



Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Engenharia Elétrica



Trabalho de Conclusão de Curso

**Análise do desempenho das características de
potência e fase para interfaces cérebro máquina
ativadas por imagética motora**

Franz Victor Peixoto Silva

João Monlevade, MG
2018

Franz Victor Peixoto Silva

**Análise do desempenho das características de
potência e fase para interfaces cérebro máquina
ativadas por imagética motora**

Trabalho de Conclusão de curso apresentado à Universidade Federal de Ouro Preto como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica pelo Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto.

Orientador: Prof.MSc. Fabricio Javier Erazo Costa

**Universidade Federal de Ouro Preto
João Monlevade
2018**

S586a Silva, Franz Victor Peixoto.
Análise do desempenho das características de potência e fase para interfaces cérebro máquina ativadas por imagética motora [manuscrito] / Franz Victor Peixoto Silva. - 2019.

57f.: il.: color; grafs; tabs.

Orientador: Prof. Dr. Fabricio Javier Erazo Costa.

Monografia (Graduação). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Departamento de Engenharia Elétrica.

1. Interface cérebro-computador. 2. Eletroencefalografia. 3. Interação homem-máquina. 4. Estimulação cerebral. 5. Aprendizagem motora. I. Costa, Fabricio Javier Erazo. II. Universidade Federal de Ouro Preto. III. Título.

CDU: 004.5

Catálogo: ficha.sisbin@ufop.edu.br



ATA DE DEFESA

Aos 18 dias do mês de **dezembro** de 2018, às 17 horas, no bloco C deste instituto, foi realizada a defesa de monografia pelo (a) formando (a) **Franz Victor Peixoto Silva**, sendo a comissão examinadora constituída pelos professores: **Fabricio Javier Erazo Costa, Glauco Ferreira Gazel Yared, Harlei Miguel de Arruda Leite**.

O (a) candidato (a) apresentou a monografia intitulada: **Análise do desempenho das características de potência e fase para interfaces cérebro máquina ativadas por imagética motora**. A comissão examinadora deliberou, por unanimidade, pela aprovação do (a) candidato(a), com a nota média 9,0, de acordo com a tabela 1. Na forma regulamentar foi lavrada a presente ata que é assinada pelos membros da comissão examinadora e pelo (a) formando(a).

Tabela 1 – Notas de avaliação da banca examinadora

| Banca Examinadora | Nota |
|-------------------------------|------------|
| Fabricio Javier Erazo Costa | 9,0 |
| Glauco Ferreira Gazel Yared | 9,0 |
| Harlei Miguel de Arruda Leite | 9,0 |
| Média | 9,0 |

João Monlevade, 18 de dezembro de 2018.

Fabricio Javier Erazo Costa
(orientador)

Franz Victor Peixoto Silva
(aluno)

Harlei Miguel de Arruda Leite

Glauco Ferreira Gazel Yared

Agradecimentos

Agradeço em primeiro lugar minha mãe, Marinalva, por me proporcionar tudo que eu tenho, principalmente educação e valores. Agradeço ao meu pai, Geraldo, pela proximidade, amor, companheirismo e a amizade desde sempre. Agradeço a meu irmão, Heron, e minha avó, Juercy, pelo apoio em todos os momentos.

Agradeço a minha família e amigos, pelos bons momentos, pelos momentos de aprendizado, pelas boas conversas, festas e afins. Neste momento agradeço a Deus por iluminar o caminho dos presentes neste agradecimento.

Agradeço de forma especial a minha namorada maravilhosa, Raphaella, pelos ensinamentos, pelas alegrias e risos, pelos momentos de reflexão, pelas *regras*, e pelo amor, te amo.

Também agradeço a Arcelor Mittal Monlevade e a equipe ARMP, onde tive um ambiente incrível de aprendizado e amadurecimento profissional. Todos os integrantes me auxiliaram de alguma forma para estar aqui, seja com conhecimento, com diálogos ou exemplos.

E por fim, mas não menos importante, ao Danilo Melges, que contribuiu diretamente no desenvolvimento deste trabalho compartilhando um pouco da sua experiência e conhecimentos. E ao meu orientador, Fabrício Erazo, que sem sua ajuda eu não estaria apresentando este trabalho. Agradeço imensamente a paciência, aos diversos ensinamentos para a Universidade, nos diversos campos, e a orientação.

*"Without commitment, you'll never start....
but more importantly,
without consistency you'll never finish".
Denzel Washington*

Resumo

Os sistemas de Interface Cérebro Computador - ICC - (BCI - do inglês *Brain Computer Interface*) permitem o controle de dispositivos externos utilizando a atividade cerebral, voltados para diversas aplicações, tais como: controle de próteses ou órteses com o intuito de melhorar a qualidade de vida e/ou recuperação de funções motoras. Neste trabalho foi estudado a influência de características de fase e potência na classificação de único trecho de tarefas motoras no Eletroencefalograma (EEG). As técnicas Padrões Espaciais Comuns (CSP - do inglês *Common Spatial Patterns*), Densidade Espectral de Potência (PSD - do inglês *Power Spectral Density*) e Índice de Acoplamento de Fase (PLV - do inglês *Phase Locking Value*) foram utilizadas como características e foram avaliadas combinadas e de forma independente. Sinais de EEG de 9 indivíduos, da base de dados da Universidade de Graz (Competição BCI 2008), foram coletados em um paradigma multiclasse de imagética motora (MI - do inglês *Motor Imagery*). As classes foram: IM da mão esquerda, mão direita, pé e língua. Foram utilizados 25 canais, sendo 22 para medir EEG e 3 monopolares para medir o eletro-oculograma (EOG). As bandas de frequências estudadas foram de 8 a 12 Hz, 13 a 30 Hz, 8 a 30 Hz e as frequências reativas. CSP atingiu uma acurácia média de 90% para o melhor indivíduo, e a média dos indivíduos foi de 75%. PLV atingiu uma média geral de 61%. Os resultados sugerem que as características na fase podem ser empregadas em ICM's ativadas por IM.

Palavras-chave: Interface cérebro máquina, Eletroencefalograma, PLV, CSP, PSD, LDA, multiclasse.

Abstract

Brain-Computer Interface systems allow the control of external devices using brain activity, for various applications, such as prostheses or orthoses control aiming a better quality of life and/or recovery of motor functions. This study evaluated the influence of phase and power features on Electroencephalography (EEG) single-trial classification of motor tasks. Features as Common Spatial Patterns (CSP), Power Spectral Density (PSD) and Phase Locking Value (PLV) were used independently assessed and together. EEG signals of 9 subjects, from Graz University data base (Competition BCI 2008), were recorded in a multiclass motor imagery paradigm. The classes were: MI of the left hand, right hand, foot and tongue. Twenty-five channels were used, of which 22 were used to measure EEG and 3 were monopolar to measure the electro-oculogram (EOG). The frequency bands studied were: 8 to 12 Hz, 13 to 30 Hz, 8 to 30 Hz and the reactive frequencies. CSP reached an average accuracy of 90 % for the best subject, and the mean accuracy for all subject was 75 %. PLV reached an overall average of 61 %. These results suggest that features in phase can be used in BCI activated by MI.

Keywords: Brain computer interface, EEG, PLV, CSP, LDA, multiclass.

Lista de ilustrações

| | |
|--|----|
| Figura 1 – Aspectos relacionados a implementação de uma ICM (Adaptado de Wolpaw et al. (2002)) | 5 |
| Figura 2 – Arquitetura de um sistema ICM (Adaptado de Brunner e Leeb (2008)) | 7 |
| Figura 3 – Sistema de posicionamento de eletrodos 10/20. Extraído em (TRANS CRANIAL TECHNOLOGIES, 2012) | 10 |
| Figura 4 – Proposta de processamento. | 20 |
| Figura 5 – Divisão temporal das atividades realizadas por trecho | 22 |
| Figura 6 – Posicionamento dos eletrodos utilizados para a aquisição dos sinais de EEG e EOG | 23 |
| Figura 7 – Mapeamento somatotópico relacionando com a posição dos eletrodos . . | 25 |
| Figura 8 – Densidade espectral de potência - Método de Grand Average - Classe Mão Esquerda | 27 |
| Figura 9 – Grand average do PLV por classes e pares de eletrodos | 28 |
| Figura 10 – Comparação da classificação utilizando as PSD's entre 8 a 30 Hz e as frequências reativas | 29 |
| Figura 11 – Comparação da classificação utilizando PLV entre 8 a 30 Hz e as frequências reativas | 30 |
| Figura 12 – Comparação da classificação utilizando as PSD's e o PLV Global entre 8 a 30 Hz e as frequências reativas | 30 |
| Figura 13 – Comparação da classificação utilizando CSP entre 8 a 30 Hz e as frequências reativas | 31 |
| Figura 14 – Comparação da classificação utilizando CSP e o PLV GLobal, entre 8 a 30 Hz e as frequências reativas | 31 |
| Figura 15 – Valores de Acurácia no paradigma Mão Direita-Língua de 8 a 30 Hz . . | 33 |
| Figura 16 – Valores de Acurácia no paradigma Mão Direita-Pé de 8 a 30 Hz | 34 |
| Figura 17 – Valores de Acurácia no paradigma Mão Esquerda-Língua de 8 a 30 Hz | 34 |
| Figura 18 – Valores de Acurácia no paradigma Mão Esquerda-Mão Direita de 8 a 30 Hz | 35 |
| Figura 19 – Valores de Acurácia no paradigma Mão Esquerda-Pé de 8 a 30 Hz . . . | 35 |
| Figura 20 – Valores de Acurácia no paradigma Pé-Língua de 8 a 30 Hz | 36 |
| Figura 21 – Disponível em: < http://www.bbci.de/competition/iv/results/index.html > Acesso em: 13 de dezembro de 2018 | 41 |

Lista de tabelas

| | |
|---|----|
| Tabela 1 – Identificação dos eletrodos. | 9 |
| Tabela 2 – Identificação dos termos dos eletrodos. | 11 |
| Tabela 3 – Descrição dos dados | 21 |
| Tabela 4 – Paradigma do processo de aquisição dos trechos | 22 |
| Tabela 5 – Designação dos eletrodos para o PLV local | 24 |
| Tabela 6 – Designação dos eletrodos do PLV global | 24 |
| Tabela 7 – Quantidade de características utilizadas para geração do modelo de classificação | 26 |
| Tabela 8 – Bandas de frequências reativas em Hz | 28 |
| Tabela 9 – Média dos valores de acurácia das 6 combinações de classificação binária de cada sujeito para cada técnica de extração de características utilizada nas bandas de frequências de 8-30 Hz e para as frequências reativas. CB1* é a combinação de PSD e PLV, e CB2* é a combinação de CSP e PLV. Em negrito estão os maiores valores encontrados para cada indivíduo. | 32 |
| Tabela 10 – Média dos valores de classificação para comparação dos paradigmas em uma abordagem Um vs Resto, para 8 a 30 Hz e frequências reativas. Em negrito estão os maiores valores encontrados para cada indivíduo. μ G é a média geral, VM é a variância multiplicada por 10^{-2} , VG é a variância geral multiplicada por 10^{-5} e FR são as frequências reativas | 33 |

Lista de abreviaturas e siglas

| | |
|----------|--|
| EEG | Eletroencefalograma |
| EOG | Eletrooculograma |
| ECoG | Eletrocorticografia |
| PSD | <i>Power spectral density</i> |
| PLV | <i>Phase locking value</i> |
| CSP | <i>Common spatial patterns</i> |
| SPEC-CSP | <i>SPECtrally Weighted-Common spatial patterns</i> |
| ICM | Interface cérebro máquina |
| ICC | Interface cérebro computador |
| BCI | <i>Brain Computer Interface</i> |
| IM | Imagética motora |
| MI | <i>Motor Imagery</i> |
| ERP | <i>Event Related Potential</i> |
| EP | <i>Evoked Potential</i> |
| LDA | <i>Linear discriminant analysis</i> |
| MRI | <i>Magnetic resonance imaging</i> |
| IDIAP | <i>Istituto dalle molle di intelligenza artificiale percettiva</i> |
| DSLVSQ | <i>Distinction-sensitive learning vector quantisation</i> |
| ISSPL | <i>(Interactive spatio-spectral patterns learning</i> |
| SVM | <i>Support Vector Machine</i> |
| SMA | <i>Supplementary Motor Area</i> |
| CCA | <i>Canonical correlation analysis</i> |
| ICA | <i>Independent Component Analysis</i> |
| CAR | <i>Common average reference</i> |

| | |
|------|---|
| ELM | <i>Extreme learning machine</i> |
| MFFV | <i>Multiresolution fractal feature vector</i> |
| ME | Mão esquerda |
| MD | Mão direita |
| PE | Pé |
| LI | Língua |

Sumário

| | | |
|------------|--|-----------|
| 1 | INTRODUÇÃO | 1 |
| 1.1 | Objetivos | 2 |
| 1.1.1 | Objetivos gerais | 2 |
| 1.1.2 | Objetivos específicos | 2 |
| 1.2 | Estrutura do trabalho | 3 |
| 2 | DESENVOLVIMENTO | 4 |
| 2.1 | Conceitos fundamentais | 4 |
| 2.2 | Arquitetura de um sistema ICM | 7 |
| 2.2.1 | Métodos de coleta de dados: ICM baseadas em EEG | 9 |
| 2.2.2 | Padrões internacionais de posicionamento de eletrodos | 9 |
| 2.2.2.1 | Ritmos cerebrais | 11 |
| 2.3 | Técnicas de processamento e resultados em ICM-IM: Revisão da literatura | 12 |
| 3 | METODOLOGIA | 15 |
| 3.1 | Métodos matemáticos | 15 |
| 3.1.1 | PLV - <i>Phase Locking Value</i> | 15 |
| 3.1.1.1 | Transformada de Hilbert | 15 |
| 3.1.2 | PSD - <i>Power Spectral Density</i> | 16 |
| 3.1.3 | CSP - <i>Common Spatial Patterns</i> | 17 |
| 3.1.4 | LDA - <i>Linear Discriminant Analysis</i> | 19 |
| 3.2 | Métodos | 19 |
| 3.2.1 | Base de dados | 21 |
| 3.2.2 | Extração de características | 22 |
| 3.2.2.1 | Características na fase | 22 |
| 3.2.2.2 | Características na potência | 25 |
| 3.2.2.3 | Número de características | 26 |
| 4 | RESULTADOS | 27 |
| 4.1 | Análise espectral: Densidade espectral de potência | 27 |
| 4.2 | Análise temporal: Índice de acoplamento de fase (PLV) | 28 |
| 4.3 | Comparação de acurácia: 8 a 30 Hz vs. Frequências reativas | 28 |
| 4.4 | Acurácias por indivíduo para cada combinação de características | 32 |
| 5 | DISCUSSÃO E CONCLUSÃO | 37 |

| | | |
|-------|--|-----------|
| 5.0.1 | Trabalhos futuros | 37 |
| | REFERÊNCIAS | 38 |
| | ANEXO A – COMPETIÇÃO DE ICM IV:RESULTADOS | 41 |

1 Introdução

Interface cérebro-máquina (ICM) é um sistema que permite o controle de dispositivos externos utilizando a atividade cerebral. Esta interface pode servir como uma ferramenta de comunicação do indivíduo, criando inúmeras possibilidades de desenvolvimento, como a escolha de palavras em um monitor, realizar o controle das atividades de uma residência.

Uma ICM genérica pode ser dividida em módulos (BRUNNER; LEEB, 2008), (1) aquisição de sinais, (2) pré-processamento, (3) processamento de sinais e (4) aplicação. A ativação da ICM é realizada pelo reconhecimento de padrões corticais devido a um estímulo sensorial e/ou cognitivo. Especificamente, as ICM-IM são as interfaces que são acionadas com a identificação das mudanças cerebrais devido a imaginação da tarefa motora.

A análise dos padrões de sincronização/dessincronização relacionada ao evento (ERS/ERD – do inglês *Event-related synchronization/desynchronization*) é muito comum em experimentos relacionados com IM, estes padrões indicam um aumento ou redução de potência do sinal em determinadas faixas de frequências. Por este motivo, a potência tem sido uma das características mais utilizadas em sistemas de ICM-IM (PFURTSCHELLER et al., 1997). O algoritmo conhecido como padrões espaciais comuns (CSP - do inglês *Common spatial patterns*) tem mostrado um bom desempenho na classificação de tarefas motoras utilizando a variância das projeções das observações nos filtros espaciais - bandas específicas (JOCHUMSEN et al., 2015; RAMOSER et al., 2000). Outros estudos mostraram que a fase também é uma característica que pode ser utilizada em BCI-IMs, encontrando valores de acurácia de 96% na discriminação de tarefas motoras quando o valor de bloqueio de fase (PLV- do inglês *Phase locking value*) foi utilizado (WANG et al., 2006; YI et al., 2016; LACHAUX et al., 1999).

1.1 Objetivos

1.1.1 Objetivos gerais

Este trabalho tem como meta principal avaliar os efeitos da utilização de características de fase e/ou potência na classificação multiclasse (IM da mão direita, mão esquerda, pés e língua) em um sistema ICM ativado por IM.

1.1.2 Objetivos específicos

De acordo com a abordagem deste trabalho, as metas específicas são a implementação da técnica de extração de característica CSP, PLV e PSD, a avaliação da influência das frequências reativas na banda alfa e a avaliação do método de validação cruzada K-fold em um paradigma multiclasse.

1.2 Estrutura do trabalho

Este trabalho está dividido em cinco capítulos: Introdução, Desenvolvimento, Metodologia, Resultados, Discussão e conclusão. O primeiro capítulo é a introdução e explicação do problema estudado. No segundo capítulo é apresentada a revisão bibliográfica sobre ICM baseadas em EEG, técnicas de processamento de sinais, e métodos de registro. No capítulo três é apresentada a metodologia proposta, sendo descritas as técnicas de pré-processamento, a base de dados, técnicas de extração de características e classificador. No quarto capítulo são mostrados os resultados de classificação. O último capítulo é a discussão dos resultados e a conclusão do trabalho.

2 Desenvolvimento

2.1 Conceitos fundamentais

A ICM é um sistema que traduz a atividade cerebral em aplicações voltadas à comunicação, reabilitação e ao controle de dispositivos externos (HÖHNE et al., 2014). A aquisição destes sinais cerebrais pode ser realizada por procedimentos invasivos como eletrocorticografia (ECoG) e não invasivos como EEG (ALIAKBARYHOSSEINABADI et al., 2014), magnetoencefalografia (MEG) e imagem por ressonância magnética (MRI). Destes procedimentos, o mais utilizado em ICM é o EEG, que é baseado nas variações dos potenciais elétricos no cérebro. A sua grande utilização se deve ao baixo custo dos instrumentos, facilidade de medição, aplicabilidade e boa resolução temporal (WOLPAW et al., 2002).

No desenvolvimento de sistemas ICM devem ser considerados aspectos como o modo de operação, tipo de entrada de sinal, ativação da operação e realimentação. A Figura 1 ilustra estes parâmetros com possíveis definições, relacionadas com a implementação do sistema.

Figura 1 – Aspectos relacionados a implementação de uma ICM (Adaptado de Wolpaw et al. (2002))



Para realizar o controle de ICMS é necessário escolher uma estratégia de alteração da atividade cerebral, como um estímulo visual, auditivo ou tátil (HÖHNE et al., 2014), gerando uma resposta evocada sincronizada com a estimulação. Esta resposta é usualmente classificada como potencial relacionado ao evento (ERP – do inglês *Event Related Potential*) - que normalmente inclui alguma componente cognitiva, como tarefas que envolvem raciocínio, atenção e imaginação - ou potencial evocado (EP – do inglês *Evoked Potential*) - resposta predominantemente sensorial. Tanto o ERP quanto o EP são comumente analisados ao se calcular a forma de onda destas respostas por meio de média de janelas de EEG sincronizadas com o estímulo.

Além da análise morfológica das respostas, um outro tipo de ativação que pode ser gerado por estimulação sensorial e/ou cognitiva é a chamada resposta induzida, que pode ser medida através dos padrões de sincronização/desincronização, que correspondem, respectivamente, ao aumento e redução da potência do sinal, causados pela estimulação. Este tipo de análise é bastante comum em experimentos que envolvem IM (PFURTSCHELLER; LOPES, 1999).

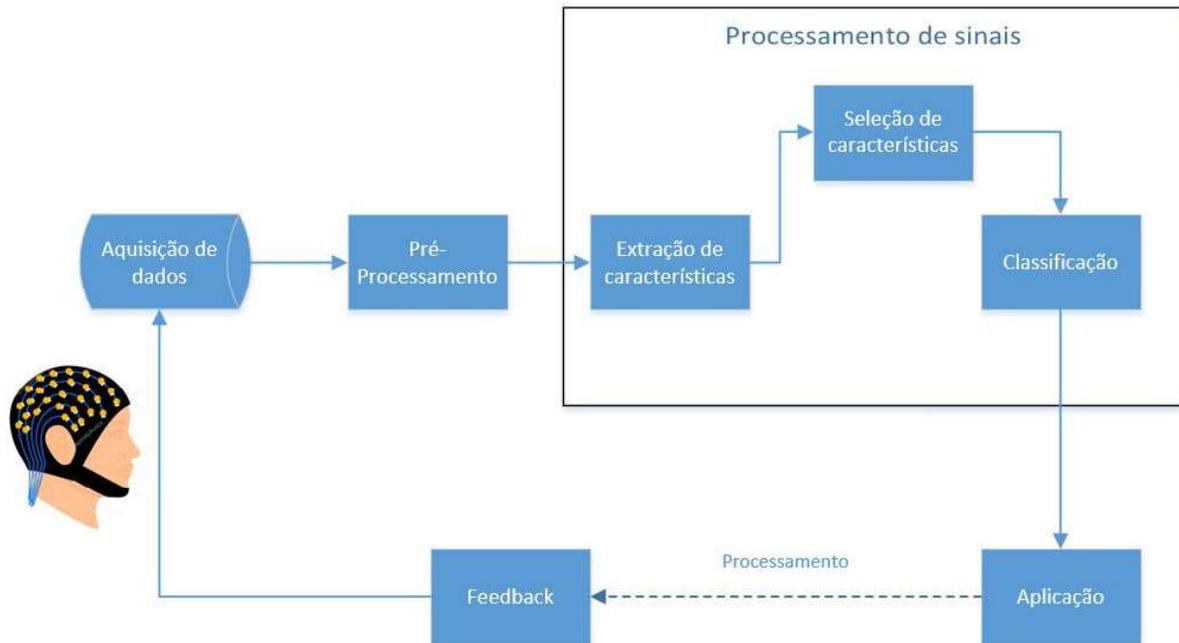
As ICMs ativadas por IM são conhecidas como ICM-IM. A IM é a simulação de um movimento, seguindo os mesmos passos de organização com estratégia, tática, mas sem realizar a execução (ativação muscular) do movimento. Esta estratégia pode ser utilizada em ICMs, porque tanto a IM como a execução do movimento ativam áreas corticais similares. Devido a este fenômeno fisiológico, tanto a IM como a ICM têm sido aplicadas como técnicas de neuroreabilitação para a recuperação e melhoria de funções motoras (BEAR; CONNORS; PARADISO, 2007).

Os sistemas ICMs como objetivos melhorar a qualidade de vida de indivíduos que sofrem com algum tipo de paralisia, auxiliando-os na comunicação ou controle de próteses. Este sistema utiliza sinais EEG com ativação por IM (tarefa motora específica) e/ou PEs (resposta a estímulos sensoriais - ex: visual) (JELLINGER, 2009; PFURTSCHELLER; NEUPER; BIRBAUMER, 2005).

2.2 Arquitetura de um sistema ICM

O modelo de um sistema genérico de uma ICM (BRUNNER; LEEB, 2008) pode ser descrito conforme ilustrado na Figura 2.

Figura 2 – Arquitetura de um sistema ICM (Adaptado de Brunner e Leeb (2008))



- Aquisição de sinais: O primeiro passo consiste em fazer o registro dos sinais cerebrais, cujo procedimento pode ser diferenciado em invasivo ou não invasivo. Os métodos de aquisição não invasivos não realizam a inserção de eletrodos/módulos no corpo. Este tipo de procedimento é realizado através de fMRI, EEG, entre outras.
- Pré-processamento: Com os sinais digitalizados, deve ser feita a adequação dos sinais através de filtragem, segmentação e técnicas de processamento para atenuação dos artefatos.
- Extração de características: Esta etapa permite a extração de informações dos sinais coletados para uma melhor representação do seu comportamento. As técnicas de extração de características são capazes de extrair parâmetros que podem identificar alterações na atividade cerebral.
- Seleção de características: Depois de se extrair as características, deve-se escolher quais parâmetros melhor diferenciam duas ou mais classes de atividades cerebrais específicas (ex: tipos diferentes de movimento).

- Classificadores: Estes métodos permitem discriminar a qual classe pertencem os dados extraídos, sendo que quanto melhor forem a extração e a seleção de características, melhor o desempenho esperado para o classificador e, portanto, da ICM.
- Aplicação: Há uma grande variedade de aplicações de sistemas de BCI, a qual inclui a comunicação de indivíduos com esclerose lateral amiotrófica (ELA) (SELLERS; DONCHIN, 2006), o controle de próteses (SAMUEL et al., 2017) e o controle de cadeira de rodas (JIANG et al., 2014).

2.2.1 Métodos de coleta de dados: ICM baseadas em EEG

O EEG é o procedimento mais utilizado atualmente na aquisição de sinais cerebrais para desenvolvimento de ICM (PFURTSCHELLER et al., 1997; WANG et al., 2012; YI et al., 2016), devido a seu baixo custo, facilidade de uso e portabilidade. É caracterizado por ter uma boa resolução temporal (WOLPAW et al., 2002), o que permite a análise de fenômenos fisiológicos de curta duração (milisegundos).

Apesar destas vantagens, existem determinados cuidados que se deve ter ao se empregar o EEG. Particularmente, para a construção de ICM, a qual envolve estimulação exógena (ex: visual) ou endógena (ex: IM), deve-se tomar em consideração o registro dos sinais na região do escalpo adjacente à área cortical predominantemente associada ao processamento de um dado estímulo, tendo-se também em mente que a medida provida pelo EEG é uma projeção na superfície do escalpo de somas espaço-temporais de atividades de diversos neurônios. Além disso, para sistemas de ICM, o emprego de equipamentos capazes de realizar o processamento online é imprescindível (WOLPAW et al., 2002).

2.2.2 Padrões internacionais de posicionamento de eletrodos

Para o registro do EEG, estabeleceram-se padrões de posicionamento de eletrodos, os quais são também amplamente empregados fora da prática médica, como na construção de ICMs e em pesquisa.

Os padrões internacionais mais utilizados para registro do EEG são: 10/20, 10/10 e 10/5. Os valores de 10, 20 e 5 referem-se à porcentagem de distâncias entre marcas anatômicas no crânio (násion-ínion passando pela linha medial, násion-ínion passando pela lateral da cabeça e distância interauricular)

Os eletrodos são identificados por 2 ou 3 caracteres de acordo com sua posição. A Tabela 1 apresenta o significado das primeiras letras da indicação de cada eletrodo. Além disso, os números que seguem indicam o hemisfério, com números pares para hemisfério direito e números ímpares para o esquerdo. Se o eletrodo estiver na linha central ele recebe o caractere “z”.

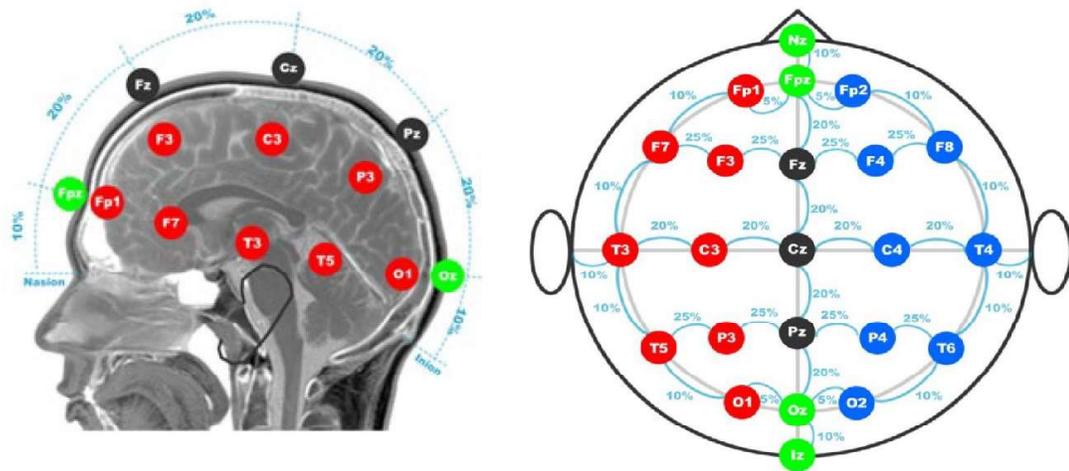
Tabela 1 – Identificação dos eletrodos.

| Eletrodo | Região Cerebral |
|----------|-----------------|
| Fp | Fronto-polar |
| F | Frontal |
| T | Temporal |
| C | Central |
| P | Parietal |
| O | Occipital |

A Figura 3 indica o posicionamento dos eletrodos do sistema 10/20, indicando a distância entre eles. Devido à baixa quantidade de eletrodos, o Sistema 10/20 pode

ser considerado de baixa resolução espacial. Esta desvantagem pode ser contornada pelo Padrão 10/10, que apresenta 81 canais (JURCAK; TSUZUKI; DAN, 2007), interpolando-se eletrodos entre cada par do Padrão 10/20. Além disso, existem no mercado sistemas para aquisição de sinais de EEG com 128, 256 ou mais canais (Geodesic EEG System 400), voltados para aplicações específicas.

Figura 3 – Sistema de posicionamento de eletrodos 10/20. Extraído em (TRANS CRANIAL TECHNOLOGIES, 2012)



2.2.2.1 Ritmos cerebrais

Como a ativação de somente um neurônio não é capaz de gerar uma corrente suficiente para ser medida, um sinal de EEG é o resultado da ativação conjunta de milhares de neurônios. Sendo assim, o sincronismo de ativação tem uma grande importância em relação à amplitude do sinal gerado, pois mesmo que diversos neurônios sejam ativados, se esse conjunto não for sincronizado, o somatório dos sinais não gera um sinal de amplitude relevante (BEAR; CONNORS; PARADISO, 2007).

Os ritmos ou bandas do EEG podem ser caracterizados pela sua faixa de frequência, estado comportamental, localização no córtex devido a um estímulo ou um estado particular. Os nomes dos ritmos cerebrais, com suas respectivas bandas de frequência se encontram detalhadas na Tabela 2.

Tabela 2 – Identificação dos termos dos eletrodos.

| Comparação de bandas do EEG | | | |
|-----------------------------|----------------|---|--|
| Banda | Frequência(Hz) | Localização cerebral | Condição de ocorrência e características da atividade cerebral |
| Delta | <4 | Frontalmente em adultos | Encontrada no sono de ondas lentas e durante algumas tarefas de atenção contínua. Usualmente, apresenta amplitude elevada. |
| Teta | 4 - 7 | Sem localização específica | Encontrada em estados de sonolência e inatividade. |
| Alfa | 8 - 15 | Região posterior em ambos os hemisférios (C3 e C4) | Observada com o indivíduo relaxado e com os olhos fechados. |
| Beta | 16 - 31 | Presente em ambos hemisférios, simétrica, localizada mais frontalmente. | Encontrada com o indivíduo ativo, focado, em estado de alerta ou em condições de ansiedade. Normalmente apresenta baixa amplitude. |
| Gama | 32+ | Em região adjacente ao córtex somatossensorial | Observado durante processamento sensorial de modalidade cruzada. |
| Mu | 8 - 12 | Em região adjacente ao córtex sensoriomotor | Comum durante a redução da atividade de neurônios motores. |

Fonte: (BEAR; CONNORS; PARADISO, 2007)

2.3 Técnicas de processamento e resultados em ICM-IM: Revisão da literatura

Na implementação de ICM-IM, a identificação dos padrões de SRE/DRE é muito importante, pois a potência é muito utilizada na extração de características.

Utilizando SRE/DRE (PFURTSCHELLER et al., 1997), foi obtido uma acurácia média de aproximadamente 80% utilizando classificadores online. A janela de tempo escolhida foi de 1 segundo em que foram coletadas as componentes espectrais, e posteriormente foi utilizado o classificador DSLVQ (do inglês - *distinction-sensitive learning vector quantization*) para determinar quais frequências eram mais relevantes. Neste paradigma foram estudados somente 2 classes, mão direita e esquerda, e os resultados obtidos mostraram maior desincronização na área contralateral central e uma maior sincronização na área ipsilateral ao movimento.

O CSP é uma técnica de extração de características amplamente utilizada em aplicações de IM no EEG. De acordo com estudos baseado nessa técnica, a IM das mãos resultou em variações do EEG nas áreas contralateral e ipsilateral central (RAMOSER et al., 2000). Além disso, utilizando a técnica CSP, foi possível discriminar a IM de duas classes, mão esquerda e mão direita, com dados de *single trial*. Os melhores resultados obtidos foram 92.7% utilizando uma derivação bipolar com 34 canais, 90,8% utilizando uma derivação CAR (do inglês - *Common average reference*) com 18 canais e 99.7% utilizando 56 canais.

A utilização de CSP como técnica de extração de características funciona paralelamente com o fenômeno de SRE/DRE. Desta forma, utilizando técnicas de otimização dos filtros espaço-espectral como SPEC-CSP (do inglês - *SPECtrally Weighted CSP*), e ISSPL (do inglês - *Interactive Spatio-Spectral Patterns Learning*), foram avaliadas as taxas de acurácia para seis indivíduos em um paradigma de duas classes. Foram comparadas as técnicas de extração de características: CSP de larga-banda, teórico SPEC-CSP e SPEC-CSP modificado, e a técnica proposta ISSPL. O classificador utilizado foi o SVM (Máquina de vetores auxiliares - *Support Vector Machine*). Para todos os indivíduos ISSPL mostrou maior acurácia, alcançando $98,67\% \pm 1.12$ para o melhor indivíduo, e uma média de aproximadamente 92% (WU et al., 2008).

Considerando os resultados satisfatórios obtidos utilizando CSP em ICM-IM, foi implementada uma abordagem que considerou uma ativação cerebral pelo PE Visual de Estado Estacionário (do inglês - *Steady State Visual Evoked Potential* - SSVEP) utilizando a análise de correlação canônica (*Canonical correlation analysis* - CCA) para avaliar o método que alcançaria a maior taxa de acurácia. A proposta implementada, foi dividida em CSP-IM *off-line*, SSVEP-*off-line* e a abordagem híbrida de combinação das duas anteriores, com CSP-IM e CSP-CCA-SSVEP. Após 5 sessões, o paradigma híbrido proposto indicou uma maior acurácia média, de aproximadamente 90% (YU et al., 2015).

Por outro lado, outros trabalhos têm estudado a fase como característica nas ICM-IMs. De acordo com essa abordagem, foi avaliada a importância da fase isoladamente como extrator de característica de uma ICM-IM. A análise de componentes independentes (ICA - do inglês *Independent Component Analysis*) foi utilizada para extrair características de fase, e como classificador a técnica de aprendizado extremo de máquina (ELM - do inglês *Extreme Learning Machine*). No experimento foram utilizados somente a IM da mão direita e língua, implementando uma classificação binária. Foram utilizadas 22 derivações de EEG obtendo uma acurácia média (9 indivíduos) de 94.3% (QURESHI; CHO; LEE, 2017).

Também foi evidenciado que a sincronia dos sinais em relação a fase é propícia para identificar as classes em uma ICM-IM. Wang et al. (2006) focaram seu estudo nas regiões corticais voltadas a movimento: área motora suplementar (SMA - do inglês *supplementary motor area*) e o córtex motor primário (também chamado de M1), analisando as derivações C3, C4 e FCz. Foram utilizadas duas classes, IM-mão direita e IM-mão esquerda. Uma acurácia média de 87% foi encontrada quando características do PLV local e global foram utilizadas em conjunto, enquanto que uma acurácia de 96% foi atingida com características combinadas de PLV global e de potência.

O estudo do PLV e da coerência espectral nas bandas alfa, beta superior, beta inferior e de 8 a 30 Hz indicou que os melhores resultados foram obtidos utilizando a banda alfa, atingindo 62% de acurácia (GYSELS; CELKA, 2004). Em contrapartida, (HU; MU; WANG, 2008) atingiram valores de classificação de 93% utilizando somente o PLV. Ainda, os resultados constataram que a utilização de uma banda mais larga, envolvendo as ondas alfa e beta, trazem melhores resultados de classificação, quando utilizadas as bandas de forma isolada..

HSU (2013), compararam a fase e a potência utilizando PLV, coerência, potência espectral e razão anti simétrica e a técnica vetor de características de multiresolução fractal (MFFV - do inglês *Multiresolution Fractal Feature Vector*). Ao se utilizar a informação de potência, uma média de 75% de acurácia foi obtida, contra 72,1% ao se empregar a fase. Neste trabalho, somente um indivíduo mostrou resultados com a fase superior aos resultados com a potência. Com a utilização de MFFV a média de acurácia foi de 81,1%. Por fim, a seleção de características utilizando algoritmo genético e uma combinação das técnicas anteriores aumentou a média de acurácia para 86,7%. Em relação ao classificador, foi utilizado tanto LDA quanto SVM, e a média das acurácias foram, respectivamente 80.8% e 86.7%.

Falzon e Camilleri (2009) propuseram uma variação do método de CSP que depende somente das componentes da fase do sinal. Como é característico da técnica CSP, em sua implementação padrão, não é possível saber se o resultado encontrado é característico da fase ou da variação da amplitude. Os resultados mostraram que o algoritmo implementado do P-CSP baseado na fase atingiu valores que são próximos e em alguns casos melhores,

do que o método usual de PLV.

3 Metodologia

3.1 Métodos matemáticos

3.1.1 PLV - *Phase Locking Value*

O PLV foi empregado em ICMs no EEG por Lachaux et al. (1999). O índice de PLV indica o grau de sincronização neural (*phase-locking*) entre dois eletrodos. Neste trabalho, este valor foi utilizado para quantizar o acoplamento de fases durante a IM da mão esquerda, mão direita, pé e língua (WANG et al., 2006).

O PLV é um índice calculado no domínio do tempo, para tanto, considere dois pares de eletrodos com medições de potencial, $S_1(t)$ e $S_2(t)$. A medição de suas fases são respectivamente $\varphi_1(t)$ e $\varphi_2(t)$. Esta técnica de extração de característica faz a comparação das fases de dois ou mais sinais para quantificar o grau de acoplamento de fases (*phase-locking*). Para isso deve-se calcular a diferença nas fases, sendo assim:

$$\Delta\varphi(t) = \varphi_1(t) - \varphi_2(t) \quad (3.1)$$

E o resultado do PLV de dois eletrodos é:

$$PLV = \left| \langle e^{j\Delta\varphi(t)} \rangle_t \right| \quad (3.2)$$

Em que o operador $\langle \cdot \rangle_t$ representa a média dos valores no tempo, e $|\cdot|$ é o módulo. Para uma abordagem global, o PLV é calculado dois-a-dois. No caso de uma abordagem local em que os eletrodos estão mais próximos, deve ser calculado em de pares de eletrodos, sendo calculada a média dos PLVs ao final. Como exemplo, se fossem utilizados 5 eletrodos, então haveria dez pares possíveis, e a fórmula seria (WANG et al., 2006):

$$PLV = \frac{1}{10} \sum_{k=1}^{10} \left| \langle e^{j\Delta\varphi(t,k)} \rangle_t \right| \quad (3.3)$$

onde k representa o índice de um dos 10 possíveis pares de eletrodos. Neste trabalho, foi calculada o PLV de cada single-trial para a realização da classificação. O índice de PLV está contido dentro do intervalo de 0 a 1, sendo que o PLV igual a 1 sugere que as áreas em que estão sendo medidos os potenciais estão em perfeita sincronia, e ao contrário, o PLV igual a 0 indica total dessincronização do estímulo.

3.1.1.1 Transformada de Hilbert

A transformada de Hilbert mapeia um sinal real $x(t)$ no domínio do tempo para um sinal $\tilde{x}(t)$ no mesmo domínio do tempo, o qual é calculado a partir da convolução de

$x(t)$ com a função $1/\pi t$ (PIERSOL; G, 2000).

$$y(t) = \tilde{x}(t) = \int_{-\infty}^{\infty} \frac{x(\tau)}{\pi(\tau - t)} d\tau \quad (3.4)$$

Então $\tilde{x}(t)$ também pode ser escrito como a convolução do sinal de entrada $x(t)$ e o termo $\frac{1}{\pi t}$ (BRACEWELL, 1999).

$$\tilde{x}(t) = x(t) * \frac{1}{\pi t} \quad (3.5)$$

Uma de suas aplicações é a análise da frequência instantânea em função do tempo do sinal analítico $z(t)$. A partir de $x(t)$ e sua Transformada de Hilbert $\tilde{x}(t)$, define-se um sinal complexo:

$$z(t) = x(t) + j\tilde{x} \quad (3.6)$$

ou, na forma polar:

$$z(t) = E(t)e^{j\varphi(t)} \quad (3.7)$$

onde $E(t)$ representa o envelope ou envoltória, ou amplitude instantânea do sinal, calculada por:

$$E(t) = |x(t) + j\tilde{x}(t)| \quad (3.8)$$

E $\varphi(t)$ é a fase instantânea, dada por:

$$\varphi(t) = \tan^{-1} \left(\frac{\tilde{x}(t)}{x(t)} \right) \quad (3.9)$$

A frequência instantânea pode ser definida como a derivada da fase em relação ao tempo, definida matematicamente como:

$$\omega(t) = -\frac{d}{dt} (\varphi(t) + L(t)) \quad (3.10)$$

A função de $L(t)$ serve para manter a fase contínua, sendo um valor inteiro multiplicado por π . De modo similar a frequência, a potência também pode ser encontrada em função do tempo. Basta elevar ao quadrado os valores do envelope.

3.1.2 PSD - *Power Spectral Density*

A técnica utilizada para realizar a análise espectral dos dados neste trabalho foi a densidade espectral de potência (PSD - do inglês *Power Spectral Density*). Existem diversas técnicas que calculam o periodograma de sinais tais como: Daniell, Bartlett, Burg e Welch (Aydın, Ü., Doğan, R., Ortaç, 2016). Neste trabalho foi utilizado a PSD pelo método de Welch.

Este método é bastante utilizado pois utiliza a Transformada Rápida de Fourier (do inglês - *Fast Fourier Transform - FFT*), o que pode reduzir a quantidade de

cálculos computacionais. O periodograma de Welch realiza a segmentação do trecho em janelas (podendo haver sobreposição – ex: 50%), calcula a transformada de Fourier de cada janela, eleva a amplitude do espectro calculado e por fim, calcula a média da potência dos trechos.

$$P_{xx}(f) = |X(f)|^2 \quad (3.11)$$

Matematicamente, dado um sinal temporal $X[n]$ de comprimento N , tal que $n = 0, \dots, N - 1$. O sinal é segmentado em janelas de tamanho L ($L < N$), separados por D amostras, e com K trechos, tal que:

$$X_1 = x(j); j = 0, \dots, L - 1 \quad (3.12)$$

$$X_2 = x(j + D); j = 0, \dots, L - 1 \quad (3.13)$$

Até

$$X_k = x(j + (k - 1)D); j = 0, \dots, L - 1. \quad (3.14)$$

Obs: Por conseguinte $(K - 1)D + L = N$.

Para calcular um periodograma para cada trecho, os trechos segmentados são multiplicados por uma janela de tamanho L , resultando em K 's periodogramas. Neste método é calculado a transformada finita de Fourier:

$$A_k(n) = \frac{1}{L} \sum_{j=0}^{L-1} X_k(j)W(j)e^{-2kijn/L} \quad (3.15)$$

Obtendo:

$$I_k(fn) = \frac{L}{U} |A_k(n)|^2; k = 1, 2, 3, \dots, K \quad (3.16)$$

Para $fn = n/L$, em que $n = 0, \dots, L/2$ e a U é a média da potência da janela $W(j)$.

$$U = \frac{1}{L} \sum_{j=0}^{L-1} W(j)^2 \quad (3.17)$$

E a estimação espectral é a média dos K 's periodogramas calculados:

$$\hat{P}(fn) = \frac{1}{K} \sum_{k=1}^K I_k(fn) \quad (3.18)$$

3.1.3 CSP - *Common Spatial Patterns*

A técnica CSP realiza a transformação linear dos dados de entrada para um novo grupo de dados em que a variância é ideal para a destinação entre classes de dados, utilizando a diagonalização simultânea de duas matrizes de covariância (RAMOSER et al., 2000). Esta transformação é realizada utilizando uma matriz de projeção em que, os dados de EEG de todas as derivações são convertidos em um subespaço espacial de baixa dimensão (IRU et al., 2005), as linhas da matriz de projeção funcionam como um filtro espacial.

O CSP foi utilizado na extração de características em uma ICM com ativação por IM pela mão esquerda, mão direita, pé e língua. Os sinais de EEG foram previamente filtrados utilizando um filtro *Butterworth* de ordem 2 e em quatro frequências de passagem: 8 a 12 Hz, 13 a 30 Hz, 8 a 30 Hz e as frequências reativas para cada indivíduo e classe. Totalizando quatro experimentos diferentes.

Conforme o algoritmo de Ramoser et al. (2000), dado um conjunto de dados de EEG de um *trial* denominado E, cujas dimensões são $N \times T$, em que N são os números de canais e T os números de amostras. A matriz de covariância C foi obtida por:

$$C = \frac{EE'}{\text{trace}(EE')} \quad (3.19)$$

Tal que *trace* é a soma da diagonal da matriz e o operador ' realiza a matriz transposta. Em sequência, é calculado a matriz de covariância para cada classe de IM, considerando o número de *trials* por classe. Assim, é possível calcular a matriz de covariância espacial composta (Eq. 3.20).

$$C_c = \overline{C1} + \overline{C2} \quad (3.20)$$

Como C_c é uma matriz quadrada, ela pode ser fatorada em $C_c = U_c \lambda_c U_c'$, em que U_c é a matriz de autovetores e λ_c é a matriz de autovalores. Considerando sempre que os autovalores estão ordenados de forma decrescente.

A transformação de branqueamento P equilibra todas as variâncias do espaço calculado pelos autovetores:

$$P = \sqrt{\lambda^{-1}} U_c' \quad (3.21)$$

Então, todos os autovalores de $PC_c P'$ são iguais a 1, e, se $\overline{C1}$ e $\overline{C2}$ são transformados em:

$$S1 = P \overline{C1} P' \quad e \quad S2 = P \overline{C2} P' \quad (3.22)$$

Consequentemente S1 e S2 irão compartilhar dos mesmos autovetores, o resultado disso é, se:

$$S1 = B \lambda_1 B' \quad (3.23)$$

então:

$$S2 = B \lambda_2 B' \quad (3.24)$$

Então a matriz de projeção W é calculada por:

$$W = B' P \quad (3.25)$$

E os dados de EEG discriminados serão:

$$Z = W E \quad (3.26)$$

3.1.4 LDA - *Linear Discriminant Analysis*

Os classificadores são utilizados em um sistema ICM para realizar a discriminação de classes, e neste trabalho foi utilizado um classificador linear que propõe uma função discriminante ótima para separação. A técnica utilizada foi a análise de discriminante linear (*Linear discriminant analysis - LDA*), que visa maximizar a separabilidade entre categorias, criando novos eixos que projetam os dados de forma excludente maximizando a distância entre as médias (de cada classe) e minimizando a variância (dispersão dentro de cada classe) (CHOU et al., 2010).

O algoritmo é baseado na geração de coeficientes que satisfazem a função linear X , em que as variáveis x , são as médias de cada característica para uma classe.

$$X = b^1 x_1 + b^2 x_2 + \dots + b^p x_p \quad (3.27)$$

A Equação 3.28 representa o termo a ser maximizado, pois no numerador está as médias que devem estar distantes e no denominador as variâncias dentro das classes que devem ser menores possível.

$$J(v) = \frac{(\tilde{\mu}_1 - \tilde{\mu}_2)^2}{\tilde{S}_1^2 + \tilde{S}_2^2} \quad (3.28)$$

Em que v é a direção a ser projetada, e J a razão de separação.

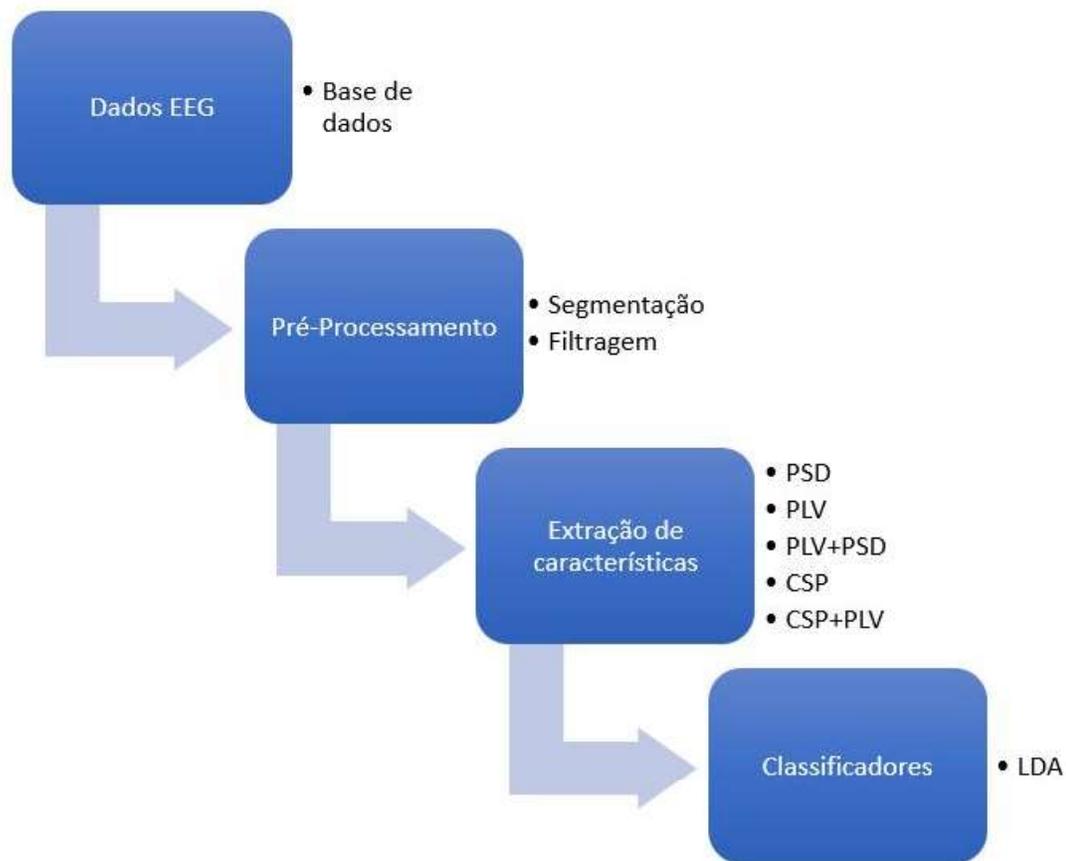
O objetivo do classificador é criar um modelo utilizando os dados de treinamento para cada paradigma entre duas classes, e avaliá-lo com os dados de teste, classificando cada *trial* entre uma das classes.

Neste trabalho, foi utilizado a função *fitdiscr* do MATLAB, em que realiza o LDA regularizado. Os dados seguem uma distribuição Gaussiana de média zero e desvio padrão um. Este método considera que o número de características é muito menor do que o número de *trials*.

3.2 Métodos

A proposta de implementação dos blocos de processamento de sinais da ICM está ilustrada na Figura 4.

Figura 4 – Proposta de processamento.



1. Dados EEG: Os dados que estudados foram retirados de uma base de dados descrita na Seção 3.2.1.
2. Pré-Processamento: Os dados são separados de acordo com o tipo do trecho (treinamento e avaliação) e pelo número do indivíduo. Nesta etapa foi realizada a segmentação dos sinais de acordo com os *single-trials*, e os mesmos foram filtrados utilizando um filtro passa-bandas de ordem 20 e frequência de passagem de 0.1 a 100 Hz. Além disso foi utilizado um filtro do tipo *notch* em 50 Hz para atenuar a influência da frequência da rede.
3. Extração de características: As técnicas implementadas foram o PSD, PLV e CSP, focando nas frequências de 8 a 12 Hz, 13 a 30 Hz, 8 a 30 Hz e as frequências relativas da banda alfa. Essas frequências foram escolhidas por abranger a banda alfa, beta e a combinação das duas. O estudo utilizou dois cenários com relação a série temporal, considerando de 0,5 a 3 segundos-625 amostras (Figura 5), correspondente a IM e o outro, tomando duas janelas, uma entre 0,5 e 1 segundo e em 3,5 e 4 segundos. Os resultados buscados seguem o padrão de estudo feito por (WANG et al., 2006). Estas técnicas foram escolhidas visando o objetivo deste trabalho, que é comparar a influência da fase dos sinais com as características espaciais e na potência.

4. Classificadores: Neste trabalho foi utilizado LDA. Como este estudo utilizou um paradigma multiclasse (4 classes), o método de realização deste bloco seguirá a metodologia de um vs resto: Classe 1 Vs Classe 2, Classe 1 Vs Classe 3, Classe 1 Vs Classe 4, Classe 2 Vs Classe 3, Classe 2 Vs Classe 4 e Classe 3 Vs Classe 4.

Neste trabalho, foram utilizados dois grupos de dados distintos, os dados de treinamento e os dados de teste. Os resultados obtidos foram obtidos através da criação de um modelo de classificação e foram utilizados os dados de teste para avaliar o modelo.

3.2.1 Base de dados

A base de dados (BRUNNER; LEEB, 2008) utilizada neste projeto consiste no registro de EEG de nove indivíduos saudáveis para quatro tarefas de imaginação de movimento (mão direita, mão esquerda, pés e língua). Os indivíduos foram orientados à IM de acordo com a direção das setas mostradas em um monitor:

- Seta para esquerda: IM da mão esquerda
- Seta para direita: IM da mão direita
- Seta para acima: IM dos pés
- Seta para abaixo: IM da língua

Cada indivíduo realizou 2 sessões (treinamento e validação), cada uma delas composta por 6 rodadas com 48 repetições por cada rodada, totalizando 288 repetições por sessão.

Tabela 3 – Descrição dos dados

| Indivíduos | Rodadas | Repetições | Total |
|------------|---------|------------|-------|
| 9 | 6 | 48 | 288 |

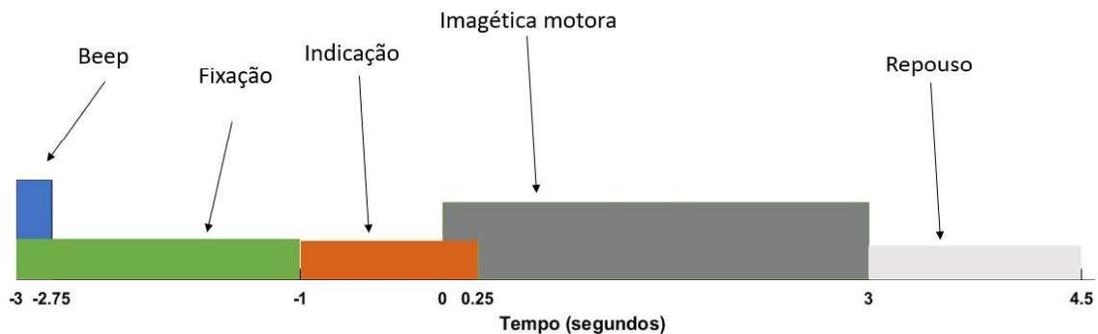
As coletas de sinais EEG foram realizadas com os indivíduos sentados de frente para uma tela. No início de cada sessão foram registrados aproximadamente 5 minutos de EOG para estimar a sua influência sobre o EEG. Em seguida, foi realizada a coleta do EEG propriamente dito, sendo que cada comando (seta) foi precedido por um sinal sonoro seguido de uma tela com um marcador de início, conforme ilustrado na Figura 5

Os sinais de EEG foram medidos por 22 eletrodos de Ag/AgCl espaçados de cerca de 3,5 cm. A Figura 6 indica a disposição dos eletrodos. A medição foi realizada com a referência na orelha esquerda e o terra na orelha direita. Os sinais foram amostrados a 250 Hz e filtrados com um filtro passa-banda de 0,5 a 100 Hz, além de um filtro notch na frequência da rede (50 Hz - Austria). Também foram registrados 3 canais para medir

Tabela 4 – Paradigma do processo de aquisição dos trechos

| Tempo(s) | Atividade |
|----------|------------------|
| 0 - 0.25 | Beep |
| 0 - 2 | Fixação |
| 2 - 3.25 | Indicação (seta) |
| 3 - 6 | Imagética motora |
| 6 - 7.5 | Repousar |

Figura 5 – Divisão temporal das atividades realizadas por trecho



Fonte: (BRUNNER; LEEB, 2008)

a influência do EOG (BRUNNER; LEEB, 2008). A disposição dos eletrodos segue um padrão 10/20.

Todos os trechos foram avaliados visualmente por especialistas para eliminar os trechos que continham artefatos e foram marcados para remoção. Para utilizar um número fixo de trechos por treinamento e teste, neste trabalho foi realizado uma contagem para saber qual era o menor número de trechos por classe. Assim, foram encontrados 49 trechos nas séries de treinamento e 53 na série de testes, ou seja, existem no mínimo 49 trechos sem artefatos em uma base e 53 na outra.

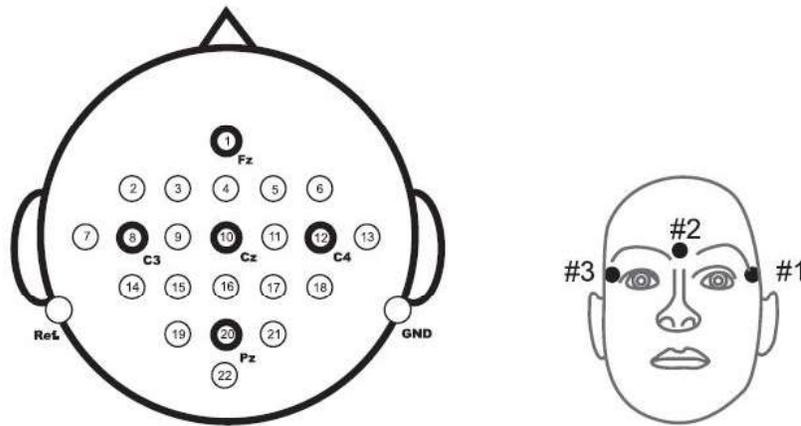
3.2.2 Extração de características

Todas as implementações foram realizadas no software MATLAB R2017a.

3.2.2.1 Características na fase

Na base de dados utilizada, os eletrodos foram aplicados seguindo a orientação 10/20, e foram demarcadas vinte e cinco derivações (BRUNNER; LEEB, 2008). Os eletrodos selecionados para o cálculo deste índice seguem um padrão neurofisiológico relacionados às regiões de estímulo cerebral ligadas as áreas que foram realizadas a imaginação, focando na área somática sensorial.

Figura 6 – Posicionamento dos eletrodos utilizados para a aquisição dos sinais de EEG e EOG



Fonte:(BRUNNER; LEEB, 2008)

Para este fim, foram propostas duas abordagens para o cálculo do PLV, uma local e outra global. A escala local é realizada tomando áreas adjacentes ao eletrodos calculado, levando em conta a região do estímulo. A escala global realizada a quantização do sincronismo entre diferente áreas cerebrais.

A Tabela 5 indica como que os eletrodos foram arranjados para o cálculo do PLV local.

| Eletrodo Central | Grupo de eletrodos |
|------------------|-----------------------|
| Fz | Fz, FC3, FCz, FC4 |
| FT7 | FT7, FC3, T7, C3 |
| FC3 | FC3, FT7, FCz, C1 |
| FCz | FCz, Fz, FC3, Cz, FC4 |
| FC4 | FC4, FCz, C2, FT8 |
| FT8 | FT8, FC4, C4, T8 |
| T7 | T7, TP7, C3, FT7 |
| C3 | C3, T7, TP7, C1, FT7 |
| C1 | C1, C3, CP3, Cz, FC3 |
| Cz | Cz, C1, CPz, C2, FCz |
| C2 | C2, Cz, CP4, C4, FC4 |
| C4 | C4, C2, TP8, T8, FT8 |
| T8 | T8, C4, TP8, FT8 |
| TP7 | TP7, CP3, C3, P3 |
| CP3 | CP3, TP7, P3, CPz, C1 |
| CPz | CPz, CP3, Pz, CP4, Cz |
| CP4 | CP4, CPz, P4, TP8, C2 |
| TP8 | TP8, CP4, P4, C4 |
| P3 | P3, TP7, Oz, Pz, CP3 |
| Pz | Pz, P3, Oz, P4, CPz |
| P4 | P4, Pz, Oz, TP8, CP4 |
| Oz | Oz, P3, Pz, P4 |

Tabela 5 – Designação dos eletrodos para o PLV local

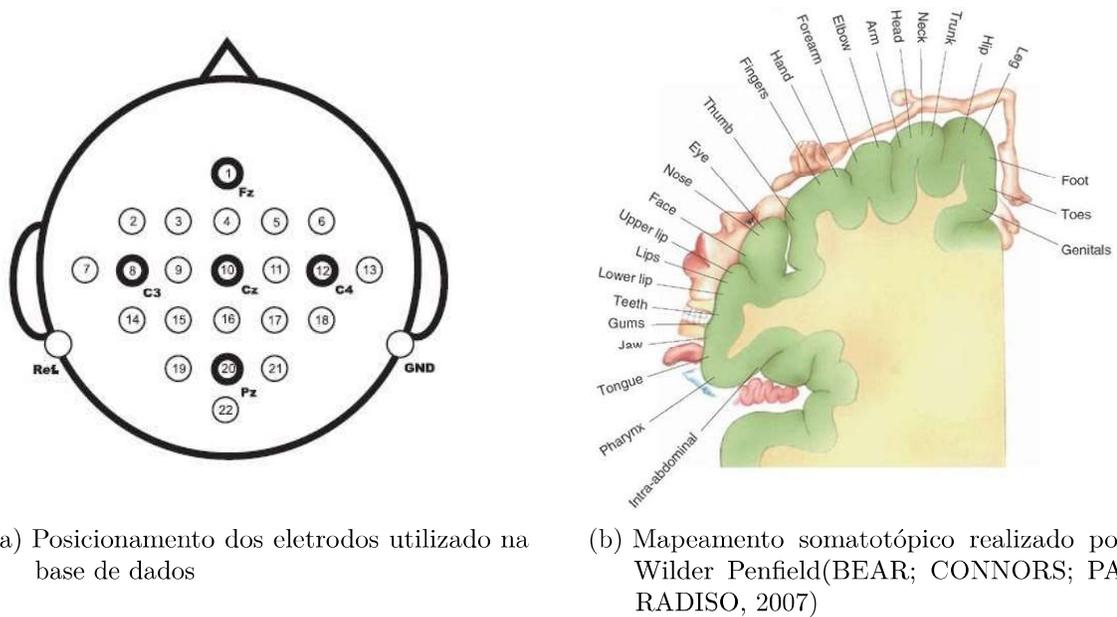
E a Tabela 4 está indicando quais eletrodos representaram as áreas cerebrais que foram relacionadas para o cálculo do PLV global.

| Classes | Grupo de Eletrodos |
|--------------|--------------------|
| Mão esquerda | FCz-C4 |
| Mão direita | FCz-C3 |
| Pé | FCz-Cz |
| Língua | Fcz-T7 e Fcz-T8 |

Tabela 6 – Designação dos eletrodos do PLV global

A Figura 7 indica como foram escolhidos os eletrodos para o cálculo do PLV local e global. Pode-se observar que, a região central do esta relacionado à estímulos nos pés, dedos e genitália, em contra-partida, a região temporal do cérebro está relacionada a boca e língua. Em relação a áreas relacionados com os estímulos nas mãos, os eletrodos C3 e C4 (WANG et al., 2006) são utilizados para este fim, sendo o C3 direcionado à mão direita e C4 e mão esquerda.

Os sinais de EEG foram previamente filtrados utilizando um filtro *Butterworth* de ordem 2 e em quatro frequências de passagem: 8 a 12 Hz, 13 a 30 Hz, 8 a 30 Hz e



(a) Posicionamento dos eletrodos utilizado na base de dados

(b) Mapeamento somatotópico realizado por Wilder Penfield (BEAR; CONNORS; PARADISO, 2007)

Figura 7 – Mapeamento somatotópico relacionando com a posição dos eletrodos

as frequências reativas para cada indivíduo e classe. Totalizando quatro experimentos diferentes.

3.2.2.2 Características na potência

Para este trabalho, as características relacionadas com as PSD's foram extraídas através da média dos valores de \hat{P} entre 8 e 13 Hz (Alfa), 13 a 30 Hz (Beta) e uma banda larga entre 8 e 30 Hz. De acordo com a série temporal relacionada com a medição da atividade, foram retirados 2,5 segundos de observação (625 amostras), que estavam contidos no período de 0,5 a 3 segundos. Este período corresponde à janela de IM (Figura 5 após os primeiros 500 ms). Os parâmetros utilizados no cálculo foram a janela de Hamming de tamanho $fs/2$, *overlapping* de 50%, N_{fft} de 250 e frequência de amostragem (fs) de 250 Hz.

Além disso, as PSD's foram utilizadas no cálculo das frequências reativas na banda alfa. Como a fisiologia dos indivíduos são diferentes, foi calculado um intervalo de frequências em que houve um maior aumento de potência nos eletrodos. Para isso, foi escolhido uma largura de banda de 5Hz centrada na frequência de que têm a maior amplitude do periodograma. Como os dados foram segmentados de acordo com a tarefa motora, a frequência reativa da classe mão esquerda estava relacionada com o eletrodo C4, mão direita com C3, pé com Cz e língua com T7 e T8. Assim, de acordo com a classe, foram encontradas as frequências reativas a partir destes eletrodos. Os parâmetros utilizados no cálculo das PSD's foram os mesmos, porém, foram estudados dois intervalos de tempo, o primeiro entre 0,5 a 1,5 segundos (250 amostras), onde houve a IM e de 3,5 a 4,5 segundos, período de relaxamento.

Em relação as características extraídas utilizando CSP, os sinais Z_P que maximizam a diferença de variância entre classes são dados pelas m primeiras e últimas linhas de Z . Para este trabalho, foi escolhido o $m = 2$. A matriz de característica foi calculada por:

$$f_p = \log \left(\frac{\text{var}(Z_p)}{\sum_{i=1}^{2m} \text{var}(Z_i)} \right) \quad (3.29)$$

3.2.2.3 Número de características

Considerando as técnicas de extração de características utilizadas neste trabalho, como PSD, PLV e CSP, a Tabela 7 indica a quantidade de características utilizadas na construção do modelo de classificação.

| Técnica | Número de Caract. | Eletrodos utilizados |
|------------|-------------------|--|
| PSD | 6 | Fz, T7, C3, Cz, C4, T8 |
| PLV Global | 5 | Fz-T7, Fz-C3, Fz-Cz, Fz-C4, Fz-T8, |
| PLV Local | 6 | Fz, T7, C3, Cz, C4, T8 |
| CSP | 4 | As duas maiores e as duas menores variâncias |

Tabela 7 – Quantidade de características utilizadas para geração do modelo de classificação

4 Resultados

Neste capítulo serão apresentados os resultados sobre as acurácias do classificador linear com as características de PSD, PLV, CSP e a sua combinação.

4.1 Análise espectral: Densidade espectral de potência

Na Figura 8 é apresentado o *grand average* da PSD (média dos 49 trechos para cada indivíduo) das 22 derivações coletadas em dois intervalos de 1s; primeiro no trecho onde foi realizada a IM da mão esquerda de 0.5s a 1,5s (vermelho) e posteriormente no intervalos de 3.5 a 4.5 s que representa o EEG de fundo (azul). Pode-se observar que em todas as derivações houve uma diminuição de potência principalmente na banda alfa quando a IM foi realizada comparada com o repouso. Este fenômeno foi encontrado para as outras IM (mão direita, língua e pé).

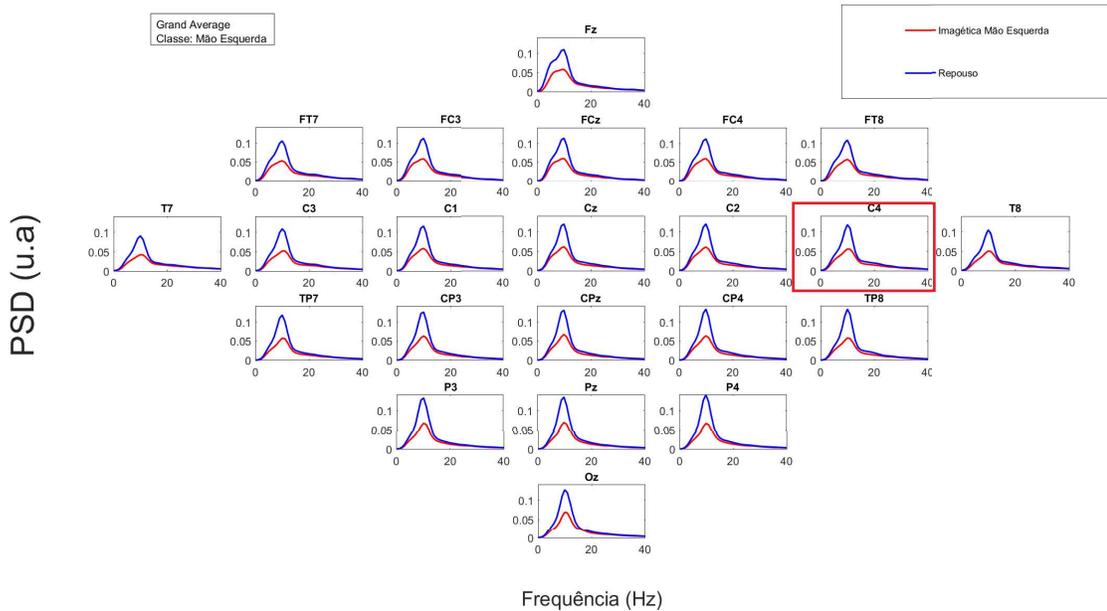


Figura 8 – Densidade espectral de potência - Método de Grand Average - Classe Mão Esquerda

A Tabela 8 mostra as bandas de frequências selecionadas como frequências reativas para cada sujeito. A escolha destas frequências foi baseada no ponto máximo (frequência central) da PSD da IM para cada classe com lagura de banda de 4 Hz (frequência central ± 2 Hz).

| Indivíduo | Mão Esquerda | Mão Direita | Pé | Língua |
|-----------|--------------|-------------|----------|----------|
| 1 | 10-14 Hz | 10-14 Hz | 9-13 Hz | 10-14 Hz |
| 2 | 9-13 Hz | 9-13 Hz | 9-13 Hz | 9-13 Hz |
| 3 | 9-13 Hz | 10-14 Hz | 9-13 Hz | 10-14 Hz |
| 4 | 11-15 Hz | 6-10 Hz | 6-10 Hz | 6-10 Hz |
| 5 | 6-10 Hz | 6-10 Hz | 6-10 Hz | 6-10 Hz |
| 6 | 8-12 Hz | 8-12 Hz | 8-12 Hz | 8-12 Hz |
| 7 | 9-13 Hz | 10-14 Hz | 10-14 Hz | 10-14 Hz |
| 8 | 9-13 Hz | 9-13 Hz | 9-13 Hz | 9-13 Hz |
| 9 | 9-13 Hz | 9-13 Hz | 8-12 Hz | 9-13 Hz |

Tabela 8 – Bandas de frequências reativas em Hz

4.2 Análise temporal: Índice de acoplamento de fase (PLV)

O PLV global, nomeado a partir deste momento somente como PLV, é mostrado na Figura 9. Os valores do grand average do PLV são mostrados para T7, C3, Cz, C4, e T8 relacionados com Fz para as 4 classes. Pode-se observar que estes valores são superiores a 0,5 para todas as classes. O padrões são similares para todas as IM, mas as principais diferenças são mostradas na relação entre C3 e C4.

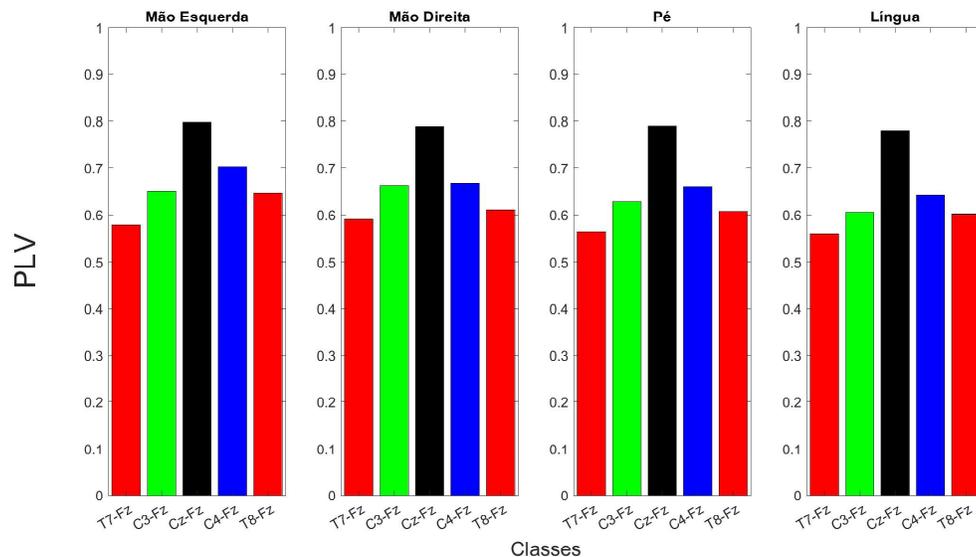


Figura 9 – Grand average do PLV por classes e pares de eletrodos

4.3 Comparação de acurácia: 8 a 30 Hz vs. Frequências reativas

Como mencionado na metodologia (Seção 3), foram realizados experimentos utilizando as técnicas de extração de características: PSD, PLV, CSP, para quatro faixas de frequências, sendo elas de 8 a 12 Hz, 13 a 30 Hz, 8 a 30 Hz e as frequências reativas (Tabela 8). Assim, as técnicas de PSD, PLV e CSP foram utilizadas de forma individual e

combinadas, para a criação do modelo e classificação dos dados de teste.

Os melhores resultados para classificação foram obtidos para as faixas de 8-30 Hz e para as frequências reativas. Os resultados mostrados nas Figuras 10-14 ilustram a comparação em *boxplots* da acurácia de classificação das 6 combinações para discriminação binária das diferentes técnicas de extração de características para os 9 sujeitos.

A Figura 10 indica os valores de acurácia encontrados utilizando as características extraídas com as PSD's e com o classificador linear. Foram utilizadas as médias dos periodogramas dentro do intervalo estudo, no caso, 8 a 30 Hz e as frequências reativas (Tabela 8). Como esperado baseado na literatura, os valores obtidos foram inferiores às demais técnicas estudadas. Os valores das taxas de acerto em termos de mediana são similares ou superiores para a banda de 8-30 Hz.

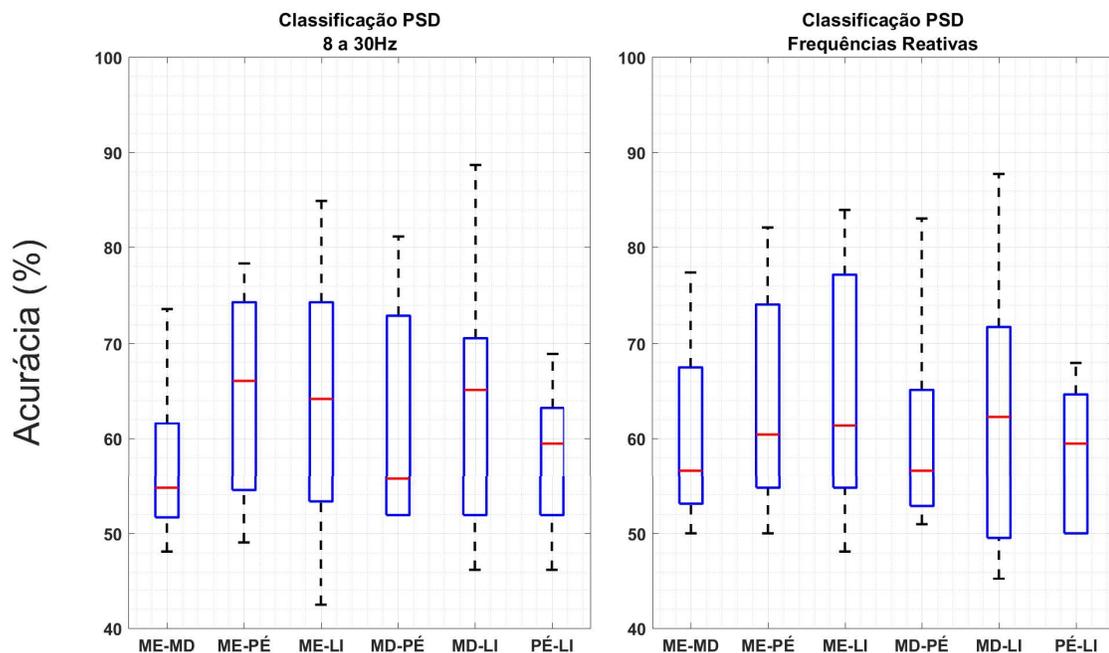


Figura 10 – Comparação da classificação utilizando as PSD's entre 8 a 30 Hz e as frequências reativas

A Figura 11 compara os valores da mediana, máximo e mínimos, entre os valores de 8-30 Hz e frequências reativas para PLV;

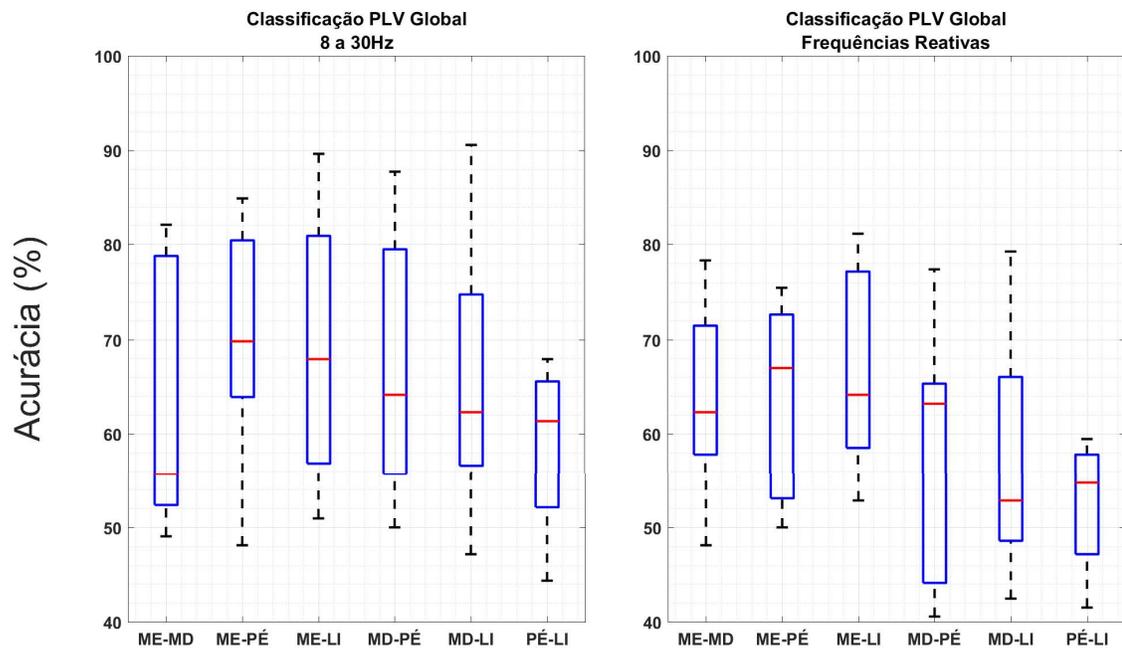


Figura 11 – Comparação da classificação utilizando PLV entre 8 a 30 Hz e as frequências reativas

A Figura 12 compara os valores da mediana, máximo e mínimos, entre os valores de 8-30 Hz e frequências reativas para a combinação de PLV e PSD.

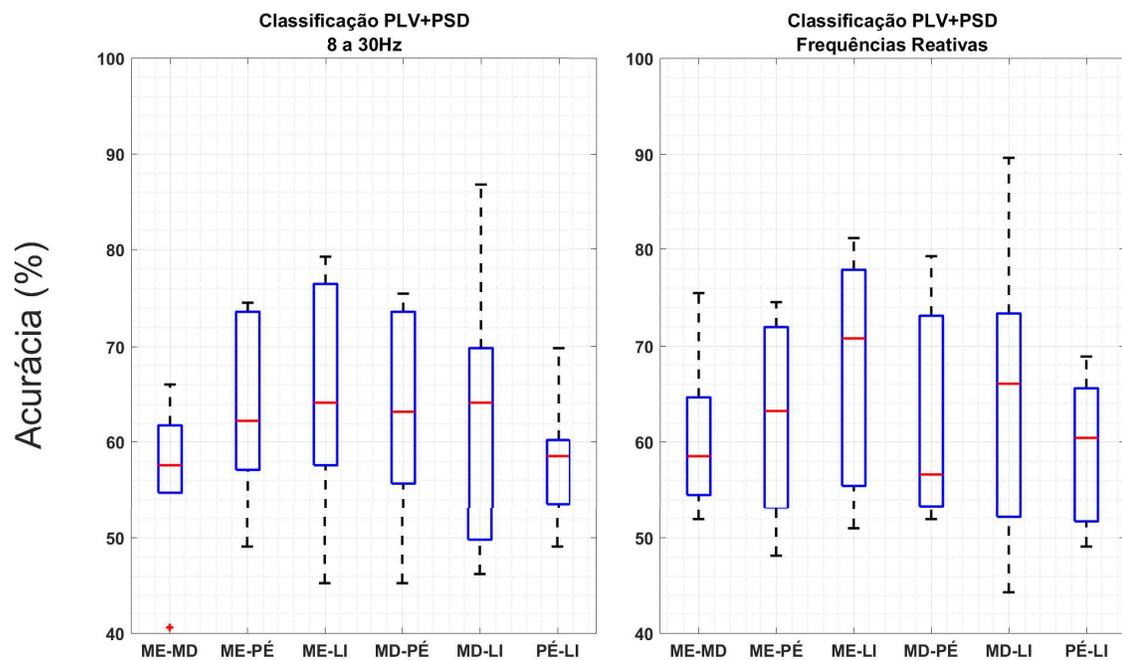


Figura 12 – Comparação da classificação utilizando as PSD's e o PLV Global entre 8 a 30 Hz e as frequências reativas

A Figura 13 compara os valores da mediana, máximo e mínimos, entre os valores de 8-30 Hz e frequências reativas para CSP.

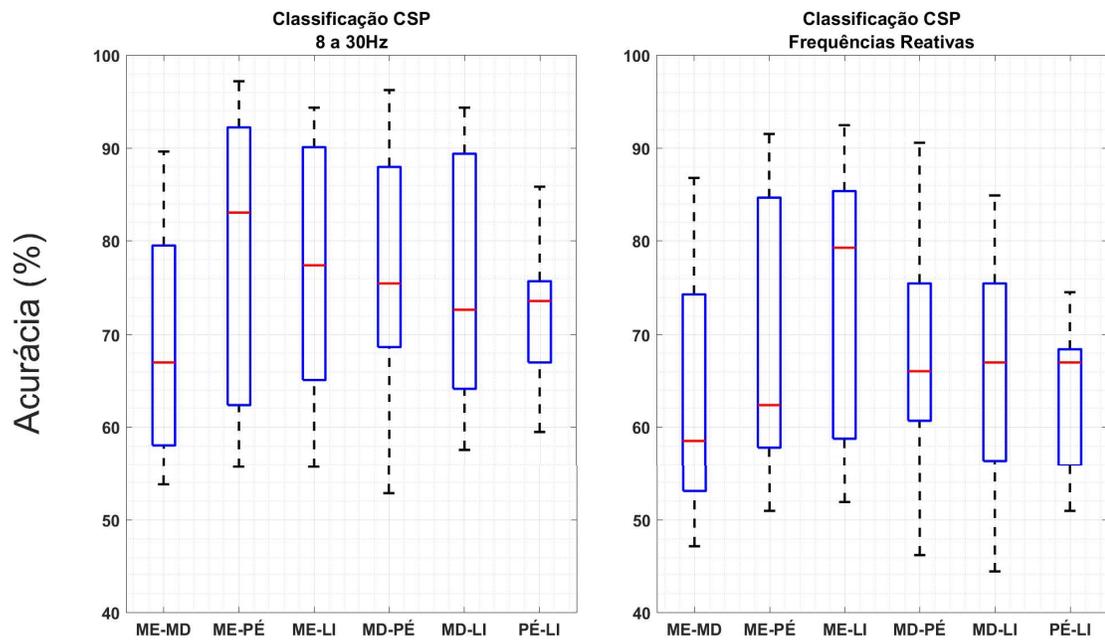


Figura 13 – Comparação da classificação utilizando CSP entre 8 a 30 Hz e as frequências reativas

A Figura 14 compara os valores da mediana, máximo e mínimos, entre os valores de 8-30 Hz e frequências reativas para a combinação de CSP e PLV.

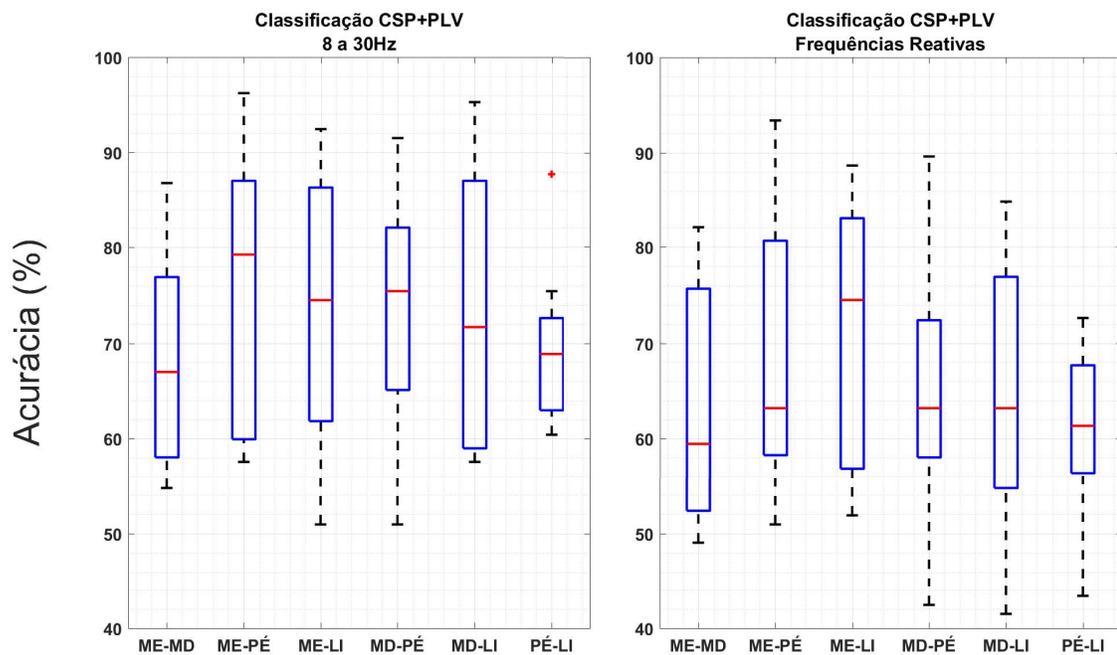


Figura 14 – Comparação da classificação utilizando CSP e o PLV GLocal, entre 8 a 30 Hz e as frequências reativas

A Tabela 9 mostra a média dos valores de acurácia das 6 classificações de cada sujeito tanto para a banda de 8-30 Hz e das frequências reativas para cada técnica de extração de características utilizada. A pesar da variabilidade entre os sujeitos, destaca-

se que os valores da média são superiores para a faixa de frequência de 8-30Hz (0.67) comparado para a média das frequências reativas (0.63). Comparando os valores por técnicas, os valores da média para a faixa de 8-30 Hz em ordem decendente são: CSP (0,75), CSP+PLV (0,72), PLV (0,65), PSD+PLV (0,62) e PSD (0,62).

| | 8 – 30 Hz | | | | | Frequências reativas | | | | |
|----------------------|------------------|------|------|-------------|------|----------------------|-------------|------|-------------|-------------|
| | PSD | PLV | CB1 | CSP | CB2 | PSD | PLV | CB1 | CSP | CB2 |
| S1 | 0.66 | 0.77 | 0.68 | 0.86 | 0.85 | 0.71 | 0.71 | 0.70 | 0.83 | 0.81 |
| S2 | 0.57 | 0.62 | 0.52 | 0.75 | 0.73 | 0.50 | 0.55 | 0.52 | 0.56 | 0.54 |
| S3 | 0.74 | 0.80 | 0.72 | 0.90 | 0.86 | 0.77 | 0.61 | 0.75 | 0.84 | 0.81 |
| S4 | 0.48 | 0.58 | 0.57 | 0.67 | 0.65 | 0.55 | 0.62 | 0.60 | 0.54 | 0.53 |
| S5 | 0.52 | 0.52 | 0.55 | 0.56 | 0.56 | 0.51 | 0.5 | 0.5 | 0.54 | 0.55 |
| S6 | 0.58 | 0.55 | 0.53 | 0.60 | 0.58 | 0.55 | 0.50 | 0.55 | 0.58 | 0.57 |
| S7 | 0.69 | 0.64 | 0.70 | 0.81 | 0.77 | 0.60 | 0.61 | 0.64 | 0.72 | 0.69 |
| S8 | 0.59 | 0.66 | 0.61 | 0.75 | 0.72 | 0.63 | 0.66 | 0.64 | 0.71 | 0.67 |
| S9 | 0.68 | 0.73 | 0.64 | 0.82 | 0.79 | 0.71 | 0.65 | 0.67 | 0.72 | 0.72 |
| μ | 0.61 | 0.65 | 0.61 | 0.75 | 0.72 | 0.61 | 0.60 | 0.62 | 0.67 | 0.65 |
| $\sigma^2 * 10^{-2}$ | 0.70 | 0.80 | 0.50 | 1.20 | 1.00 | 0.80 | 0.50 | 0.70 | 1.20 | 1.10 |
| μ_{geral} | 0.67 | | | | | 0.63 | | | | |
| σ_{geral}^2 | $7.2 * 10^{-06}$ | | | | | 10^{-5} | | | | |

Tabela 9 – Média dos valores de acurácia das 6 combinações de classificação binária de cada sujeito para cada técnica de extração de características utilizada nas bandas de frequências de 8-30 Hz e para as frequências reativas. **CB1*** é a combinação de PSD e PLV, e **CB2*** é a combinação de CSP e PLV. Em negrito estão os maiores valores encontrados para cada indivíduo.

A Tabela 10 indica a média dos valores de acurácia das 5 combinações de técnicas de extração de características de cada sujeito tanto para a banda de 8-30 Hz e das frequências reativas para cada classificação binária. Da mesma que na tabela 6, os valores foram superiores para a banda de 8-30 Hz (0.67) comparado com as frequências reativas (0.63). Os valores da classificação entre as classes foram similares (aproximadamente 0.7), somente as classe ME-MD (0.63) e PE-LI (0,63) tiveram valores inferiores.

4.4 Acurácias por indivíduo para cada combinação de características

Os valores de acurácia para a banda de 8-30 Hz foram superiores, comparadas com os valores obtidos nas frequências reativas. As Figuras 15-20 mostram os valores por indivíduo para cada classificação binária: MD-LI (Figura 15), MD-PÉ (Figura 16), ME-LI (Figura 17), ME-MD (Figura 18), ME-PÉ (Figura 19) e PÉ-LI (Figura 20). Para todas as figuras, observa-se que existe uma variabilidade entre indivíduo e entre técnicas, mas com uma tendência das maiores obtidos para CSP (padrão ouro).

| | | S1 | S2 | S3 | S4 | S5 | S6 | S7 | S8 | S9 | μ | VM | μG | VG |
|----------|-------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|------|---------|------|
| 8 a 30Hz | ME-MD | 0.62 | 0.54 | 0.79 | 0.58 | 0.55 | 0.52 | 0.57 | 0.72 | 0.73 | 0.62 | 0.90 | 0.67 | 2.85 |
| | ME-PÉ | 0.83 | 0.70 | 0.85 | 0.63 | 0.54 | 0.56 | 0.78 | 0.60 | 0.80 | 0.70 | 1.40 | | |
| | ME-LI | 0.82 | 0.56 | 0.80 | 0.62 | 0.54 | 0.56 | 0.75 | 0.70 | 0.88 | 0.69 | 1.60 | | |
| | MD-PÉ | 0.83 | 0.73 | 0.85 | 0.61 | 0.51 | 0.59 | 0.76 | 0.64 | 0.59 | 0.68 | 1.40 | | |
| | MD-LI | 0.83 | 0.56 | 0.88 | 0.56 | 0.55 | 0.57 | 0.77 | 0.67 | 0.74 | 0.68 | 1.70 | | |
| | PÉ-LI | 0.63 | 0.70 | 0.63 | 0.54 | 0.56 | 0.60 | 0.69 | 0.67 | 0.65 | 0.63 | 0.30 | | |
| F.R | ME-MD | 0.66 | 0.50 | 0.77 | 0.63 | 0.52 | 0.54 | 0.54 | 0.72 | 0.69 | 0.62 | 0.90 | 0.63 | 1.80 |
| | ME-PÉ | 0.81 | 0.52 | 0.79 | 0.64 | 0.50 | 0.57 | 0.70 | 0.60 | 0.72 | 0.65 | 1.30 | | |
| | ME-LI | 0.82 | 0.54 | 0.79 | 0.69 | 0.51 | 0.56 | 0.69 | 0.70 | 0.82 | 0.68 | 1.40 | | |
| | MD-PÉ | 0.81 | 0.58 | 0.81 | 0.47 | 0.51 | 0.55 | 0.62 | 0.67 | 0.59 | 0.62 | 1.40 | | |
| | MD-LI | 0.79 | 0.55 | 0.77 | 0.45 | 0.52 | 0.51 | 0.69 | 0.64 | 0.68 | 0.62 | 1.40 | | |
| | PÉ-LI | 0.61 | 0.49 | 0.59 | 0.50 | 0.54 | (0.57) | 0.65 | 0.64 | 0.65 | 0.58 | 0.40 | | |

Tabela 10 – Média dos valores de classificação para comparação dos paradigmas em uma abordagem Um vs Resto, para 8 a 30 Hz e frequências reativas. Em negrito estão os maiores valores encontrados para cada indivíduo. μG é a média geral, VM é a variância multiplicada por 10^{-2} , VG é a variância geral multiplicada por 10^{-5} e FR são as frequências reativas

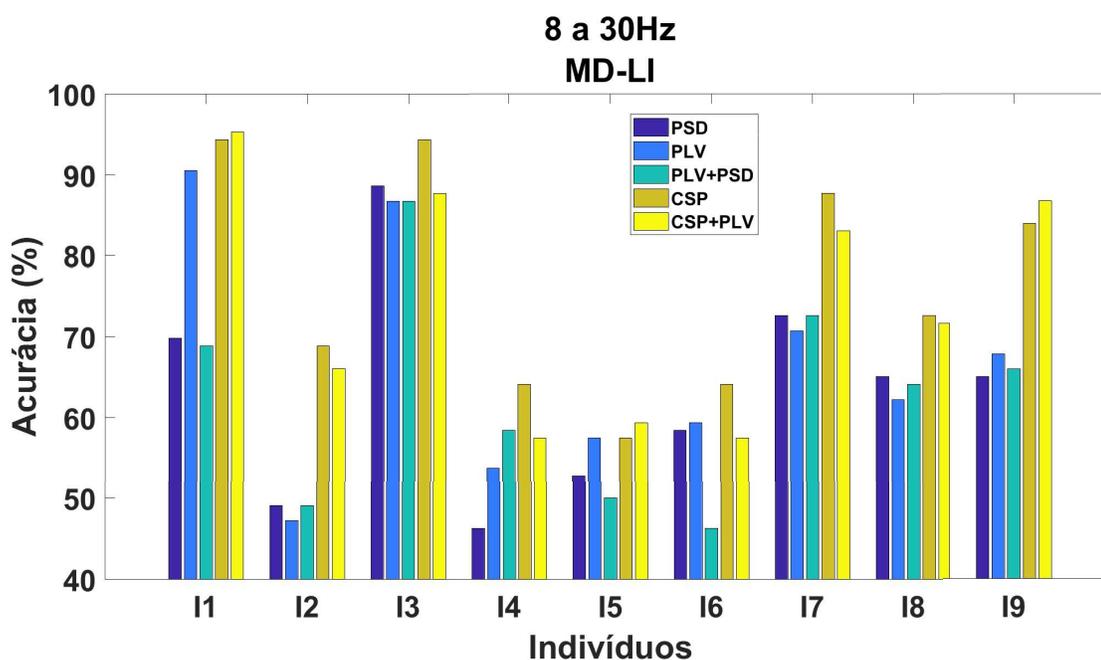


Figura 15 – Valores de Acurácia no paradigma Mão Direita-Língua de 8 a 30 Hz

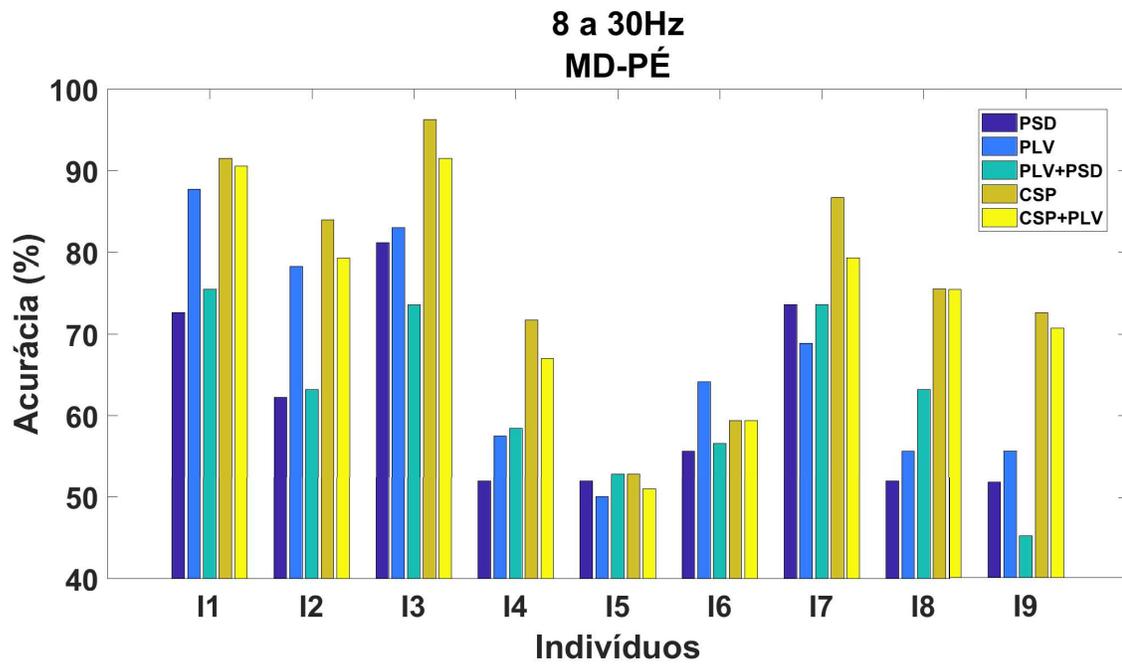


Figura 16 – Valores de Acurácia no paradigma Mão Direita-Pé de 8 a 30 Hz

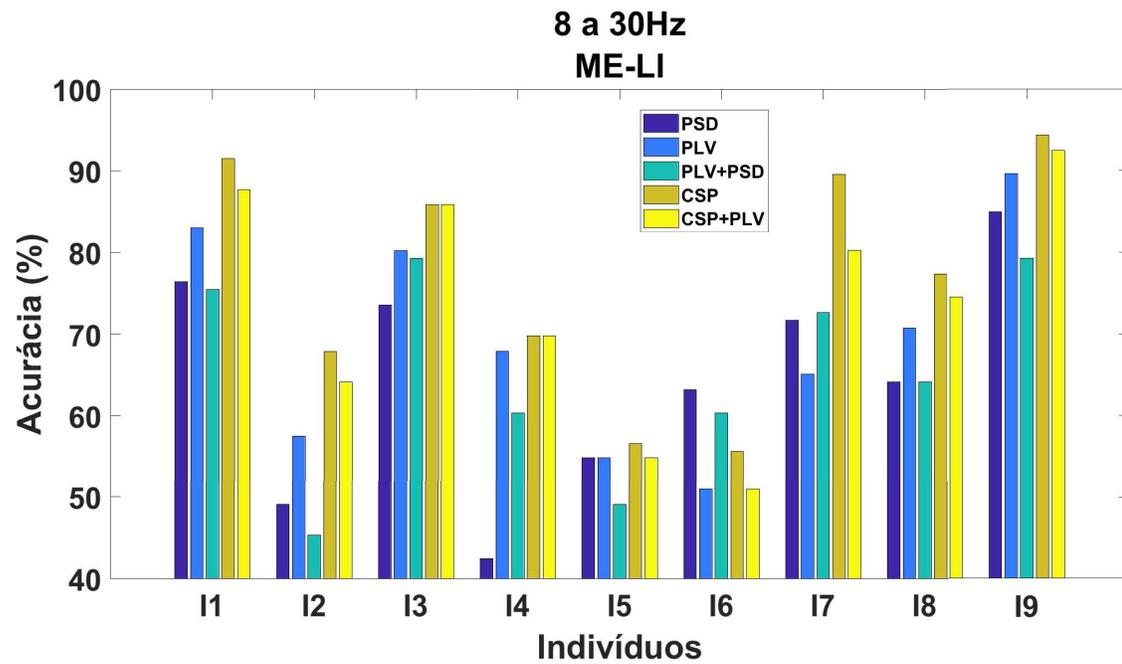


Figura 17 – Valores de Acurácia no paradigma Mão Esquerda-Língua de 8 a 30 Hz

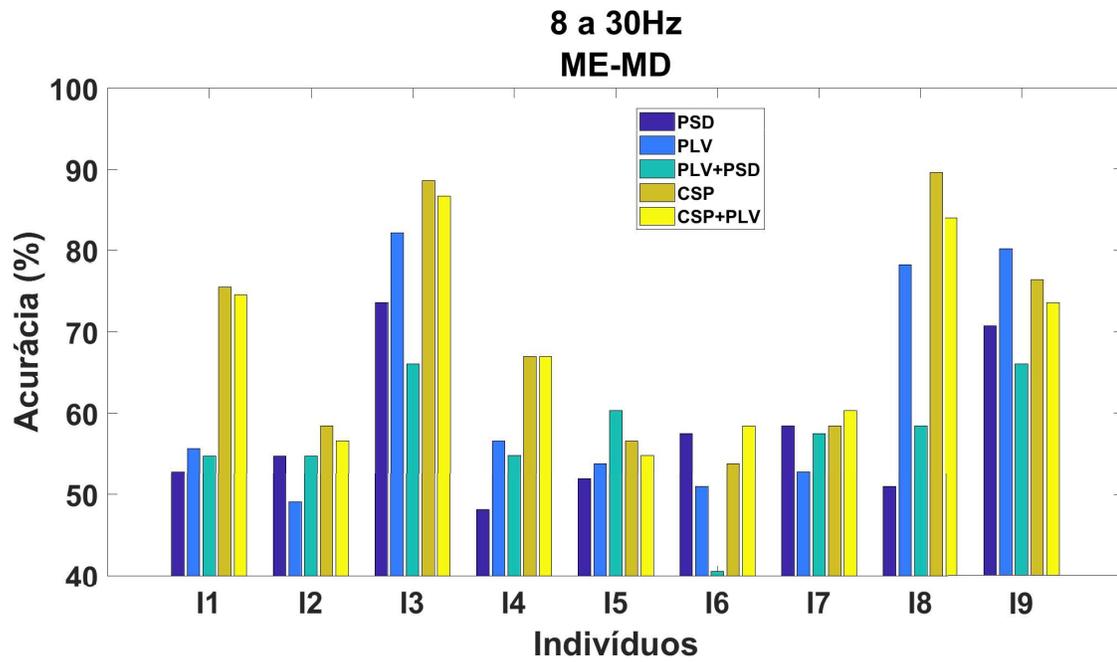


Figura 18 – Valores de Acurácia no paradigma Mão Esquerda-Mão Direita de 8 a 30 Hz

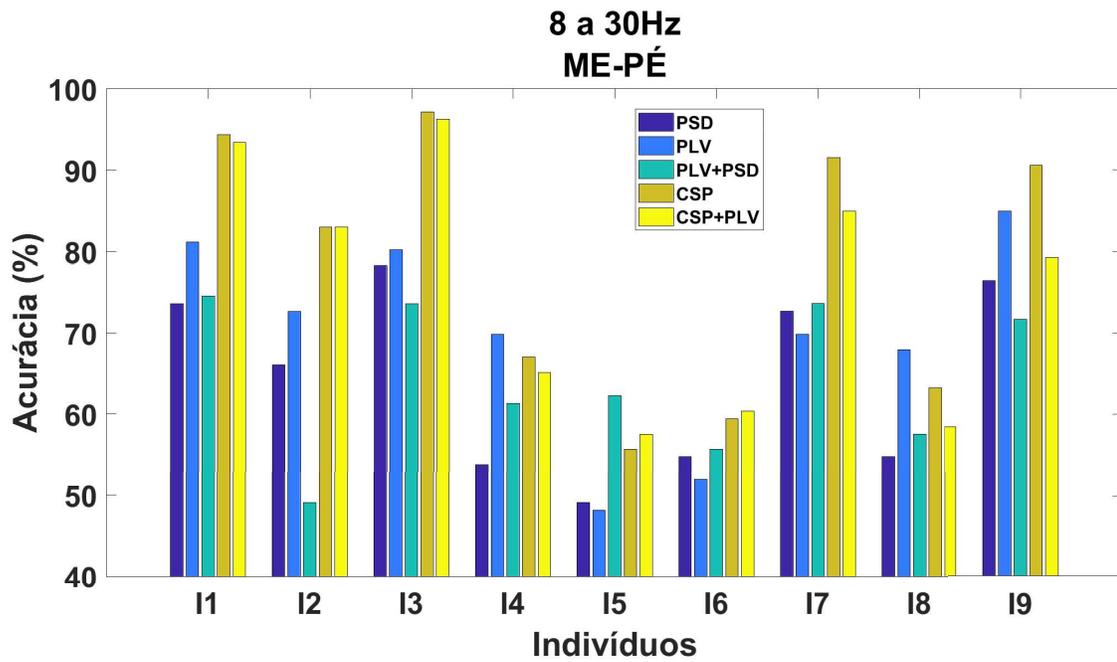


Figura 19 – Valores de Acurácia no paradigma Mão Esquerda-Pé de 8 a 30 Hz

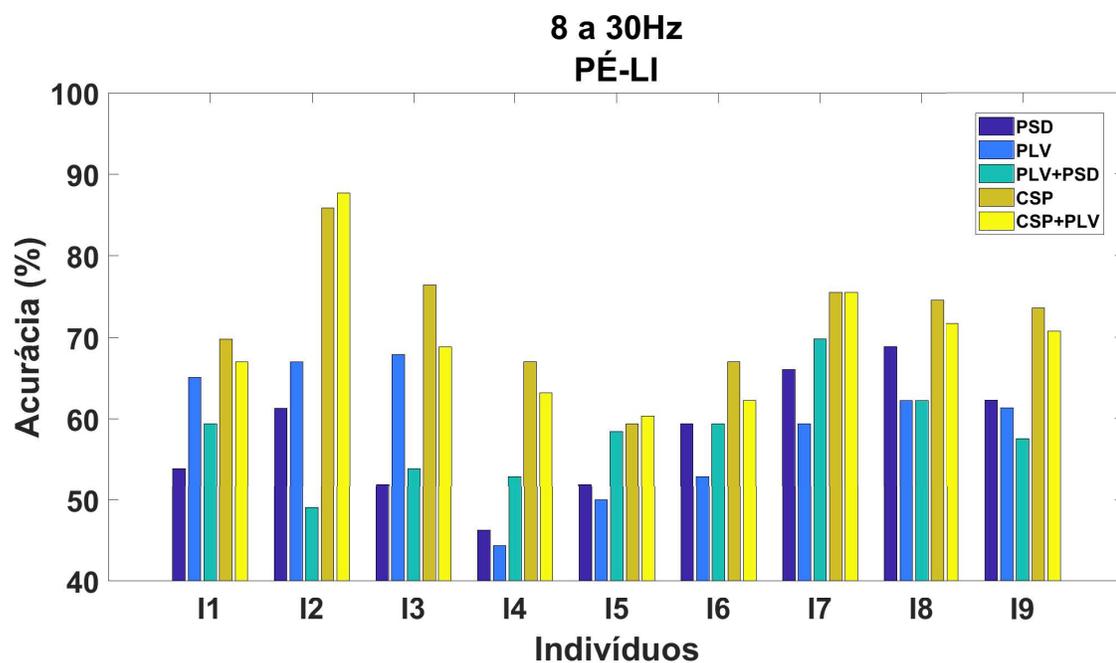


Figura 20 – Valores de Acurácia no paradigma Pé-Língua de 8 a 30 Hz

5 Discussão e conclusão

Como as respostas motoras tem variabilidade inter-eletrodo e inter-indivíduo (PFURTSCHELLER et al., 1997), as frequências reativas foram calculadas para avaliar o desempenho dos sinais filtrados nestas faixas de frequência. Os valores de acurácia de classificação foram superiores (Tabelas 7-8) na faixa de 8-30 Hz comparado quando as frequências reativas foram empregadas. Estes resultados podem ser explicados porque neste estudo foi utilizado exclusivamente a banda alfa e poderia ser um indicativo que a banda beta também é importante para a classificação.

Neste estudo foi utilizado somente o PLV global porque não houve um aumento ou um padrão quando foi utilizado o PLV local. Este fenômeno sugere que a relação de fase para discriminação é melhor quando se compara a área relacionada com a IM no cortex motor primário e com a área motora suplementar.

CSP foi a técnica que ofereceu os melhores resultados de acurácia do classificador. Este resultado já era esperado devido que CSP é uma técnica multivariada que otimiza a discriminação da potência entre duas classes. As características de fase (PLV) se mostraram um pouco superiores comparadas com as características de potência (PSD). Este resultado sugere a importância da fase para realizar a discriminação de diferentes IMs.

A combinação das características de fase e potência não ofereceram uma melhora na discriminação das diferentes classificações binárias. Apesar deste resultado, novos testes deverão ser realizados utilizando diferentes faixas de frequência e intervalos de tempos. Neste estudo foram utilizadas um número pequeno de características, o que sugere um trabalho futuro com maiores características, a utilização de algoritmos de seleção de características e classificadores não lineares.

5.0.1 Trabalhos futuros

Diante de algumas características deste trabalho foi constatado alguns pontos podem ser alterados para testar alguns cenários, como: janela de tempo variável, tanto a largura quanto na série temporal, adição de frequências reativas na banda beta, utilizar um maior número de características e um seletor de características.

Referências

- ALIAKBARYHOSSEINABADI, S. et al. Detection of movement intention from movement-related cortical potentials with different paradigms. *Biosystems and Biorobotics*, v. 7, n. 6, p. 237–244, 2014. ISSN 21953570. 4
- Aydın, Ü., Doğan, R., Ortaç, F. E. Sivrihisar-Beyşehir-Afyon Civarı Magitlerin Jeolojisi ve Birbiri ile İlişkileri. *Doğal Kay. ve Eko. Bült.*, v. 21, n. 2, p. 105–116, 2016. ISSN 0018-9278. 16
- BEAR, M. F.; CONNORS, B. W.; PARADISO, M. a. C. N. M. L. S. L. T. F. W. L. . B. . F. C.-R. A. T. S. D. V. L. S. L. Q. P. . B. . P. & P. L. C. . R. C.-R. H. i. L. O. V. L. Neuroscience : exploring the brain. p. 36–37, 2007. 6, 11, 25
- BRACEWELL, R. The Hilbert Transform. *The Fourier Transform and Its Applications*, p. 267–272, 1999. 16
- BRUNNER, C.; LEEB, R. BCI Competition 2008 – Graz data set A. *Knowledge Creation Diffusion Utilization*, p. 1–6, 2008. ISSN 1662-4548. 6, 1, 7, 21, 22, 23
- CHOU, L. J. et al. ECS Transactions: Preface. *Low-Dimensional Nanoscale Electronic and Photonic Devices 4 - 218th ECS Meeting, October 10, 2010 - October 15, 2010*, v. 33, n. 9, p. iii–iii, 2010. ISSN 08898545. 19
- FALZON, O.; CAMILLERI, K. P. An algorithm for brain computer interfacing based on phase synchronization spatial patterns. *3rd International Conference on Advanced Engineering Computing and Applications in Sciences, ADVCOMP 2009*, p. 142–147, 2009. 13
- GYSELS, E.; CELKA, P. “Phase synchronization for the recognition of mental tasks in a brain-computer interface., ” {IEEE} {Transactions} on {Neural} {Systems} and {Rehabilitation} {Engineering}. v. 12, n. 4, p. 406–415, 2004. 13
- HÖHNE, J. et al. Motor imagery for severely motor-impaired patients: Evidence for brain-computer interfacing as superior control solution. *PLoS ONE*, v. 9, n. 8, 2014. ISSN 19326203. 4, 5
- HSU, W.-Y. Single-Trial Motor Imagery Classification Using Asymmetry Ratio, Phase Relation, Wavelet-Based Fractal, and Their Selected Combination. *International Journal of Neural Systems*, v. 23, n. 02, p. 1350007, 2013. ISSN 0129-0657. Disponível em: <<http://www.worldscientific.com/doi/abs/10.1142/S012906571350007X>>. 13
- HU, J.; MU, Z.; WANG, J. Phase Locking Analysis of Motor Imagery in Brain-Computer Interface. *2008 International Conference on BioMedical Engineering and Informatics*, p. 478–481, 2008. Disponível em: <<http://ieeexplore.ieee.org/document/4549219/>>. 13
- IRU, R. et al. Common spatial pattern method for channel selection in motor imagery based BCI. *Engineering In Medicine And Biology*, v. 5, p. 5392–5395, 2005. ISSN 1557-170X. Disponível em: <http://ieeexplore.ieee.org/xpls/abs{_}all.jsp?arnumber=1615>. 17

- JELLINGER, K. A. *Toward Brain-Computer Interfacing*. [s.n.], 2009. v. 16. e52–e52 p. ISSN 13515101. ISBN 9780262042444. Disponível em: <<http://doi.wiley.com/10.1111/j.1468-1331.2008.02463.x>>. 6
- JIANG, L. et al. Motor imagery controlled wheelchair system. *Proceedings of the 2014 9th IEEE Conference on Industrial Electronics and Applications, ICIEA 2014*, p. 532–535, 2014. 8
- JOCHUMSEN, M. et al. Comparison of spatial filters and features for the detection and classification of movement-related cortical potentials in healthy individuals and stroke patients. *Journal of Neural Engineering*, IOP Publishing, v. 12, n. 5, p. 56003, 2015. ISSN 17412552. Disponível em: <<http://dx.doi.org/10.1088/1741-2560/12/5/056003>>. 1
- 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*, v. 34, n. 4, p. 1600–1611, 2007. ISSN 10538119. 10
- LACHAUX, J.-P. et al. Measuring phase synchrony in brain signals. *Human brain mapping*, v. 8, n. 4, p. 194–208, 1999. 1, 15
- PFURTSCHELLER, G.; LOPES, F. H. Event-related EEG / MEG synchronization and desynchronization : basic principles. *Clinical Neurophysiology*, v. 110, p. 1842–1857, 1999. ISSN 1388-2457. 5
- PFURTSCHELLER, G.; NEUPER, C.; BIRBAUMER, N. *Human Brain-Computer Interface*. [S.l.: s.n.], 2005. 1–35 p. ISBN 0849312876. 6
- PFURTSCHELLER, G. et al. EEG based discrimination between imagination of right and left hand movement. *Electroencephalography and clinical Neurophysiology*, v. 103, p. 642–651, 1997. 1, 9, 12, 37
- PIERSOL, J. S. B.; G, A. Random Data Analysis and Measurement Procedures. *Measurement Science and Technology*, v. 11, n. 12, p. 1825–1826, dec 2000. ISSN 0957-0233. Disponível em: <<http://www.iop.org/EJ/abstract/0957-0233/11/12/702http://stacks.iop.org/0957-0233/11/i=12/a=702?key=crossref.2f2a7be5bc7263abd4b3de92000b0aca>>. 16
- QURESHI, M. N. I.; CHO, D.; LEE, B. EEG classification for motor imagery BCI using phase-only features extracted by independent component analysis. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, p. 2097–2100, 2017. ISSN 1557170X. 13
- RAMOSER, H. et al. Optimal spatial filtering of single-trial EEG during imagined hand movement. *IEEE Trans. Rehabil. Eng.*, v. 8, n. 4, p. 441 ST — Optimal spatial filtering of single—tri, 2000. ISSN 10636528. Disponível em: <<http://dx.doi.org/10.1109/86.895946>>. 1, 12, 17, 18
- SAMUEL, O. W. et al. Motor Imagery Classification of Upper Limb Movements Based on Spectral Domain Features of EEG Patterns. *Engineering in Medicine and Biology Society (EMBC), 39th Annual International Conference of the IEEE*, p. 2976–2979, 2017. 8
- SELLERS, E. W.; DONCHIN, E. A P300-based brain-computer interface: Initial tests by ALS patients. *Clinical Neurophysiology*, v. 117, n. 3, p. 538–548, 2006. ISSN 13882457. 8

TRANS CRANIAL TECHNOLOGIES. *10/20 System Positioning*. 2410 Fortis Tower, 77-79 Gloucester Road, Wanchai, Hong Kong, 2012. 6, 10

WANG, Y. et al. Phase synchrony measurement in motor cortex for classifying single-trial EEG during motor imagery. *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, p. 75–78, 2006. ISSN 05891019. 1, 13, 15, 20, 24

WANG, Y. et al. Adaptive estimation of EEG for subject-specific reactive band identification and improved ERD detection. *Neuroscience Letters*, Elsevier Ireland Ltd, v. 528, n. 2, p. 137–142, 2012. ISSN 03043940. Disponível em: <<http://dx.doi.org/10.1016/j.neulet.2012.09.001>>. 9

WOLPAW, J. R. et al. Brain Computer Interfaces for communication and control. *Frontiers in Neuroscience*, v. 4, n. 113, p. 767–791, 2002. ISSN 1388-2457. 6, 4, 5, 9

WU, W. et al. Classifying single-trial EEG during motor imagery by iterative spatio-spectral patterns learning (ISSPL). *IEEE Transactions on Biomedical Engineering*, v. 55, n. 6, p. 1733–1743, 2008. ISSN 00189294. 12

YI, W. et al. EEG oscillatory patterns and classification of sequential compound limb motor imagery. *Journal of NeuroEngineering and Rehabilitation*, Journal of NeuroEngineering and Rehabilitation, v. 13, n. 1, p. 11, 2016. ISSN 1743-0003. Disponível em: <<http://www.jneuroengrehab.com/content/13/1/11>>. 1, 9

YU, T. et al. Enhanced Motor Imagery Training Using a Hybrid BCI with Feedback. *IEEE Transactions on Biomedical Engineering*, v. 62, n. 7, p. 1706–1717, 2015. ISSN 15582531. 12

ANEXO A – Competição de ICM

IV:Resultados

| #. contributor | kappa | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | research lab | co-contributors |
|------------------|-------------|------|------|------|------|------|------|------|------|------|---|---|
| 1. Kai Keng Ang | 0.57 | 0.68 | 0.42 | 0.75 | 0.48 | 0.40 | 0.27 | 0.77 | 0.75 | 0.61 | Institute for Infocomm Research, Agency for Science, Technology and Research Singapore | Zheng Yang Chin, Chuanchu Wang, Cuntai Guan, Haihong Zhang, Kok Soon Phua, Drahim I lamadicharef, Keng Peng Tee |
| 2. Liu Guangquan | 0.52 | 0.69 | 0.34 | 0.71 | 0.44 | 0.16 | 0.21 | 0.66 | 0.73 | 0.69 | School of Mechanical Engineering, Shanghai Jiao Tong University, China | Huang Gan, Zhu Xiangyang |
| 3. Wei Song | 0.31 | 0.38 | 0.18 | 0.48 | 0.33 | 0.07 | 0.14 | 0.29 | 0.49 | 0.44 | College of Information Science and Technology, Beijing Normal University, China and National Key Laboratory for Cognitive Neuroscience and Learning, Beijing Normal University, China | Jin Wu, Jiakai Zhang |
| 4. Damien Coyle | 0.30 | 0.46 | 0.25 | 0.65 | 0.31 | 0.12 | 0.07 | 0.00 | 0.46 | 0.42 | Intelligent Systems Research Centre, School of Computing and Intelligent Systems, Faculty of Computing and Engineering, Magee Campus, University of Ulster, UK | Abdul Satti, Martin McGinnity |
| 5. Jin Wu | 0.29 | 0.41 | 0.17 | 0.39 | 0.25 | 0.06 | 0.16 | 0.34 | 0.45 | 0.37 | National Key Laboratory for Cognitive Neuroscience and Learning, Beijing Normal University, China and College of Information Science and Technology, Beijing Normal University, China | Guangming Chen, Wei Song, Jiakai Zhang |

Figura 21 – Disponível em: <<http://www.bbci.de/competition/iv/results/index.html>>
Acesso em: 13 de dezembro de 2018

Comparando os valores encontrados utilizando somente CSP de 8 a 30 Hz, foi encontrado um valor do índice Kappa= 0.47.



TERMO DE RESPONSABILIDADE

O texto do trabalho de conclusão de curso intitulado “Análise do desempenho das características de potência e fase para interfaces cérebro máquina ativadas por imagética motora” é de minha inteira responsabilidade. Declaro que não há utilização indevida de texto, material fotográfico ou qualquer outro material pertencente a terceiros sem a devida citação ou consentimento dos referidos autores.

João Monlevade, 04 de junho de 2019.

Franz Victor Peixoto Silva



DECLARAÇÃO DE CONFERÊNCIA DA VERSÃO FINAL

Declaro que conferi a versão final a ser entregue pelo aluno **Franz Victor Peixoto Silva**, autor do trabalho de conclusão de curso intitulado **Análise do desempenho das características de potência e fase para interfaces cérebro máquina ativadas por imagética motora** quanto à conformidade nos seguintes itens:

1. A monografia corresponde a versão final, estando de acordo com as sugestões e correções sugeridas pela banca e seguindo as normas ABNT;
2. A versão final da monografia inclui a ata de defesa (Anexo IV - apenas verso), a ficha catalográfica e o termo de responsabilidade (ANEXO X -) devidamente assinado.

João Monlevade, 24 de maio de 2019.

Nome do(a) Professor(a)