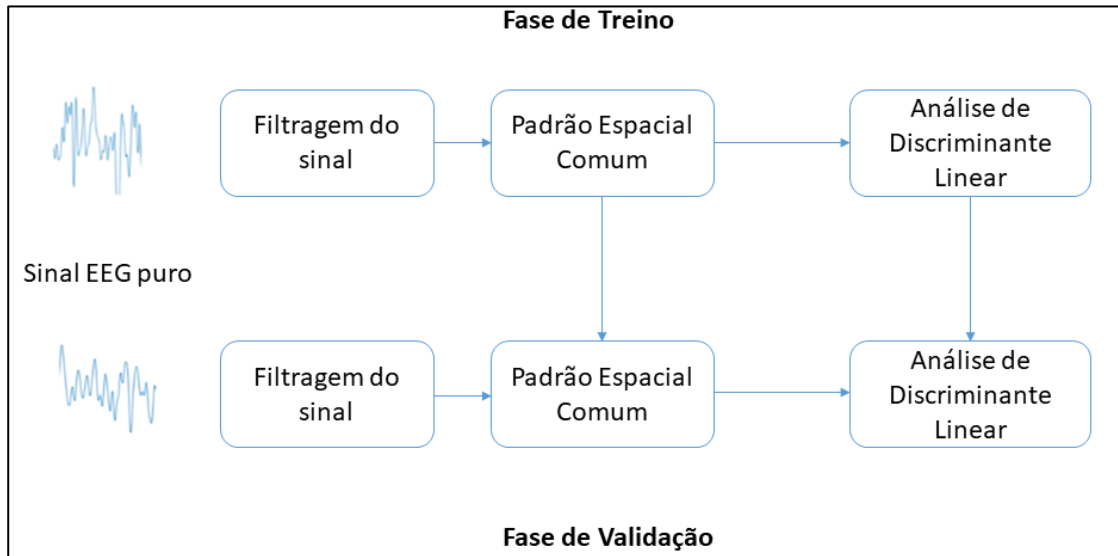
A matriz de projeção \mathbf{C}_{ref} é utilizada nas fases de calibração e validação. Para obter o vetor de características para a classificação, utiliza-se $\{\mathbf{C}_p\}_{p=1}^P$, e logo em seguida é aplicada uma ponderação. Além disso, as dimensões do vetor \mathbf{S}_p devem ser alteradas respeitando a equação (15) (DELISLE-RODRIGUEZ et al., 2019).

$$\operatorname{vect}(\mathbf{S}_p) = [S_{p1,1}; \sqrt{2}S_{p1,2}; S_{p2,2}; \sqrt{2}S_{p1,3}; \dots; S_{pE,E}] \quad (15)$$

3.3.2.2 Padrão Espacial Comum

O padrão espacial comum é eficaz na construção de filtros espaciais que discriminam duas classes em ICCs baseadas em EEG (ANG et al., 2008). Além disso, o PEC tem altas taxas de sucesso na extração de recursos dos fenômenos DRE e SRE para reconhecimento da IM. O objetivo de empregar este algoritmo é maximizar a diferença de variância utilizando uma matriz de covariância amostral de sinais EEG entre duas classes em estudo. A Figura 6 ilustra o diagrama de blocos deste método.

Figura 6 – Diagrama de blocos para o algoritmo PEC



Fonte: Silva (2020).

Nota: Adaptado pelo Autor.

Seja $\mathbf{x}_i \in \mathbb{R}^{E \times t}$ os dados filtrados de EEG para o conjunto de calibração de classes A e B , onde i é o número da sessão, E o número de canais, e n a quantidade de amostras no tempo. Calcule-se a matriz de covariância normalizada para A e o seu valor médio correspondente, segundo as equações (16) e (17), respectivamente.

$$\mathbf{R}_i^A = \frac{\mathbf{x}_i^A (\mathbf{x}_i^A)^T}{\text{tr}[\mathbf{x}_i^A (\mathbf{x}_i^A)^T]} \quad (16)$$

$$\mathbf{R}^A = \sum_{i=1} \langle \mathbf{R}_i^A \rangle \quad (17)$$

Onde:

\mathbf{R}^A – Matriz de covariância normalizada para classe A ;

tr – Função matricial para somar os elementos da diagonal principal.

A matriz de covariância normalizada e o valor médio correspondente também são calculados para B . Vale salientar que também é possível computar a matriz de covariância composta \mathbf{C} , segundo a equação (18), e fatorá-la em autovetores conforme a equação (19).

$$\mathbf{R}^C = \mathbf{R}^A + \mathbf{R}^B \quad (18)$$

$$\mathbf{R}^C = \mathbf{B}_C \lambda (\mathbf{B}_C)^T \quad (19)$$

Onde:

\mathbf{B}^C – Matriz de autovetores normalizados de dimensão $E \times E$;

λ – Matriz diagonal de autovalores.

A fim de equalizar as variâncias no espaço abrangido pelos autovetores de \mathbf{B}_C , são utilizadas as equações (20) a (22) para transformar \mathbf{R}^A e \mathbf{R}^B .

$$\mathbf{W} = \lambda^{-\frac{1}{2}} (\mathbf{B}^C)^T \quad (20)$$

$$\mathbf{S}^A = \mathbf{W} \mathbf{R}^A (\mathbf{W})^T \quad (21)$$

$$\mathbf{S}^B = \mathbf{W} \mathbf{R}^B (\mathbf{W})^T \quad (22)$$

Onde:

\mathbf{W} – Vetor de transformação linear;

\mathbf{S}^A – Vetor da classe A com transformação linear aplicada;

\mathbf{S}^B – Vetor da classe B com transformação linear aplicada.

Pela equação (23), \mathbf{S}^A e \mathbf{S}^B compartilham os mesmos autovetores. Logo, é possível realizar a sua decomposição, segundo as equações (24) e (25) (MULLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999).

$$\mathbf{S}^A + \mathbf{S}^B = \mathbf{W} \mathbf{R}^C (\mathbf{W})^T = \mathbf{1}_{E \times E} \quad (23)$$

$$\mathbf{S}^A = \mathbf{U} \boldsymbol{\Psi}^A (\mathbf{U})^T \quad (24)$$

$$\mathbf{S}^B = \mathbf{U} \boldsymbol{\Psi}^B (\mathbf{U})^T \quad (25)$$

$$\boldsymbol{\Psi}^A + \boldsymbol{\Psi}^B = \mathbf{I}, \quad (26)$$

Onde:

$\boldsymbol{\Psi}$ – Vetor de autovalores;

\mathbf{I} – Matriz identidade;

\mathbf{U} – Vetor ortonormal.

Como consequência, a projeção das épocas de EEG no vetor \mathbf{U} podem fornecer vetores de características, os quais são ideais para discriminar as classes A e B . Com isso, a matriz de projeção é computada, e cada sinal EEG puro é decomposto pelas equações (27) e (28).

$$\mathbf{p}^\top = \mathbf{U}^\top \mathbf{W} \quad (27)$$

$$\mathbf{z}_i = \mathbf{p}^\top \mathbf{x}_i \quad (28)$$

Onde:

\mathbf{x}_i – Sinal de EEG puro;

\mathbf{p}^\top – Matriz de projeção de dimensão $E \times E$;

\mathbf{z}_i – Matriz de expansão de coeficientes com a mesma dimensão da matriz \mathbf{x}_i .

A metodologia do padrão espacial comum determina os modos de tal forma que a variância da primeira linha da matriz \mathbf{z}_i é máxima para os sinais da classe A , e mínimo para os sinais da classe B . Ou seja, as variâncias das primeiras filas e últimas colunas da matriz \mathbf{z}_i contêm as informações mais relevantes para a discriminação entre as classes (MULLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999).

Todas as k sessões de coleta de sinal EEG formam o conjunto completo de treinamento e, dessa forma, é possível aplicar o algoritmo PEC. Para tal, é computada a matriz de projeção \mathbf{p}^\top e, em seguida, é utilizado o classificador de análise de discriminante linear (ADL), onde as primeiras linhas e últimas colunas são mantidas para fornecer os melhores coeficientes da matriz de expansão \mathbf{z}_i . Feito isso, o passo final é normalizar os dados conforme a equação (29) (MULLER-GERKING; PFURTSCHELLER; FLYVBJERG, 1999; DELISLE-RODRIGUEZ, 2017).

$$f_p^i = \log \left(\frac{var_p^i}{\sum_{p=1}^{2m} var_p^i} \right), \quad (29)$$

Onde:

var_p^i – Variância da linha p da matriz \mathbf{z}_i ;


f_p^i – Vetor de características normalizado.

3.3.3 Classificação

A classificação de características nas ICCs baseia-se no aprendizado de máquinas, em que o sistema aprende a mapear atividades neurais do paciente. Os algoritmos podem ser divididos em duas classes: aprendizado supervisionado e não supervisionado (LOTTE et al., 2007). Na primeira modalidade, os dados de treino consistem em um conjunto de entrada de dados com suas respectivas saídas. Dessa forma, o computador aprende a função que mapeia os dados de entrada e suas saídas. Caso as saídas sejam discretas, o problema é chamado de classificação, e para saídas contínuas, regressão. A segunda modalidade tem ênfase na descoberta de uma estrutura estatística em dados sem rótulo. Para tal, os dados de treino são entradas, e o objetivo é aprender o modelo estatístico que pode ser compacto ou útil para a análise subsequente.

A análise de discriminante linear (ADL) é um algoritmo de aprendizado supervisionado, sendo aplicado com sucesso em ICCs para distinguir classes. Este é um método de baixo uso computacional que utiliza hiperplanos para separar os dados em diferentes classes. A ADL assume a distribuição normal dos dados, com igual matriz de covariância para ambas as classes. O hiperplano separador (Figura 7) é obtido buscando a projeção que maximiza a distância entre duas classes, minimizando a variância entre interclasses (LOTTE et al, 2007). É importante ressaltar que a performance deste classificador depende necessariamente do tamanho do conjunto de treino. Caso ele esteja mal condicionado, ou seja, o seu número de variáveis é maior do que o número de parâmetros a serem estimados, além de conter desvios da normalidade, recomenda-se a utilização da análise de discriminante regularizado (ADR) (WU et al., 1996).

Figura 7 – Hiperplano separador para ADL

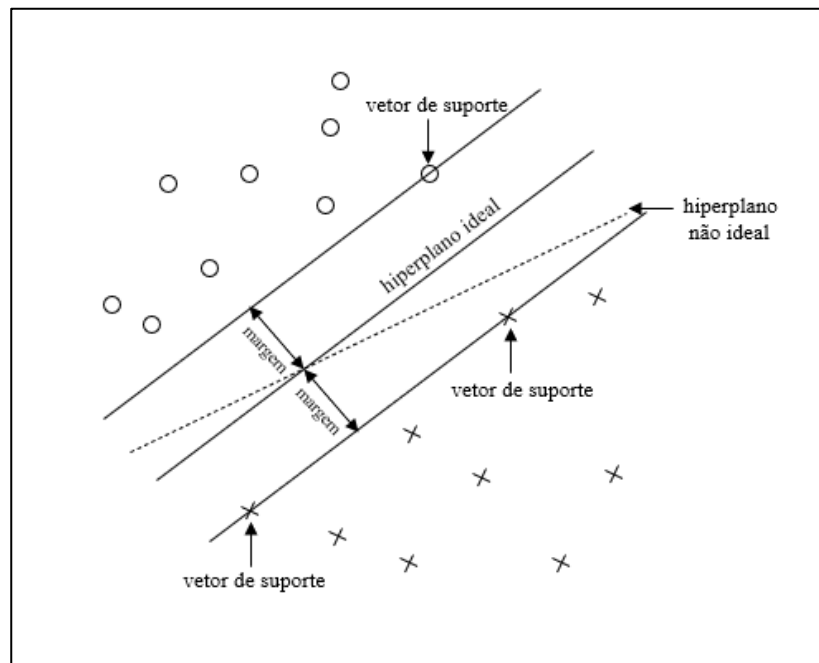


Fonte: Lotte e outros (2007).

O ADR é um classificador que introduz um parâmetro de regularização C que pode permitir ou penalizar erros de classificação no conjunto de treino. Logo, sua resultante pode acomodar falsos positivos e obter melhores capacidades de generalização (LOTTE et al, 2007).

Outro classificador supervisionado é a máquina de vetores de suporte (MVS) que se baseia em um hiperplano para discriminar duas classes, como pode ser observado na Figura 8. O MVS é conhecido por ter boas propriedades de generalização, por ser insensível ao excesso de treinamento e à dimensionalidade dos dados, e ter sido aplicado com sucesso em ICCs (LOTTE et al., 2007).

Figura 8 – Hiperplano separador para MVS



Fonte: Lotte e outros (2007).

Nota: Adaptado pelo Autor.

3.3.4 Método de Análise de Dados

Após os dados de EEG serem classificados, é possível avaliar o desempenho do classificador, que é normalmente resumido por uma matriz de confusão (MC). Cada elemento desta matriz determina o número de amostras classificadas corretamente ou incorretamente. Logo, através da MC pode-se obter um valor para ser utilizado para comparar diferentes técnicas de classificação ou modelos diferentes para o classificador (FATOURECHI et al., 2008). Alguns

tipos de métricas são a acurácia (ACC) e o coeficiente de Cohen Kappa (CCK). É importante salientar que o classificador deve ser projetado para classificar duas classes balanceadas, logo nota-se a equação (30).

$$N_{total\ amostras} = N_+ + N_- \quad (30)$$

Onde:

$N_{total\ amostras}$ – Total de amostras analisadas pelo classificador;

N_+ – Amostras de uma classe positiva;

N_- – Amostras de uma classe negativa.

A matriz de confusão, então, é preenchida pela quantidade de verdadeiro positivo (VP), falso positivo (FP), verdadeiro negativo (VN) e falso negativo (FN) gerados pelo classificador. A MC pode ser obtida pela equação (31).

$$M_{confusão} = \begin{bmatrix} VP & FN \\ FP & VN \end{bmatrix} \quad (31)$$

Onde:

$M_{confusão}$ – Matriz de confusão.

3.3.4.1 Acurácia

Uma medida de desempenho normalmente utilizada em ICCs é a acurácia do classificador, que é um método válido para classes balanceadas. Esta métrica mede a instância de dados que foi corretamente classificada no conjunto de teste, levando em consideração todos os dados coletados (DELISLE-RODRIGUEZ, 2017). O desempenho é obtido pela equação (32).

$$ACC = \frac{N_{TP} + N_{TN}}{N_{total}} \quad (32)$$

Onde:

ACC – Acurácia do sistema.

3.3.4.2 Coeficiente de Cohen Kappa

A estatística Kappa é utilizada para testar a confiabilidade do classificador, devido ao fato que este índice descreve até que pontos os dados coletados no estudo são representações corretas das variáveis medidas. O CCK varia de -1 até 1, sendo que quanto mais próximo de 1, mais confiável é a informação. Logo, valores próximos de -1 indicam uma menor confiabilidade e, por fim, o valor zero indica um sinal mais aleatório (MCHUGH, 2012). O índice é calculado pela equação (33).

$$\kappa = \frac{P_o - P_e}{1 - P_e}, \quad (33)$$

Onde:

κ – Índice Kappa;

P_o – Probabilidade empírica de veracidade dos dados;

P_e – Probabilidade de os dados serem classificados aleatoriamente.

4 METODOLOGIA E MÉTODOS

4.1 Aspectos Metodológicos

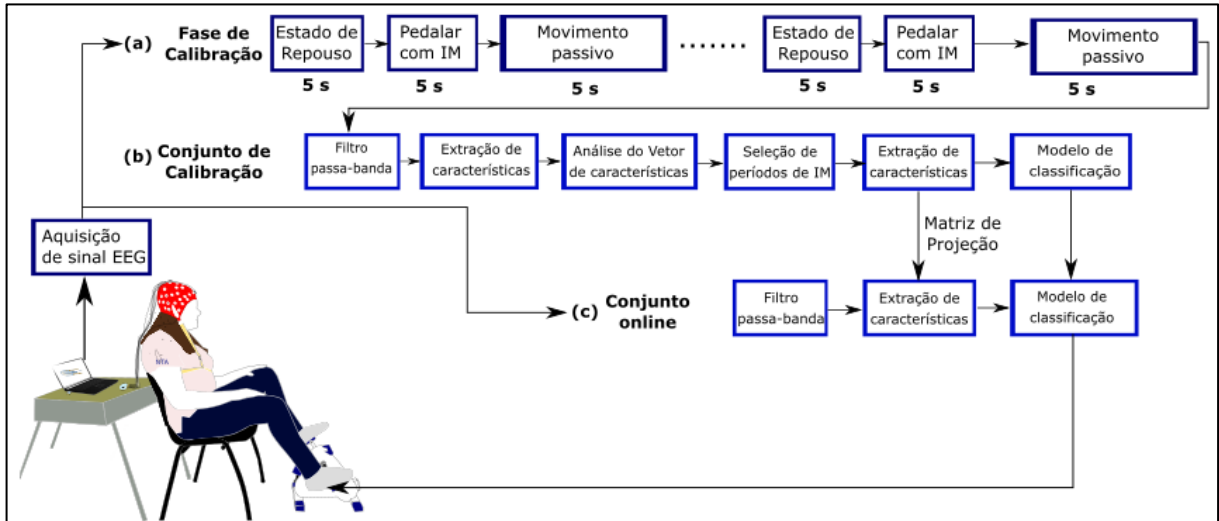
O presente trabalho, do ponto de vista da sua natureza, é uma pesquisa aplicada porque busca melhorar a performance de uma ICC, explorando novas implementações na etapa de extração de características, de forma a melhorar o reconhecimento do padrão de pedalar. Logo, serão feitas pesquisas sobre o tema abordado levando em consideração trabalhos já desenvolvidos nesta área, tendo em vista identificar qual será o desempenho da interface cérebro-computador comparando com outras ICCs já desenvolvidas. Quanto aos objetivos, trata-se de uma pesquisa explicativa, uma vez que os dados são manipulados, classificados e interpretados. Em relação aos procedimentos técnicos, é uma pesquisa experimental com objeto de estudo definido. O problema proposto foi abordado de forma quantitativa.

4.2 Etapas da Interface Cérebro-Computador

Uma ICC baseada em EEG é normalmente dividida em duas etapas, sendo a primeira chamada de fase de calibração, na qual o sinal EEG é processado de forma a gerar um modelo para classificação. Com isso, é habilitada a segunda etapa, chamada de validação.

Várias melhorias em ICCs foram obtidas no Núcleo de Tecnologia Assistiva da UFES (LAISECA, 2018; SILVA, 2020), as quais serão utilizadas como base para este projeto de Graduação. A Figura 9 apresenta a ICC utilizada, cuja fase de calibração foi projetada para que os participantes realizem tarefas de IM pedalando por um período de 5 s e, logo em seguida, recebam sucessivos movimentos passivos por mais 5 s. Na prática, esta abordagem deve promover a reabilitação motora cortical e física, desde a fase de calibração, visando o objetivo principal de pacientes e fisioterapeutas, que é executar o movimento por várias vezes durante a sessão de reabilitação (SILVA, 2020).

Figura 9 – ICC estudada



Fonte: Silva (2020).

Nota: Adaptado pelo Autor.

4.3 Ponderação para o Vetor de Características

Estudos sobre ICCs baseadas em EEG, como em Cardoso (2021), relatam uma diminuição de potência ($p > 0.05$), para o sinal de EEG obtido do eletrodo Cz durante as condições de IM e movimento passivo em relação ao estado de repouso para a banda μ e β . De forma a obter um novo conjunto de características para treinar o classificador, utiliza-se o algoritmo descrito nesta seção.

Os valores de ponderação são obtidos computando a transformada de Fourier (TF), nas frequências de 15 a 30 Hz, para as épocas i de 1 segundo do canal Cz, e depois normalizando-os sobre a banda de 8 a 30Hz. Seja $\mathbf{X}^{IM} = [\mathbf{x}_1^{IM}, \mathbf{x}_2^{IM}, \dots, \mathbf{x}_N^{IM}]$, o conjunto de treino com sinais EEG relacionados à IM, com N segmentos, e $\mathbf{X}^R = [\mathbf{x}_1^R, \mathbf{x}_2^R, \dots, \mathbf{x}_N^R]$, o conjunto de treino com sinais EEG relacionados ao estado de repouso. Calcula-se então a potência para o conjunto de IM e repouso pelas equações (34) e (35), respectivamente.

$$b_i^{IM} = \frac{\sum_{f=15}^{30} S_i^{IM}}{\sum_{f=8}^{30} S_i^{IM}} \quad (34)$$

$$b_i^R = \frac{\sum_{f=15}^{30} S_i^R}{\sum_{f=8}^{30} S_i^R} \quad (35)$$

Onde:

b_i^{IM} – Potência do sinal de IM normalizado;

b_i^R – Potência do sinal do repouso normalizado;

S_i^{IM} – Transformada de Fourier para o sinal de IM;

S_i^R – Transformada de Fourier para o sinal de repouso.

A média de potência do repouso é obtida na equação (36).

$$R = \frac{\sum_{i=1}^N b_i^R}{N} \quad (36)$$

Onde:

R – Valor de potência médio do repouso;

N – Quantidade de amostras do sinal.

Com isso, é possível calcular a potência relativa para o conjunto de IM e conjunto de repouso pelas equações (37) e (38), respectivamente.

$$p_i^{IM} = b_i^{IM} - R \quad (37)$$

$$p_i^R = b_i^R - R \quad (38)$$

Onde:

p_i^{IM} – Potência relativa do conjunto de Imagética Motora;

p_i^R – Potência relativa do conjunto de repouso.

O peso para cada época do sinal é calculado conforme as equações (39) e (40).

$$w_i^{IM} = \frac{(p_i^{IM})^{-1}}{\sum_{k=1}^N (p_k^{IM})^{-1}} \quad (39)$$

$$w_i^R = \frac{(p_i^R)^{-1}}{\sum_{k=1}^N (p_k^R)^{-1}} \quad (40)$$

Onde:

w_i^{IM} – Peso do sinal para a época de IM;

w_i^R – Peso do sinal para a época de repouso.

Com isso, o vetor de ponderação final é obtido pela equação (41).

$$\mathbf{W} = [w_i^R \quad w_i^{IM}]^T \quad (41)$$

Onde:

\mathbf{W} – Vetor peso final.

4.4 Probabilidade Baseada no Percentil

A fim de selecionar os vetores de características da IM mais relacionados com o movimento real e, também, para obter um modelo mais confiável para o reconhecimento da IM e estado de repouso, utiliza-se uma metodologia baseada no percentil, de forma a rejeitar padrões de IM não confiáveis, ou seja, mais relacionados ao estado de repouso (SILVA, 2020). Tal medida é amplamente utilizada na estatística, em que o percentil (p_{th}) é o valor que divide os dados quando são classificados em ordem crescente. O p_{th} de 25% é chamado de primeiro quartil, ou seja deixando 25% dos dados abaixo do limiar e 75% acima. Outros dois limiares importantes são o de 50%, também chamado de mediana, e o de 75%. A equação de p_{th} é apresentada em (42).

$$p_j \leq p_{th} \quad (42)$$

Onde:

p_{th} – Probabilidade de ocorrência de IM para o percentil th .


p_j – Sinal a ser classificado para a época j .

Dessa forma, é obtido um novo conjunto de calibração formado por épocas do sinal EEG mais relacionadas à IM do movimento de pedalar e estado de repouso. Vale ressaltar que, segundo o estudo de Silva (2020), o percentil que apresentou melhor resultado foi o de 75% e, desta forma, esse limiar foi escolhido neste trabalho.

4.5 Coleta de Sinal

Para validar a ICC deste trabalho, foi utilizado um banco de dados EEG coletados previamente por Romero e outros (2020), o qual contém sinais de EEG provenientes de movimentos de pedalar passivos, estado de repouso, e movimentos de pedalar em conjunto com IM. O sinal EEG foi coletado com frequência de amostragem de 250 Hz, utilizando a *OpenBCI Cyton Board* (OCB), a qual é uma placa de circuito integrado para captura de sinais baseada no microcontrolador *PIC32MX250F128B 32 bits*, com 128 *kilobytes* de memória *Flash* e 32 *kilobytes* de memória RAM. Além disso, o OCB possui 8 canais diferenciais de alto ganho e baixo ruído. É possível observar o sistema de coleta de sinal EEG na Figura 10.

Figura 10 – Sistema de aquisição de sinal EEG




Fonte: Openbci (2021).

O banco de dados foi formado coletando sinais de 10 sujeitos, sendo 8 sujeitos saudáveis (sendo que 1 deles era mulher e os outros 7 eram homens) sem lesões nos membros inferiores ou complicações para se locomover, e 2 sujeitos que sofreram AVC há 2 e 5 anos atrás. Dentro do grupo de sujeitos pós-AVC, as duas eram mulheres, sendo uma com 46 anos de idade e hemiparesia direita, e a outra com 48 anos de idade e hemiparesia esquerda. Além disso, todos os sujeitos possuem membros dominantes do lado direito (LAISECA et al., 2020).

Para coletar os sinais de EEG, os sujeitos utilizaram uma touca com 8 eletrodos Ag-AgCl, nos quais foi aplicado um gel condutor para melhorar a recepção do sinal. Os canais utilizados foram o FC1, FC2, C3, Cz, C4, CP1, CP2 e Pz, sendo utilizados A1 e A2 como referência

(LAISECA et al., 2020). O posicionamento dos eletrodos foi baseado no Sistema Internacional 10-20, o qual é ilustrado pela Figura 11.

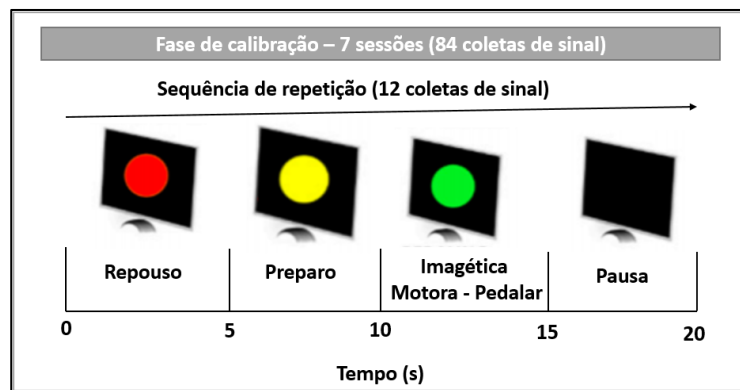
Figura 11 – Sistema internacional 10-20



Fonte: Silva (2020).

Para cada sujeito, o banco de dados foi dividido em um conjunto de calibração e um de validação. A primeira parte é formada por sete sessões, sendo que cada uma é composta por 12 aquisições de sinal, totalizando 84 capturas para cada classe (IM e repouso). O protocolo utilizado leva em consideração que o usuário imagina o movimento de pedalar e descansa, sendo cada ação realizada por 5 s. A Figura 12 ilustra a fase de calibração.

Figura 12 – Protocolo usado no conjunto de calibração



Fonte: Cardoso e outros (2021).
 Nota: Adaptado pelo Autor.

Apesar de coletadas sete sessões, apenas seis foram utilizadas para treinar o sistema, totalizando 72 coletas de sinal, já que a última sessão, também chamada de *online*, foi empregada como um conjunto de validação, a fim de calibrar e testar o sistema desenvolvido. É importante comentar que na sessão *online*, obtida com 24 coletas de dados para cada classe, o participante foi incentivado a acionar o pedal motorizado pela IM e, logo em seguida, ele era recompensado com o movimento passivo de 5 s como *feedback* (LAISECA et al., 2020).

4.6 Interface Cérebro-Computador Proposta

Com os sinais EEG do banco de dados e algoritmos definidos foi possível realizar a implementação da ICC por software. O primeiro processamento de sinal aplicado neste trabalho foi a filtragem dos sinais de EEG de todas as sessões baseando-se em filtros passa-banda de TRF e ITRF, para períodos de 1 s a cada 64 ms, nos intervalos de frequência de 0,1 a 30 Hz, de forma a preservar a informação neural do sinal de EEG puro (LAISECA et al., 2020). Para a fase de calibração, a primeira etapa consistiu em computar a potência relativa e extrair as características pela GR, conforme as seções 3.3.2.1 e 4.1, respectivamente, para épocas de 1 s do sinal dos instantes de IM, repouso e movimento passivo. Desta forma, com a multiplicação dos vetores de saída das seções 3.3.2.1 e 4.1, obtém-se um vetor de características ponderado. Com isso, foi possível aplicar o cálculo de probabilidade e verificar quais padrões estão mais relacionados com a IM, e obter um conjunto selecionado.

Segundo Silva (2020), uma ICC que combina a geometria de Riemann e o padrão espacial comum tem um bom desempenho para a classificação de sinal e, logo, essa configuração foi utilizada neste trabalho. A etapa dois, então, consiste em utilizar o PEC, resultando, portanto, no conjunto de características final para treinar o classificador.

A etapa *online* utiliza uma metodologia parecida com a fase de calibração, filtrando o sinal para a banda de interesse e aplicando a potência relativa, porém, só foi utilizado o PEC para fazer a extração de características e, logo em seguida, o sinal foi classificado.

Efetuada essas etapas, as métricas ACC e Kappa foram utilizadas para verificar o desempenho da ICC, de forma a ser comparada com outras disponíveis no NTA/UFES. Vale ressaltar que os classificadores utilizados foram baseados no ADL, ADR e MVS. É importante notar que os

dados provenientes da fase de calibração foram utilizados para treinar o sistema, enquanto os dados obtidos da fase *online* foram utilizados para validar a ICC.

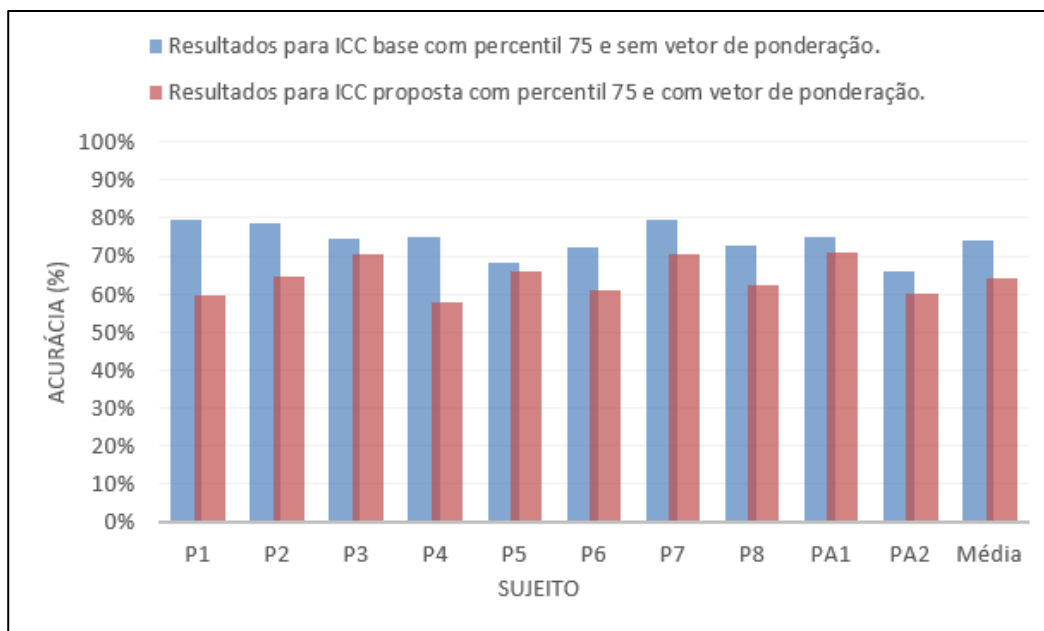
5 RESULTADOS

Neste capítulo são apresentados os resultados obtidos neste projeto de Graduação em duas seções, sendo a primeira o processo de calibração e a segunda a fase de validação. É importante ressaltar que a ICC proposta utiliza os algoritmos discutidos nas seções 4.1 e 4.2, enquanto o modelo base para comparação utiliza somente a última metodologia. Além disso, ambos os sistemas utilizam o percentil 75, a configuração que aplica GR e o PEC para extração de características na primeira e última etapa, respectivamente.

5.1 Análise da Fase de Calibração


As Figuras 13 e 14 mostram a performance obtida pelas ICCs, através das medidas de acurácia e Kappa, na fase de calibração para 8 sujeitos saudáveis (P1 até P8) e duas pessoas que sofreram AVC (PA1 e PA2) para o estado de repouso e reconhecimento da IM para o movimento de pedalar.

Figura 13 – Acurácia das ICCs analisadas



Fonte: Produção do próprio autor.

Figura 14 – Kappa das ICCs analisadas



Fonte: Produção do próprio autor.

Os valores obtidos na etapa de calibração podem ser observados na Tabela A1, no APÊNDICE A. Na etapa de calibração, a ICC proposta obteve valores menores de acurácia quando comparada ao modelo base. Essa diferença fica mais notável quando observado o sujeito P1, pois ele apresentou uma redução do valor de ACC de 19,93%. Por outro lado, os valores obtidos para P3, P5 e PA1 diferem pouco dos resultados obtidos por Silva (2020), implicando que esses sujeitos tiveram uma melhor ativação da intenção motora em torno da região Cz, quando comparada com os outros sujeitos do grupo.

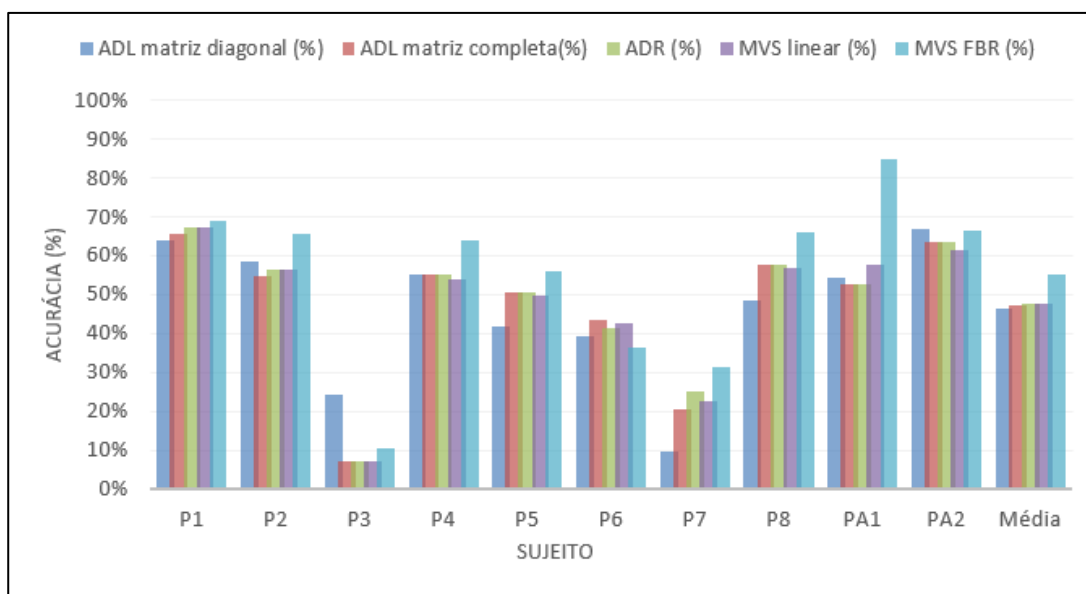
Esse decréscimo de performance da ICC também é observado pela métrica Kappa, a qual obteve uma redução expressiva de até 65,53%, sendo esse o caso para P1. Vale ressaltar que o resultado dos sujeitos P3, P5 e PA1 corroboram com o parágrafo anterior, obtendo um valor próximo ao modelo base e maior que a média do grupo de estudo. Os outros participantes apresentaram uma redução de κ em torno de 41,17%.

Para a fase de calibração, foi utilizado o ADL de matriz completa para a classificação de características. Em resumo, para os sujeitos analisados, a ICC base apresentou melhor performance, com acurácia média de 74,18% e Kappa de 0,473, quando comparada com a ICC proposta, a qual obteve um ACC de 64,33% e κ de 0,286.

5.2 Análise da Fase de Validação


A ICC foi treinada com o conjunto de calibração e, portanto, está apta a reconhecer os padrões de IM do conjunto de validação, também conhecido como fase *online*. Os resultados desta última etapa são ilustrados nas Figuras 15 e 16, cujos dados obtidos podem ser vistos na Tabela A1, que está no APÊNDICE A.

Figura 15 – Acurácia da ICC base para fase de validação



Fonte: Produção do próprio autor.

Figura 16 – Acurácia da ICC para a fase de validação



Fonte: Produção do próprio autor.

Os resultados da ICC utilizando percentil 75 e vetor de ponderação mostram que este sistema alcançou valores de até 59,90% para ADL matriz diagonal, 54,58% para ADL matriz completa, 54,58% para ADR, 52,38% para MVS linear e 70,09% para MVS FBR para sujeitos saudáveis. Para os que sofreram AVC, obteve-se 57,46%, 82,07%, 81,91%, 80,03% e 64,15%, respectivamente. Por outro lado, a ICC que utilizou somente o percentil 75 para sujeitos saudáveis obteve melhores resultados para todos os tipos de classificadores testados, exceto o MVS FBR.

É importante notar que alguns sujeitos, utilizando a ICC proposta, apresentaram melhoras de desempenho consideráveis, sendo eles o caso do P3, aumentando de 24,13% para 44,82% pelo ADL matriz diagonal, de 6,89% para 41,37% pelo ADL matriz completa, de 6,89 para 41,37% para o ADR, de 6,89% para 44,82 pelo MVS linear, e de 10,34% para 51,72% pelo MVS FBR. Além desse sujeito, nota-se também uma diferença em P7 e PA1. Tal mudança também foi observada na fase de calibração, logo, a ponderação pelo vetor de características teve um efeito positivo no treinamento do classificador.

Para esse grupo de estudo, na fase de validação, em contrapartida com a diminuição de acurácia na etapa de calibração, observou-se uma melhora nos valores médios para os classificadores ADL matriz diagonal, ADL matriz completa, ADR e MVS linear. Essa melhora está dentro do esperado, tendo em vista que, como relatado por Laiseca (2020) e Cardoso e outros (2021), observou-se uma diminuição de potência de ($p > 0.05$) para esse grupo de estudo. Além disso, o algoritmo foi proposto para melhorar o desempenho da ICC quando o sujeito apresenta uma melhor ativação da intenção motora na região Cz, já que ela está relacionada como movimento de membro inferior.

6 CONCLUSÃO

Este trabalho, em conjunto com o que está sendo desenvolvido no NTA/UFES, apresentou um novo método para melhorar a performance de uma ICC, ponderando o vetor de características de forma que ele esteja mais relacionado ao movimento de pedalar. Essa nova abordagem pode melhorar o desempenho e classificação de sinais EEG em tempo real, o que torna a ICC desenvolvida mais efetiva e mais atrativa para aplicações em clínicas.

O foco deste estudo foi no reconhecimento da IM e, desta forma, a principal contribuição foi propor uma ponderação do vetor de características, buscando obter padrões de sinal mais relacionados ao movimento de pedalar. Então, para tal, a primeira etapa do trabalho foi realizar um estudo para verificar a região mais relacionada ao movimento dos membros inferiores, sendo esta sobre o eletrodo Cz. Logo, foi possível implementar um algoritmo de processamento de sinais de EEG e, baseando-se nas ICCs disponíveis no NTA/UFES, obteve-se uma nova ICC.

Foram utilizados sinais provenientes de 10 indivíduos de um banco de dados para treinar a nova ICC, sendo 8 saudáveis e 2 pós-AVC e, assim, foi possível validá-la. A ICC não obteve o desempenho esperado na fase de calibração, uma vez que apresentou acurácia e Kappa menores que o modelo base. Porém, na etapa de validação, essa nova ICC apresentou um valor médio de ACC melhor para alguns classificadores, além de ter melhorado consideravelmente o desempenho para alguns sujeitos. Essa nova abordagem, implementando a potência relativa, abre a possibilidade de utilizar novas formas de melhorar o processo de calibração de ICCs, o que ainda é um desafio, devido à intrínseca alta incerteza sobre o reconhecimento da Imagética Motora. Além disso, a nova ICC desenvolvida aqui tem um grande potencial para ajudar no reconhecimento de padrões de sinais cerebrais, o que deve ser explorado em pesquisas futuras.

Para trabalhos futuros, propõe-se também testar a ICC com um banco de dados com maior número de sujeitos, focando principalmente nas pessoas que sofreram AVC, de forma a ter uma visão mais ampla do funcionamento desta ICC proposta. Além disso, pretende-se buscar outras configurações para a extração de características dos sinais de EEG. Por fim, também deseja-se portar esse sistema para o software *OpenVibe*, visando o funcionamento em tempo real da ICC e habilitando novas coletas de dados para o banco de dados do NTA/UFES.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALTSCHULER, E. L.; WISDOM, S.; STONE, L.; FOSTER, C.; GALASKO, D.; LLEWELLYN, M.; RAMACHANDRAN; V. Rehabilitation of hemiparesis after stroke with a mirror. **The Lancet**, Londres, v. 353, n. 9169, p. 2035-2036, jun. 1999.
- AMERICAN STROKE ASSOCIATION. **Types of Stroke and Treatment**. 2021. Disponível em: <https://www.stroke.org/en/about-stroke/types-of-stroke>. Acesso em: 23 de mar. 2021.
- ANG, K. K.; CHIN, Z. Y.; ZHANG, H.; GUAN, C. Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface. *In: IEEE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS*, 1., 2008, Hong Kong. **Proceedings** [...]. Hong Kong: IEEE, 2008. p. 2390-2397.
- ANG, K.; CHUA, K.; PHUA, K.; WANG, C.; CHIN, Z.; KUAH, C.; LOW, W.; GUAN, C. A Randomized Controlled Trial of EEG-Based Motor Imagery Brain Computer Interface Robotic Rehabilitation for Stroke. **Clinical EEG and Neuroscience**, [s. l], v. 46, n. 4, p. 310-320, 1 out. 2015.
- ARYA, K. N.; PANDIAN, S.; KUMAR, V. Effect of activity-based mirror therapy on lower limb motor-recovery and gait in stroke: A randomised controlled trial. **Neuropsychological Rehabilitation**, v. 29, n. 8, p. 1193-1210, 14 set. 2019.
- BARACHANT, A.; BONNET, S.; CONGEDO, M.; JUTTEN, C. Classification of covariance matrices using a Riemannian-based kernel for BCI applications. **Neurocomputing**, Amsterdã, v. 122, p. 172-178, jul. 2013.
- BASMAJIAN, J.; LUCA, C. **Muscle Lives: Their Functions Revealed by Electromyographic**. [S. l]: Williams & Wilkins, 1985.
- BIODEX. **Avaliação Neuromuscular e Equilíbrio**. 2021. Disponível em: <https://www.carcioficial.com.br/unweighing-system/>. Acesso em: 1 de abr. 2021.
- BORTOLE, M.; VENKATAKRISHNAN, A.; ZHU, F.; MORENO, J. C.; FRANCISCO, G. E.; PONS, J. L.; CONTRERAS-VIDAL, J. L. The H2 robotic exoskeleton for gait rehabilitation after stroke: Early findings from a clinical study Wearable robotics in clinical testing. **Journal of NeuroEngineering and Rehabilitation**, [s. l], v. 12, n. 1, p. 1-14, 17 jun. 2015.
- CALLOW, N.; HARDY, L. Types of Imagery Associated with Sport Confidence in Netball Players of Varying Skill Levels. **Journal of Applied Sport Psychology**, [s. l], v. 13, n. 1, p. 2-18, 1 jan. 2001.
- CARDOSO, V.; DELISLE-RODRIGUEZ, D.; ROMERO-LAISECA, M.; LOTERIO, F.; GURVE, D.; FLORIANO, A.; VALADÃO, C.; SILVA, L.; KRISHNAN, S.; FRIZERANETO, A.; BASTOS-FILHO, T. Effect of a Brain-Computer Interface Based on Pedaling Motor Imagery on Cortical Excitability and Connectivity. **Sensors**, Basel, v. 21, n.6, p. 1-13, 5 mar. 2021.

CHEN, H.; CHEN, S.; CHEN, J.; FU, Li.; WANG, Y. Kinesiological and kinematical analysis for stroke subjects with asymmetrical cycling movement patterns. **Journal of Electromyography and Kinesiology**, [s. l], v. 15, n. 6, p. 587-595, dez. 2005.

CHEN, S.; LIAW, J.; CHAN, H.; CHANG, Y.; KU, C. A real-time fatigue monitoring and analysis system for lower extremity muscles with cycling movement. **Sensors**, Basel, v. 14, n.7, p. 12410-24, 10 jul. 2014.

CONGEDO, M.; RODRIGUES, P. L. C; BOUCHARD, F; BARACHANT, A; JUTTEN, C. A closed-form unsupervised geometry-aware dimensionality reduction method in the Riemannian Manifold of SPD matrices. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY*, 39., 2017, Jeju. **Proceedings** [...]. Jeju: IEEE, 2017. p. 3198-3201.

CUNHA, I. T.; LIM, P.; QURESHY, H.; HENSON, H.; MONGA, T.; PROTAS, E. Gait outcomes after acute stroke rehabilitation with supported treadmill ambulation training: a randomized controlled pilot study. **Archives of Physical Medicine and Rehabilitation**, [s. l], v. 83, n. 9, p. 1258-1265, 1 set. 2002.

DECETY, J. The neurophysiological basis of motor imagery. **Behavioural Brain Research**. [S. l]. v. 77, n.1, p. 45-52, 1 maio 1996.

DELISLE-RODRIGUEZ, D; **Brain-Computer Interface Based on Unsupervised Methods to Recognize Motor Intention for Command of a Robotic Exoskeleton**. 2017. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Centro Tecnológico, Universidade Federal do Espírito Santo, Vitória, 2017.

DELISLE-RODRIGUEZ, D.; VILLA-PARRA; A. C.; BASTOS-FILHO, T.; LÓPEZ-DELIS, A.; FRIZERA-NETO, A.; KRISHNAN, S.; ROCON, E. Adaptive Spatial Filter Based on Similarity Indices to Preserve the Neural Information on EEG Signals during On-Line Processing. **Sensors**, Basel, v. 17, n. 12, p. 2725-49, 13 nov. 2017.

DELISLE-RODRIGUEZ, D.; CARDOSO, V.; GURVE, D.; LOTERIO, F.; ROMERO-LAISECA, M. A.; KRISHNAN, S.; BASTOS-FILHO, T. System Based on subject-specific bands to recognize pedaling motor imagery: towards a BCI for lower-limb rehabilitation. **Journal of Neural Engineering**, [s. l], v. 16, n. 5, p. 56-72, 23 jul. 2019.

DIPIETRO, L.; FERRARO, M.; PALAZZOLO, J.; KREBS, H.; VOLPE, B.; HOGAN, N. Customized Interactive Robotic Treatment for Stroke: EMG-Triggered Therapy. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, [s. l], v. 13, p. 325-334, set. 2005.

FATOURECHI, M.; WARD, R. K.; MASON, S. G.; HUGGINS, J.; SCHLOGL, A.; BIRCH, G. E. Comparison of Evaluation Metrics in Classification Applications with Imbalanced Datasets. *In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND APPLICATIONS*, 7., 2008, San Diego. **Proceedings** [...]. San Diego: IEEE, 2008. p. 777-782.

FUJIWARA, T.; LIU, M.; CHINO, N. Effect of pedaling exercise on the hemiplegic lower limb. **American Journal of Physical Medicine & Rehabilitation**. [s. l], v. 82, n. 5, p. 357-363, 1 maio 2003.

GAUR, P.; PACHORI, R. B.; WANG, H.; PRASAD, G. A multi-class EEG-based BCI classification using multivariate empirical mode decomposition based filtering and Riemannian geometry. **Expert Systems with Applications**, [s. l], v. 95, n. 16, p. 201-211, 1 abr. 2018.

GOLDFINE, A. M.; SCHIFF, N. D. What is the role of brain mechanisms underlying arousal in recovery motor function after structural brain injuries? **Current Opinion in Neurology**, [s. l], v. 24, n. 6, p. 564-9, dez. 2011.

GUERRA, Z. F.; LUCCHETTI, A. L. G.; LUCCHETTI, G. Motor Imagery Training After Stroke: A Systematic Review and Meta-analysis of Randomized Controlled Trials. **Journal of Neurologic Physical Therapy**, [s. l], v. 41, n. 4, p. 205-214, 2017.

HOSPITAL ENCORE. **Saiba quais são os tipos de AVC**. 2021. Disponível em: <https://encore.com.br/saiba-quais-sao-os-tipos-de-avc/>. Acesso em: 24 de mar. 2021.

HEALTHLINE. **Cerebrovascular Accident**. 2018. Disponível em: <https://www.healthline.com/health/cerebrovascular-accident>. Acesso em: 24 de mar. 2021.

HERNÁNDEZ, M. F. **Human-Robot-Environment Interaction Strategies for Walker-Assisted Gait**. 2018. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Centro Tecnológico, Universidade Federal do Espírito Santo, Vitória, 2018.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa Nacional de Saúde**. Rio de Janeiro: IBGE, 2020. 116 p. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101764.pdf>. Acesso em: 23 de mar. 2021.

JIANG, N.; GIZZI, L.; MRACHACZ-KERSTING, N.; DREMSTRUP, K.; FARINA, D. A brain-computer interface for single-trial detection of gait initiation from movement related cortical potentials. **Clinical Neurophysiology**, [s. l], v. 126, n. 1, p. 154-159, 1 jan. 2015.

JOCHUMSEN, M.; ROVSING, C.; ROVSING, H.; CREMOUX, S.; SIGNAL, N.; ALLEN, K.; TAYLOR, D.; NIAZI, I. K. Quantification of movement-related EEG correlates associated with motor training: A study on movement-related cortical potentials and sensorimotor rhythms. **Frontiers in Human Neuroscience**, [s. l], v. 11, n. 604, p. 1-12, 2017.

KILICARSLAN, A.; GROSSMAN, R. G.; CONTRERAS-VIDAL, J. L. A robust adaptive denoising framework for real-time artifact removal in scalp EEG measurements. **Journal of Neural Engineering**, [s. l], v. 13, n. 2, p. 5-21, 10 fev. 2016.

KIM, J.; LEE, B.; Lee, H. S.; SHIN, K. H.; KIM, M. Ju.; SON, E. Differences in brain waves of normal persons and stroke patients during action observation and motor imagery. **Journal of Physical Therapy Science**, [s. l], v. 26, n. 2, p. 215-218, 1 fev. 2014.

KWAKKEL, G.; KOLLEN, B.; LINDEMAN, E. Understanding the pattern of functional recovery after stroke: Facts and theories. **Restorative Neurology and Neuroscience**, [s. l], v.22, n. 3-4, p.281-299, 1 fev. 2004.

KWAKKEL, G.; KOLLEN, B.; TWISK, J. Impact of time on improvement of outcome after stroke. **Stroke**, [s. l], v. 37, n. 9, p. 2348-53, 24 set. 2006.

LAISECA, A. **Neuro-Robot System for Lower-Limb Rehabilitation After Stroke Based on Motor Imagery and Motorized Bike**. 2018. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Centro Tecnológico, Universidade Federal do Espírito Santo, Vitória, 2018.

LAISECA, A.; DELISLE-RODRIGUEZ, D.; CARDOSO, V.; GURVE, D.; LOTERIO, F.; NASCIMENTO, J.; KRISHNAN, S.; NETO-FRIZERA, A.; BASTOS-FILHO, T.. A Low-Cost Lower-Limb Brain-Machine Interface Triggered by Pedaling Motor Imagery for Post-Stroke Patients Rehabilitation. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, [s. l], v. 28, n. 4, p. 988-996, 14 fev. 2020.

LESKE, S.; DALAL, S. S. Reducing power line noise in EEG and MEG data via spectrum interpolation. **NeuroImage**, Amsterdã, v. 189, n. 59, p. 763-776, 1 abr. 2019.

LOTZE, M.; COHEN, L. G. Volition and Imagery in Neurorehabilitation. **Cognitive and Behavioral Neurology**, [s. l], v. 19, n. 3, p. 135-140, set. 2006.

LOTTE, F.; CONGEDO, M.; LÉCUYER, A.; LAMARCHE, F.; ARNALDI, B. A review of classification algorithms for EEG-based brain computer interfaces. **Journal of Neural Engineering**, [s. l], v. 4, n. 2, p. 1-13, jun. 2007.

MAEDA, F.; KLEINER-FISMAN, G.; PASCUAL-LEONE, A. Motor facilitation while observing hand actions: specificity of the effect and role of observer's orientation. **Journal of Neurophysiology**, [s. l], v. 87, n. 3, p. 1329-35, mar. 2002.

MCHUGH, M. L. Interrate reliability: the kappa statistic. **Biochemia Medica**, [s. l], v. 22, n. 3, p. 276-282, 29 ago. 2012.

MRACHACZ-KERSTING, N.; JIANG, N.; STEVENSON, A. J. T.; NIAZI, I. K.; KOSTIC, Vladimir; PAVLOVIC, A.; RADOVANOVIC, S.; DJURIC-JOVICIC, M.; AGOSTA, F.; DREMSTRUP, K.; FARINA, D. Efficient neuroplasticity induction in chronic stroke patients by an associative brain-computer interface. **Journal of Neurophysiology**, [s. l], v. 115, n. 3, p. 1410-21, mar. 2016.

MULLER-GERKING, J.; PFURTSCHELLER, G.; FLYVBJERG, H. Designing optimal spatial filters for single-trial EEG classification in a movement task. **Clinical Neurophysiology**, Amsterdã, v. 110, n. 5, p. 787-798, 1999.

NAIR, S.; TALY, A. Stroke Rehabilitation: Tradicional and Modern Approaches. **Neurology India**, India, v. 50, n. s1, p. 85-93, dec. 2002.

OPENBCI. **Cyton Biosensing Board (8-channels)**. 2021. Disponível em: <https://shop.openbci.com/collections/frontpage/products/cyton-biosensing-board-8-channel?variant=38958638542>. Acesso em: 6 de abr. de 2021.

PONS, J. **Wearable Robots: Biomechatronic Exoskeletons**. [S. l.: s. n.], 2008.

RAO, R. P. N. **Brain-computer interfacing: An Introduction**. [S. l.]: Cambridge University Press, 2011.

RICHARDS, L.; HANSON, C.; WELLBORN, M.; SETHI, A. Driving motor recovery after stroke. **Topics in Stroke Rehabilitation**, v. 15, n. 5, p. 397-411, 15 nov. 2008.

RIMBERT, S.; GAYRAUD, N.; BOUGRAIN, L.; CLERC, M.; FLECK, S. Can a Subjective Questionnaire Be Used as Brain-Computer Interface Performance Predictor?. **Frontiers in Human Neuroscience**, v. 12, n. 529, p. 1650-1651, 23 jan. 2019.

SILVA, L. A. **Development of a Neuro-Robot System for Lower-Limb Rehabilitation of Post-Stroke Patients Using Motorized Bike Pedal and Motor Imagery**. 2020. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Centro Tecnológico, Universidade Federal do Espírito Santo, Vitória, 2020.

THIEME, H.; MORKISH, N.; MEHRHOLZ, J.; POHL, M.; BEHRENS, J.; BORGETTO, B.; DOHLE, C. **Mirror therapy for improving motor function after stroke**. 2018. Disponível em: <https://www.cochranelibrary.com/cdsr/doi/10.1002/14651858.CD008449.pub3/full>. Acesso em: 5 de nov. 2019.

VALIPOUR, S.; SHALIGRAM, A.; KULKARNI, G. Detection of an alpha rhythm of EEG signals based on EEGLAB. **Journal of Engineering Research and Applications**, [s. l.], v. 4, n. 1, p. 154-159, jan. 2014.

VILLA-PARRA, A. C.; DELISLE-RODRIGUEZ, D.; LIMA, J. S.; FRIZERA-NETO, A.; BASTOS, T. Knee Impedance Modulation to Control an Active Orthosis Using Insole Sensors. **Sensors**, Basel, v. 17, n. 12, p. 2751-2769, 28 nov. 2017.

VOGT, L.; LUCKI, K.; BACH, M. B.; BANZER, W. Rollator use and functional outcome of geriatric rehabilitation. **Journal of Rehabilitation and Research and Development**, [s. l.], v. 47, n. 7, p. 619-625, jun. 2011.

VURAL, S.; YUZER, G.; OZCAN, D.; OZBUDAK, S.; OZGIRGIN, N. The Effects of Mirror Therapy in Stroke Patients with Complex Regional Pain Syndrome Type 1: A Randomized Controlled Study. **Archives of Physical Medicine and Rehabilitation**, Amsterdã, v. 97, n. 4, p. 575-581, abr. 2015.

WANG, Q.; ZHAO, J.; ZHU, Q.; LI, J.; MENG, P. Comparison of conventional therapy, intensive therapy and modified constraint-induced movement therapy to improve upper extremity function after stroke. **Journal of Rehabilitation Medicine**, [s. l.], v. 43, n. 7, p. 619-625, jun. 2011.

WOLPAW, J.; WOLPAW, E. W. **Brain-Computer Interfaces: Principles e Practice**. [S. l.: s. n]., 2012.

WORLD HEALTH ORGANIZATION. **World Health Statistics**. 2019. Disponível em: <https://apps.who.int/iris/bitstream/handle/10665/324835/9789241565707-eng.pdf?sequence=9&isAllowed=y>. Acesso em: 24 de mar. 2021.

WRIGHT, D. J.; HOLMES, P. S.; SMITH, D. Using the movement-related cortical potential to study motor skill learning. **Journal of Motor Behavior**, [s. l], v. 43, n. 3, p. 193-201, 2011.

WU, W.; MALLET, Y.; WALCZAK, B.; PENNINGCKX, W.; MASSART, D. L.; HEUERDING, S.; ERNI, F. Comparison of regularized discriminant analysis, linear discriminant analysis and quadratic discriminant analysis applied to NIR data. **Analytica Chimica Acta**, Amsterdã, v. 329, n. 3, p. 257-265, 20 ago. 1996.

YGER, F.; BERAR, M.; LOTTE, F. Riemannian approaches in Brain-Computer Interfaces: a review. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, [s. l], v. 25, n. 10, p. 1753-1762, out 2016.

ZIMMERMANN-SCHLATTER, A.; SCHUSTER, C.; PUHAN, M. A.; SIEKIERKA, E.; STEURER, J. Efficacy of motor imagery in post-stroke rehabilitation: a systematic review. **Journal of NeuroEngineering and Rehabilitation**, [s. l], v. 5, n. 8, p. 80-90, 14 mar. 2008.

APÊNDICE A – RESULTADOS PARA CADA ICC

Neste apêndice são mostrados os valores obtidos para a ICC de base e o sistema proposto, que foi implementado no software *MATLAB*. Os resultados podem ser observados na Tabela A1.

Tabela A1 – Resultados das interfaces cérebro-computador simuladas

Resultados para ICC base com percentil 75 e sem Vetor de ponderação.							
Fase de Calibração			Fase de Validação				
Sujeito	Acurácia (%)	Kappa	ADL matriz diagonal (%)	ADL matriz completa (%)	ADR (%)	MVS linear (%)	MVS FBR (%)
P1	79,681	0,557	63,934	65,574	67,213	67,213	68,852
P2	78,740	0,562	58,182	54,545	56,364	56,364	65,455
P3	74,354	0,464	24,138	6,897	6,897	6,897	10,345
P4	75,191	0,472	54,887	54,887	54,887	53,885	63,659
P5	68,126	0,363	41,885	50,262	50,262	49,738	56,021
P6	72,392	0,449	39,316	43,223	41,148	42,613	36,386
P7	79,713	0,591	9,486	20,553	24,901	22,530	31,225
P8	72,642	0,471	48,309	57,488	57,488	56,522	65,700
PA1	75,141	0,480	54,088	52,594	52,673	57,547	84,670
PA2	65,905	0,318	66,580	63,185	63,316	61,227	66,188
Média	74,188	0,473	46,081	46,921	47,515	47,453	54,850
Resultados para ICC proposta com percentil 75 e com Vetor de ponderação.							
Fase de Calibração			Fase de Validação				
P1	59,747	0,192	36,066	54,098	54,098	50,820	67,213
P2	64,612	0,279	47,273	50,909	49,091	47,273	70,909
P3	70,394	0,403	44,828	41,379	41,379	44,828	51,724
P4	57,891	0,158	42,105	47,619	47,118	52,381	62,657
P5	66,196	0,325	52,356	39,791	40,052	37,173	37,435
P6	61,009	0,222	43,223	40,537	40,537	38,950	37,851
P7	70,284	0,402	31,621	32,411	32,016	31,621	38,340
P8	62,500	0,261	59,903	54,589	54,589	48,792	61,353
PA1	70,787	0,416	57,469	82,075	81,918	80,031	64,151
PA2	59,947	0,198	47,781	46,345	44,256	54,830	22,585
Média	64,337	0,286	46,262	48,975	48,506	48,670	51,422

Fonte: Produção do próprio autor.