

**UNIVERSIDADE FEDERAL DE MINAS GERAIS**  
**Escola de Engenharia**  
**Programa de Pós-Graduação em Engenharia Elétrica**

Henrico Reis Barbosa

**ANÁLISE DE SINAIS DE ELETROENCEFALOGRAFIA  
DURANTE IMAGÉTICA MOTORA POR MEIO DE  
TÉCNICAS DE PROCESSAMENTO TEMPO-FREQUÊNCIA**

Belo Horizonte  
2025

Henrico Reis Barbosa

**ANÁLISE DE SINAIS DE ELETROENCEFALOGRAFIA  
DURANTE IMAGÉTICA MOTORA POR MEIO DE  
TÉCNICAS DE PROCESSAMENTO TEMPO-FREQUÊNCIA**

Dissertação apresentada para o curso de mestrado em engenharia elétrica da Universidade Federal de Minas Gerais como requerimento parcial para obtenção do grau de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Danilo Barbosa Melges,  
DEE/UFMG

Belo Horizonte  
2025

B238a	<p>Barbosa, Henrico Reis. Análise de sinais de eletroencefalografia durante imagética motora por meio de técnicas de processamento tempo-frequência [recurso eletrônico] / Henrico Reis Barbosa. – 2025. 1 recurso online (115 f. : il., color.) : pdf.</p> <p>Orientador: Danilo Barbosa Melges.</p> <p>Dissertação (mestrado) – Universidade Federal de Minas Gerais, Escola de Engenharia.</p> <p>Inclui bibliografia.</p> <p>1. Engenharia elétrica – Teses. 2. Eletroencefalografia – Teses. 3. Fourier, Transformações de – Teses. 4. Hilbert, Transformadas de – Teses. I. Melges, Danilo Barbosa. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.</p> <p>CDU: 621.3(043)</p>
-------	---



UNIVERSIDADE FEDERAL DE MINAS GERAIS

**Escola de Engenharia**

COLEGIADO DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

## FOLHA DE APROVAÇÃO

**"Análise de Sinais de Eletroencefalografia Durante Imagética Motora por Meio de Técnicas de Processamento Tempo-frequência"**

**Henrico Reis Barbosa**

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 04 de junho de 2025.

Por:

**Prof. Dr. Danilo Barbosa Melges**  
DEE (UFMG) - Orientador

**Prof. Dr. Hani Camille Yehia**  
DELT (UFMG)

**Prof. Dr. Renan Fernandes Kozan**  
DEE (UFMG)



Documento assinado eletronicamente por **Danilo Barbosa Melges, Professor do Magistério Superior**, em 04/06/2025, às 17:35, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Renan Fernandes Kozan, Professor do Magistério Superior**, em 05/06/2025, às 12:43, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Hani Camille Yehia, Professor do Magistério Superior**, em 06/06/2025, às 15:10, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufmg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **4260639** e o código CRC **EC143C8B**.

Referência: Processo nº 23072.234143/2025-31

SEI nº 4260639

## Agradecimentos

Início meus agradecimentos de forma pesada, porém prometo que daqui para frente, só para frente mesmo, não para trás. Quando iniciei o mestrado em 2020 senti que eu estava no começo de vários sonhos. Eu acreditava nas expectativas de meus amigos e colegas de que concluiria a experiência de mestrado rapidamente. Porém era impossível prever a calamidade da pandemia de COVID-19. O período de tensão sem perspectiva de vacinas e a luta constante por me manter cientificamente informado e divulgando este conhecimento para orientar e proteger as pessoas queridas cobraram o seu preço. Desenvolvi sintomas graves de depressão e ansiedade que hoje felizmente estão sob controle. Além disto tive meu diagnóstico tardio de autismo e superdotação, que também estavam cobrando seu preço na saúde junto com o desgaste da pandemia.

Entretanto, tive pessoas, seja na forma de amigos, colegas de trabalho (porque mestrado também é trabalho), professores e profissionais de saúde fenomenais que me ajudaram a suportar todas as dores. Posso afirmar que hoje não sinto apenas as dores, também sinto esperança e que tenho autonomia para continuar vivendo dias melhores. Quem estiver lendo não só estes agradecimentos, mas esta dissertação, gostaria que minhas humildes palavras sejam capazes de transmitir a dor, perseverança e contentamento vividos ao longo destes quase 5 anos e meio de mestrado, ainda mais vindas de alguém que *legit* adora estudar sobre todas as ciências.

Zerésimamente, quero agradecer a meu orientador Danilo Barbosa Melges, professor com quem eu estou em contato desde meu primeiro período na graduação para poder trabalhar com engenharia aplicada à saúde. Para mim o processo de escrita já não foi fácil, ainda mais considerando os agravantes de saúde mental que vieram à luz no começo de 2022. Ter tido um orientador humano e acolhedor, que me ajudava a ir traçando estratégias e perspectivas para permanecer no mestrado todo semestre, e que sempre foi muito empático com minhas enfermidades foi essencial para eu saber que estava tudo bem eu continuar no mestrado. Graças a ele eu me senti validado, senti que me era permitido demorar mais do que os 2 ~ 2,5 anos padrão para terminar o mestrado. E complementar a isto, todo meu agradecimento e carinho ao colegiado e à secretaria do PPGEE, que aceitou todos os meus pedidos de prorrogação e trancamento de matrícula sem questionar a legitimidade dos meus problemas de saúde. E neste bloco também quero agradecer à CAPES pelo apoio financeiro.

Primeiramente, quero agradecer aos meus professores das disciplinas de mestrado do

PPGEE que se adaptaram prontamente ao ensino remoto emergencial: Antônio de Pádua Braga (Reconhecimento de Padrões), Eduardo Mazoni Andrade Marçal Mendes (Introdução aos Processos Estocásticos), Bruno Vilhena Adorno (Lógica e Pensamento Matemático). Apesar da tensão pandêmica, eu aprendi e me diverti bastante em todas as disciplinas. Ainda, agradeço aos professores Adriano Vilela Barbosa e Hani Camille Yehia (Tecnologia e Ciência da Fala) que me ajudaram a voltar a frequentar fisicamente a UFMG já em 2024, o que me rendeu amigos como o doutorando em musicoterapia Ivan Moriá. Quem diria que uma conversa entre um engenheiro e um músico sobre programação em Python iria tão longe!

Continuando, quero agradecer aos profissionais de saúde que me acompanharam e me acompanham nos meus tratamentos. Minhas psicólogas Márcia Alves dos Santos, Natália Soares, Isabella Calijorne, minhas psiquiatras Maria Alice Silveira e Ana Paula Brasil, meu nutricionista Helder Lira e minha terapeuta ocupacional Rúbia Moura. Sem eles eu não teria dado conta de viver para chegar neste momento.

Pode soar estranho, mas quero agradecer também as várias versões do Henrico do passado. Agradeço a eles por terem deixado relatórios de trabalho atualizados com frequência e códigos MATLAB® devidamente comentados e explicados. Ainda por cima eles tiveram que segurar toda a barra, foram aprendendo a identificar as próprias dificuldades, a buscar ajuda tanto profissional quanto a dos amigos por mais difícil que fosse se expressar. Eles também cuidaram de mim, foram aprendendo a escutar mais as necessidades do corpo, respeitar os próprios limites, valorizar o descanso, abrir mão de modos de funcionamento perfeccionistas automáticos e padrões irrealistas de desempenho. Se eu pudesse enviar uma mensagem ao passado, eu ficaria feliz em escrever nela que os esforços de cuidado deram frutos, mesmo sendo um passinho de cada vez, com altos e baixos.

Ainda, quero agradecer ao dojô de karate estilo Kenyu (賢友流空手道の道場) do *sensei* Sérgio Murilo, que me ajudou a começar a sair do sedentarismo e voltar a me conectar com meu gosto por artes marciais, com o bônus de me conectar com a língua japonesa que estudo e leciono já há uns bons anos. Além do *sensei*, gostaria de agradecer aos meus *senpais* Kaio Alcântara, Vinícius Hernandez e Gabriel Santos, além de tantos outros que contribuem para o clima agradável de esforço e respeito dentro do dojô.

Falando em língua japonesa, não posso me esquecer do outro sonho que se iniciou em 2020, quando comecei a dar aulas de japonês na Escola Modelo de Língua Japonesa de Minas Gerais, meu querido *Gakkou* de BH. Foi treinando para me tornar professor de japonês que

pude também estudar sobre teorias e técnicas de aprendizagem baseadas em pesquisas científicas, e foi lá também que tive minhas primeiras experiências com turmas maiores. O *Gakkou* é um dos lugares que me confirmou que realmente, eu vou morrer pobre, porque gosto genuinamente de ensinar. Quero agradecer meus colegas *senseis* que são hoje *tomodachis* do *kokoro*, Haratani, Tsuyoshi, Yuka, Miyuki, Aryssa, Joe, Jojo, Elisa, Helder, Paloma, Miyamoto, Vinícius, Hisami e Nami.

Continuando, quero agradecer minha família estendida, que me acompanhou nos altos e baixos, estiveram comigo no fundo do poço depressivo e que me fez companhia até eu me sentir pronto e capaz de sair de lá. Nem sempre as ajudas foram as mais acertadas, o que faz parte e é natural, mas definitivamente foram as mais carinhosas e com boas intenções. Quando digo família estendida me refiro a parentes de sangue que são próximos, minha namorada e meus amigos. Seus nomes mais do que merecem estar aqui: Vitória Izabel de Moraes, Maria Rosângela dos Reis, Breno Reis Barbosa, Antônio Flávio dos Reis, Vanderci Barbosa, Elaini Almeida Peixoto, Vera de Sousa Ribeiro Jesus, Vinícius Antônio Soares Ferreira, Rivelino Junio Bispo de Oliveira, Matheus dr. LIGHT Eduardo da Silva Vaz Gonzales Acosta, Marcelo Senac, Victor Pedroso Castelo Branco Passos, Ana Carolina da Silva Reis, e vários outros. Além deles também agradeço aos meus diversos amigos de graduação e pós-graduação, e sofredores da área acadêmica Rúbia Reis Guerra, Luiz Henrique Moraes Antunes, Matheus Vieira L. Moreira, Lucas Ariel da Rocha Carvalho, Juliana Chaves, Jermana Lopes, Alcendino Jardim Neto, Fabiano Médice, Ivan Moriá Borges, Arabela Franco, Guilherme Lage, Mayra Mota Medeiros, Letícia Pereira Resende, Mariana Pimenta Adaixo de Deus, Thiago Lucas de Oliveira, Frederico Parrela, Natália Lelis Torres, Bárbara de Paula Ferreira. E gostaria de agradecer profundamente a Neuza Aparecida dos Santos, diarista que sem ela seria um desafio enorme para somente eu e minha mãe cuidarmos da casa e de nós, e à Marlene Ferreira dos Santos que também trabalhou para nós durante toda a minha criação. Apesar das injustiças sociais e ao baixo reconhecimento do trabalho de cuidado pelo mundo no geral, que pelo menos fique o registro de meus agradecimentos a este serviço essencial.

Em penúltimo lugar, quero agradecer aos meus amigos da Praça, que partilham comigo a criação do Dojô Hiroba de Estudos Interdisciplinares, Fernanda, Jonatan, Natali, Lucas Cardoso, Douglas Alves, Renan Wenzel de Exatas, Renan Wenzel de Humanas, Renan Wenzel de Biológicas, Gustavo Pereira *et al.* Agradeço também ao professor Felipe Campelo, que me deu minha primeira disciplina de estatística aplicada em 2018, aliando o ensino de filosofia e história da ciência à estatística. Em 2014 cursei uma disciplina de Filosofia da Ciência e

Epistemologia na FAFICH que foi essencial para eu entender como o fazer científico vai para além da tecnologia e do progresso, podendo mesmo regredir, e é um fenómeno também social com todas as suas falhas inerentes. Infelizmente não me lembro os nomes dos pós-graduandos e do professor que me ensinaram, mas que sou profundamente grato a eles, eu sou. Sobre o mesmo tópico, agradeço também aos professores Maria Lúcia Oliveira de Souza e Altay Alves Lino de Souza por ofertarem as disciplinas de Estatística Aplicada à Psicobiologia I, II e III de forma online pela UNIFESP e aos meus amigos de disciplina Patrícia Pauli, Pedro Alvim, Pedro Zangrando, dentre vários outros. Quem sabe, sabe o tanto que estas aulas e o Discord da disciplina contribuíram e continuam a contribuir para meus estudos de métodos científicos.

Por último quero agradecer a todos aqueles professores, amigos e divulgadores científicos que me ajudam a estudar sobre filosofia da ciência, história da ciência, epistemologia, e como construir um mundo interdisciplinar de verdade sem rixa entre as áreas. Podcasts Naruhodo, Dragões de Garagem, Scicast, Intervalo de Confiança, Xadrez Verbal, Chutando a Escada, Rádio Escafandro, Quatro de 15, História FM; Canais de Youtube e páginas em redes sociais de ciência Nunca vi 1 Cientista, Mari Krüger, Olá Ciência, canal Peixe Babel, Manual do Mundo, Nerdologia, 3 Blue 1 Brown, Princípiã Matemática, Another Roof, Artem Kirsanov (melhor explicação de *wavelet* que já vi no YouTube), Steve Brunton. E apesar de não ser divulgação científica, sem o podcast Realidades Paralelas do Guaxinim e sua Taverna do Guaxinim eu definitivamente não teria conseguido manter o mínimo de sanidade durante todo este período.

Vai saber quantas mãos foram necessárias para que esta dissertação fosse possível. A única certeza que é foram muitas. Provavelmente um infinito contável.

## Resumo

A imagética motora (IM) consiste no ato de imaginar um movimento sem efetivamente executá-lo, sendo possível encontrar atividade correlata no eletroencefalograma (EEG). A dessincronização relacionada a evento (DRE) na banda alfa do EEG é o fenômeno mais consistente durante IM, representando uma redução na potência nas frequências de 8 a 13 Hz. O EEG durante IM vem sendo estudado nos domínios do tempo, da frequência e tempo-frequência. Neste trabalho, foi investigada a evolução temporal de parâmetros espectrais dinâmicos (PEDs) calculados a partir da transformada de Fourier de tempo curto (TFTC) e da transformada discreta de Hilbert (TDH). Os PEDs calculados foram: a amplitude instantânea ( $A_i$ ) e a frequência instantânea ( $F_i$ ) pela TDH, e a amplitude eficaz ( $A_{ef}$ ) e a frequência central ( $F_{ce}$ ) pela TFTC. Estes parâmetros foram calculados para registros de EEG durante IM, visando ao desenvolvimento de interfaces cérebro-máquina baseando-se em medidas de fácil interpretação. Estes registros são de 9 voluntários, oriundos do conjunto de dados 2A da quarta Competição de Interface Cérebro-Máquina de Berlim. O protocolo experimental possui os seguintes marcos temporais: beep sonoro em  $t = 0$  s; sinal visual indicando início da IM a desempenhar (4 classes de IM: mão direita - MD, mão esquerda - ME, pés e língua) de  $t = 2$  s a  $t = 3,25$  s; sustentação da IM até  $t = 6$  s; pausa entre ensaios com pelo menos 1,5 s de duração após  $t = 6$  s. Os resultados indicam que os parâmetros de amplitude ( $A_i$  e  $A_{ef}$ ) começa a aumentar em  $t = 2$  s, atingindo um pico em torno de  $t = 3$  s, seguido por uma queda até  $t = 4$  s, voltando a subir ao fim da IM ( $t = 6$  s). Os parâmetros de frequência ( $F_i$  e  $F_{ce}$ ) apresentaram traçados com perfil invertido em relação aos parâmetros de amplitude, com correlação negativa ( $\text{corr}(A_i, F_i)$  e  $\text{corr}(A_{ef}, F_{ce})$ ) presente de  $t = 1$  s a  $t = 6$  s. Usando a integral dos PEDs no intervalo de 3 a 4 s, foram identificadas diferenças estatisticamente significativas (DES) entre as IMs na maioria das derivações e para todos os PEDs, tendo sido mais evidente as diferenças entre a IM dos pés quando comparada a IM da língua ou MD. Também foram identificadas DES usando as integrais dos PEDs no intervalo de 4 a 5 s para a maioria das derivações, com os PEDs de frequência complementando os PEDs de amplitude, um identificando DES para os casos em que o outro falhou em detectar, e vice-versa. Assim como reportado por outros trabalhos, foi mais fácil diferenciar IMs relacionadas a grupos musculares distintos (pés vs MD e pés vs língua) do que IMs relacionadas a grupos musculares similares (MD vs ME).

**Palavras-chave:** imagética motora; EEG; análise tempo-frequência; transformada discreta de Hilbert; transformada de Fourier de tempo curto.

## Abstract

Motor imagery (MI) is the act of imagining a movement without actually executing it, and correlated activity can be found in the electroencephalogram (EEG). Event-related desynchronization (ERD) in the alpha band of the EEG is the most consistent phenomenon during MI, representing a reduction in power at frequencies from 8 to 13 Hz. MI EEG has been studied in the time, frequency and time-frequency domains. In this work, we investigated the temporal evolution of dynamic spectral parameters (DSPs) calculated from the short-time Fourier transform (STFT) and the discrete Hilbert transform (DHT). The DSPs calculated were: instantaneous amplitude ( $A_i$ ) and instantaneous frequency ( $F_i$ ) from the DHT, and root-mean-square ( $A_{rms}$ ) and center frequency ( $F_{ce}$ ) from the STFT. These parameters were calculated for EEG recordings during MI, with the aim of developing brain-machine interfaces based on easy-to-interpret measurements. These recordings are from 9 volunteers, taken from the 2A dataset of the fourth Berlin Brain-Computer Interface Competition. The experimental protocol has the following key events: a beep at  $t = 0$  s; a visual signal prompting the subject to start the MI to be performed (4 classes of MI: right hand - RH, left hand - LH, feet and tongue) from  $t = 2$  s to  $t = 3.25$  s; sustained MI until  $t = 6$  s; pause between trials lasting at least 1.5 s after  $t = 6$  s. The results indicate the amplitude parameters ( $A_i$ , and  $A_{rms}$ ) start to increase at  $t = 2$  s, reaching a peak around  $t = 3$  s, decreasing until  $t = 4$  s, and rising again at the end of the MI ( $t = 6$  s). The frequency parameters ( $F_i$  and  $F_{ce}$ ) showed an inverted profile with respect to the amplitude parameters, with a negative correlation ( $\text{corr}(A_i, F_i)$  and  $\text{corr}(A_{rms}, F_{ce})$ ) present from  $t = 1$  s to  $t = 6$  s. Using the integral of the DSPs in the 3 to 4 s interval, statistically significant differences (SSD) were identified between the MIs in most leads and for all DSPs, with the differences between the MI of the feet compared to the MI of the tongue or RH being more evident. SSDs were also identified using the DSP integrals in the 4 to 5 s range for most leads, with the frequency DSPs complementing the amplitude DSPs, one identifying SSDs for cases where the other failed to detect, and vice-versa. As reported by other studies, it was easier to differentiate MIs related to different muscle groups (feet vs RH and feet vs tongue) than MIs related to similar muscle groups (RH vs LH).

**Keywords: motor imagery; EEG; time-frequency analysis; discrete Hilbert transform; short-time Fourier transform.**

## Lista de Figuras

Figura 2.1: Forma de onda típica de um potencial de ação. Modificada de BEAR; CONNORS; PARADISO, 2008.....	24
Figura 2.2: Lobos cerebrais. Adaptado de GRAY H; GRAY; CLEMENTE, 1985 .....	25
Figura 2.3: Mapa citoarquitetônico de Broadman. Extraído de (BEAR; CONNORS; PARADISO, 2008). .....	25
Figura 2.4: Representação das regiões do corpo no (a) córtex sensorial somático e no (b) córtex motor. Adaptado de HALL, 2011. ....	26
Figura 2.5: Passo a passo para identificação de DRE e SRE. Extraído de (PFURTSCHELLER; LOPES DA SILVA, 1999). .....	29
Figura 2.6: Diagrama de blocos de uma ICM. ....	30
Figura 2.7: Sistema 10-20 de posicionamento (A) e sistema 10-10 (B). Modificado de NIEDERMEYER et al., 2016.....	30
Figura 2.8: Sinal composto por um <i>chirp</i> linear decrescente (a), um <i>chirp</i> quadrático crescente (b), e uma senoide monotônica localizada no tempo.....	38
Figura 2.9: Espectrogramas obtidos da TFTC usando janela retangular e janela <i>Hann</i> . ....	39
Figura 2.10 - Sinais de exemplo para processamento com TDH. ....	44
Figura 2.11 - Amplitudes e frequências instantâneas dos sinais da Figura 2.10. ....	45
Figura 2.12 - Amplitudes e frequências instantâneas dos sinais da Figura 2.10, usando a estratégia de janela deslizante.....	46
Figura 2.13: Comparação entre a distribuição de Wigner-Ville (apenas valores positivos), o espectrograma e o escalograma do sinal de exemplo. ....	49
Figura 3.1: Protocolo experimental de um ensaio do conjunto CICMB-2A. Modificada de (TANGERMANN et al., 2012).....	52
Figura 3.2: Disposição dos eletrodos para coleta de EEG do conjunto CICMB-2A. Extraída de (TANGERMANN <i>et al.</i> , 2012). ....	53
Figura 3.3 - Diagrama de processamento para obtenção dos PEDs pela TDH. ....	55
Figura 3.4 - Diagrama de processamento para obtenção dos PEDs pela TFTC.....	57

Figura 4.1: Exemplo de aplicação da média coerente no conjunto CICMB-2A. Voluntário A01, derivação Cz, IM dos pés. ....	60
Figura 4.2: Exemplo do processamento para obtenção dos PEDs pela TDH no conjunto CICMB-2A. Voluntário A01, derivação Cz, IM dos pés. ....	61
Figura 4.3: Exemplo do processamento para obtenção dos PEDs pela TFTC no conjunto CICMB-2A. Voluntário A01, derivação Cz, IM dos pés. ....	62
Figura 4.4: Evolução temporal de $A_i[n]$ (esquerda) e $F_i[n]$ (direita) para as 4 classes de IM (ME – mão esquerda, MD – mão direita, P – pés, L – língua) nas derivações indicadas para o voluntário A01, sessão de treinamento do conjunto de dados. ....	64
Figura 4.5: Evolução temporal de $A_i[n]$ (esquerda) e $F_i[n]$ (direita) para as 4 classes de IM (ME – mão esquerda, MD – mão direita, P – pés, L – língua) nas derivações indicadas para o voluntário A02, sessão de treinamento do conjunto de dados. ....	65
Figura 4.6: Evolução temporal de $A_{ef}[n]$ (esquerda) e $F_{ce}[n]$ (direita) para as 4 classes de IM (ME – mão esquerda, MD – mão direita, P – pés, L – língua) nas derivações indicadas para o voluntário A02, sessão de treinamento do conjunto de dados. ....	67
Figura 4.7: Evolução temporal de $A_{ef}[n]$ (esquerda) e $F_{ce}[n]$ (direita) para as 4 classes de IM (ME – mão esquerda, MD – mão direita, P – pés, L – língua) nas derivações indicadas para o voluntário A02, sessão de treinamento do conjunto de dados. ....	68
Figura 4.8 - <i>Boxplot</i> do PED $sA_i$ no intervalo t3. ....	71
Figura 4.9 - <i>Boxplot</i> do PED $sA_i$ no intervalo t4. ....	73
Figura 4.10 - <i>Boxplot</i> do PED $sF_i$ no intervalo t3. ....	77
Figura 4.11 - <i>Boxplot</i> do PED $sF_i$ no intervalo t4. ....	78
Figura 4.12 - <i>Boxplot</i> do PED $sA_{ef}$ no intervalo t3. ....	81
Figura 4.13 - <i>Boxplot</i> do PED $sA_{ef}$ no intervalo t4. ....	83
Figura 4.14 - <i>Boxplot</i> do PED $sF_{ce}$ no intervalo t3. ....	86
Figura 4.15 - <i>Boxplot</i> do PED $sF_{ce}$ no intervalo t4. ....	88
Figura 4.16 - <i>Boxplots</i> das integrais de $A_i$ (esquerda) e $F_i$ (direita) ao longo dos intervalos para IM dos pés. ....	95
Figura 4.17 - <i>Boxplots</i> das correlações entre $A_i$ e $F_i$ nos intervalos para IM dos pés. ....	96

Figura 4.18 - *Boxplots* das integrais de  $Aef$  (esquerda) e  $Fce$  (direita) ao longo dos intervalos para IM dos pés. .... 99

Figura 4.19 - *Boxplots* das correlações entre  $Aef$  e  $Fce$  nos intervalos para IM dos pés..... 100

## Lista de Abreviações

AMS	Área Motora Suplementar
APM	Área Pré-Motora
BP	<i>Bereitschaftspotential</i>
CAR	<i>Common Average Reference</i>
CICMB	Competição de Interface Cérebro-Máquina de Berlin
CICMB-2A	Conjunto de dados de <i>benchmark</i> “2A – Imagética Motora Contínua Multi-Classe” da quarta CICMB
CSP	<i>Common Spatial Patterns</i>
DES	Diferença estatisticamente significativa
DP	Desvio-padrão
DRE	Dessincronização Relacionada a Evento
EEG	Eletroencefalograma
EM	Execução Motora
EP	Erro-padrão
IC	Intervalo de confiança
ICM	Interface Cérebro Máquina
IIQ	Intervalo interquartil
IM	Imagética Motora
MC	Média Coerente
ME	Mão esquerda
MD	Mão direita
PE	Perna esquerda
PD	Perna direita
PED	Parâmetro Espectral Dinâmico
PEVRP	Potencial evocado visual em regime permanente
PRE	Potencial Relacionado a Evento

SRE	Sincronização Relacionada a Evento
SVM	Máquina de vetor de suporte ( <i>Support Vector Machine</i> , em inglês)
TDH	Transformada Discreta de Hilbert
TDF	Transformada Discreta de Fourier
TF	Transformada de Fourier
TH	Transformada de Hilbert
TFTC	Transformada de Fourier de Tempo Curto
TW	Transformada <i>Wavelet</i>

## Lista de Símbolos

$F_s$	Frequência de amostragem
$T_s$	Período de amostragem
$\Delta t$	Resolução temporal, correspondente ao tamanho (em segundos) da janela
$\Delta f$	Resolução espectral
$A_i$	Amplitude instantânea
$F_i$	Frequência instantânea (apenas valores positivos, em Hertz)
$\theta_i$	Fase instantânea
$P_i$	Potência instantânea
$A_{ef}$	Amplitude eficaz
$F_{ce}$	Frequência central
$\alpha$	Banda de frequência de 8 a 13 Hz do EEG
$\alpha_t$	significância de teste estatístico
$\beta$	Banda de Frequência de 14 a 30 Hz do EEG
$\gamma$	Banda de Frequência superior a 30 Hz do EEG
$\theta$	Banda de Frequência de 4 e 7,5 Hz do EEG

## Sumário

<b>Capítulo 1: Introdução .....</b>	<b>20</b>
<b>1.1 Objetivo Geral .....</b>	<b>21</b>
<b>1.2 Objetivos Específicos .....</b>	<b>21</b>
<b>1.3 Estrutura do Trabalho .....</b>	<b>21</b>
<b>Capítulo 2: Revisão Bibliográfica .....</b>	<b>23</b>
<b>2.1 O Encéfalo e o Sistema Sensório-Motor .....</b>	<b>23</b>
<b>2.1.1 O Potencial de Ação .....</b>	<b>23</b>
<b>2.1.2 O Encéfalo .....</b>	<b>24</b>
<b>2.2 O Fenômeno de Interesse: Imagética Motora .....</b>	<b>26</b>
<b>2.2.1 Dessincronização e Sincronização Relacionada a Evento .....</b>	<b>28</b>
<b>2.3 Modelo para Interfaces Cérebro-Máquina .....</b>	<b>29</b>
<b>2.3.1 Aquisição e Condicionamento de Sinais de EEG .....</b>	<b>30</b>
<b>2.3.2 Pré-processamento .....</b>	<b>31</b>
<b>2.3.3 Extração de Características e Classificação .....</b>	<b>32</b>
<b>2.3.4 Desafios para o Desenvolvimento de ICMs Baseadas em IM .....</b>	<b>33</b>
<b>2.4 Análise Tempo-Frequência .....</b>	<b>35</b>
<b>2.4.1 Transformada Discreta de Fourier .....</b>	<b>35</b>
<b>2.4.2 Transformada de Fourier de Tempo Curto e o Espectrograma .....</b>	<b>36</b>
<b>2.4.3 Sinal Analítico e a Transformada de Hilbert .....</b>	<b>39</b>
<b>2.4.4 Relações entre Distribuições Tempo-Frequência .....</b>	<b>47</b>
<b>Capítulo 3: Materiais e métodos .....</b>	<b>51</b>
<b>3.1 Base de Dados .....</b>	<b>51</b>
<b>3.1.1 Coleta e Condicionamento do Conjunto de Dados CICMB-2A .....</b>	<b>51</b>
<b>3.2 Pré-Processamento: Média Coerente e Filtragem .....</b>	<b>53</b>
<b>3.3 Processamento: Parâmetros Espectrais Dinâmicos (PEDs) .....</b>	<b>54</b>

3.3.1	PEDs pela Transformada Discreta de Hilbert .....	54
3.3.2	PEDs pela Transformada de Fourier de Tempo Curto .....	56
3.3.3	Métricas para Análise Estatística dos PEDs .....	57
3.4	Análise Estatística da Forma de Onda .....	57
Capítulo 4:	Resultados.....	59
4.1	Traçados dos PEDs .....	59
4.1.1	Passo-a-passo do processamento .....	59
4.1.2	Traçados dos PEDs .....	62
4.2	Diferenças entre as classes .....	69
4.2.1	Diferenças entre as classes – PED $sA_i$ .....	69
4.2.2	Diferenças entre as classes – PED $sF_i$ .....	73
4.2.3	Diferenças entre as classes – PED $sA_{ef}$ .....	78
4.2.4	Diferenças entre as classes – PED $sF_{ce}$ .....	83
4.2.5	Resumo das diferenças entre classes para os PEDs de amplitude e frequência .....	88
4.3	Diferenças entre os intervalos.....	92
4.3.1	Diferenças entre os intervalos – $sA_i$ , $sF_i$ e $\text{corr}(A_i, F_i)$ .....	92
4.3.2	Diferenças entre os intervalos – $sA_{ef}$ , $sF_{ce}$ e $\text{corr}(A_{ef}, F_{ce})$ .....	96
Capítulo 5:	Discussão.....	101
5.1	Comparação de traçados dos PEDs .....	101
5.2	Interpretação dos testes estatísticos: PEDs da TDH versus PEDs da TFTC .....	101
5.3	Comparação com a literatura.....	102
5.4	Aplicações e desempenho de ICMs baseadas em IM .....	105
Capítulo 6:	Conclusão, Limitações e Sugestões de Trabalhos Futuros .....	107
6.1	Limitações do presente trabalho .....	107
6.2	Trabalhos futuros.....	107

<b>Referências .....</b>	<b>109</b>
--------------------------	------------

## Capítulo 1: Introdução

A imagética motora (IM) consiste na simulação mental de um movimento sem efetivamente executá-lo (JEANNEROD, 1994). Ela é interessante pois, mesmo sendo uma tarefa cognitiva, compartilha os mesmos mecanismos e substratos neurais da execução do movimento, permitindo estudar o controle motor a partir de sinais gerados por fontes bioquímicas neuronais (e.g.: eletroencefalograma - EEG), detectáveis no córtex motor, no córtex pré-frontal e no córtex parietal posterior (HANAKAWA, 2016). A IM vem sendo aplicada no desenvolvimento de interfaces cérebro-máquina (ICM) (KIM; CARLSON; LEE, 2013), na reabilitação motora (ALONSO-VALERDI; SALIDO-RUIZ; RAMIREZ-MENDOZA, 2015) e até mesmo no treinamento esportivo (ROMANO SMITH *et al.*, 2019).

O sinal de EEG, coletado durante imagética motora, exhibe ao menos dois fenômenos bem descritos na literatura: o *Bereitschaftspotential* (BP) e a dessincronização relacionada a evento na banda alfa ( $DRE\alpha$ ). O BP, também conhecido como potencial de prontidão, é caracterizado por um aumento da amplitude do EEG pouco antes do começo efetivo do movimento, podendo ser mais bem visualizado a partir da média coerente (sincronizada com a imaginação ou execução do movimento), sendo, portanto, um dos principais potenciais relacionados a evento (PRE) observáveis durante IM (BIRBAUMER *et al.*, 1990). A  $DRE\alpha$  é caracterizada pela diminuição da potência na banda alfa enquanto o movimento é executado ou imaginado (PFURTSCHELLER; LOPES DA SILVA, 1999). Tanto BP quanto  $DRE\alpha$  se mostram mais evidentes em regiões relacionadas ao planejamento motor, o que inclui, principalmente, derivações da região fronto-central e centro-parietal.

Neste contexto, diversas técnicas vêm sendo utilizadas para identificar alterações no EEG, tanto no domínio do tempo (e.g.: identificação de BP e outros PREs), quanto no da frequência (e.g.:  $DRE\alpha$ ), podendo-se citar a categorização multiclasse baseada na correlação cruzada entre as derivações EEG e uma derivação de referência (KRISHNA; PASHA; SAVITHRI, 2016) e a variância *intertrial* (entre ensaios/estímulos) para estimar a  $DRE\alpha$  (SHAHLAEI *et al.*, 2019). Além destas, alguns trabalhos empregaram técnicas tempo-frequência, tais como a transformada de Fourier de tempo curto (TFTC) (HORTAL *et al.*, 2015), transformada wavelet (TW) (GHAEMI *et al.*, 2017) e a transformada de Hilbert-Huang (THH) (WANG *et al.*, 2019).

Dentre as técnicas tempo-frequência, a transformada discreta de Hilbert (TDH) pode ser

usada para extrair os chamados parâmetros espectrais dinâmicos (PEDs), nominalmente amplitude ( $A_i$ ), potência ( $P_i$ ), fase ( $\theta_i$ ) e frequência ( $F_i$ ) instantâneas de um sinal. Logo, a TDH permite acompanhar a dinâmica temporal destes parâmetros de fácil interpretação. Shahlaei et al. (2019), por exemplo, estimaram a  $DRE\alpha$  a partir da  $A_i$  obtida pela TDH e Hu et al. (2008) exploraram o sincronismo de fase calculado a partir de  $\theta_i$ . De forma similar, a TFTC pode ser usada para extrair PEDs análogos à  $F_i$ , com o cálculo da frequência central ( $F_{ce}$ ), e à  $A_i$ , com o valor eficaz da amplitude ( $A_{ef}$ ). Apesar das técnicas tempo-frequência serem populares no desenvolvimento de ICMs baseadas em IM, os trabalhos apresentados na literatura costumam focar mais na comparação de desempenho (e.g.: taxa de acertos da ICM) dos métodos de classificação do que na interpretação e na descrição das características extraídas dos sinais de EEG durante IM, foco deste trabalho.

## 1.1 Objetivo Geral

Este projeto se propôs a investigar as propriedades dos PEDs em registros de EEG durante IM de forma a facilitar o seu uso no desenvolvimento de ICMs. Esta investigação permitiu avaliar se os diferentes PEDs são bons descritores da atividade cortical relacionada à IM e se seu cálculo é robusto à atividade de fundo (EEG espontâneo).

## 1.2 Objetivos Específicos

i) Análise da evolução temporal e da distribuição espacial da amplitude instantânea e da frequência instantânea obtidas a partir da transformada discreta de Hilbert da média coerente de sinais de EEG durante IM.

ii) Análise da evolução temporal e da distribuição espacial da amplitude eficaz e da frequência central obtidas a partir da transformada de Fourier de tempo curto da média coerente de sinais de EEG durante IM.

A partir dos objetivos i) e ii), foi possível identificar as similaridades e diferenças entre a TDH e a TFTC.

## 1.3 Estrutura do Trabalho

O “capítulo 1: Introdução” conceitua brevemente o que é a IM, fenômenos do EEG associados a ela e algumas aplicações do seu uso em ICM e reabilitação. O “capítulo 2: Revisão Bibliográfica” contém as bases de neurofisiologia e de processamento de sinais necessárias para a compreensão de PREs e da IM, em particular. Nele também é feita a conceituação e breve

discussão de modelagem de ICMs e de representações tempo-frequência empregadas neste trabalho. O “capítulo 3: Materiais e Métodos” descreve a base de dados utilizada, o protocolo experimental de coleta, as informações dos participantes, assim como a forma como os PEDs foram calculados a partir da TDH e da TFTC. Também são descritos os métodos utilizados para investigar diferenças estatisticamente significativas entre os PEDs para IMs de diferentes classes (e.g.: mão direita, mão esquerda, pés e língua), bem como sua evolução temporal. O “capítulo 4: Resultados” mostra e descreve as formas de onda obtidas, além de apresentar os resultados da análise estatística. O “capítulo 5: Discussão” apresenta uma breve discussão de trabalhos da literatura que utilizaram protocolos experimentais similares e/ou a mesma base de dados, bem como uma reflexão das aplicações e desempenhos de ICMs baseadas em IM. Por fim, o “capítulo 6: Conclusão, Limitações e Sugestões de Trabalhos Futuros” enumera alguns pontos de melhoria e sugestões de continuidade do presente trabalho.

## Capítulo 2: Revisão Bibliográfica

Este capítulo aborda i) a fisiologia e anatomia do encéfalo, particularmente as regiões envolvidas no processamento do sistema sensorio-motor e a eletrofisiologia relacionada; ii) a imagética motora, em termos de suas componentes imagéticas e fenômenos elétricos relacionados; iii) os modelos matemáticos e computacionais comumente usados para descrição e detecção da IM; iv) as técnicas e os desafios de ICMs baseadas em imagética motora; e v) a descrição das técnicas de análise tempo-frequência utilizadas neste trabalho, a transformada de Fourier de tempo curto e transformada de Hilbert.

### 2.1 O Encéfalo e o Sistema Sensorio-Motor

Para que exista o movimento voluntário é preciso que exista uma estrutura no corpo capaz de mudar suas dimensões físicas a partir de algum tipo de comando. O movimento voluntário é possível graças ao sistema músculo-esquelético formado por fibras musculares eletricamente excitáveis. E o comando e controle do movimento é possível graças ao sistema nervoso central (SNC) que se comunica enviando sinais para que os músculos se contraíam e recebendo destes informação de retorno sobre o grau de contração, dentre outras informações. A estrutura do SNC é formada por neurônios e células gliais, sendo os neurônios as células responsáveis pela transmissão do sinal elétrico de comando e controle. Além disto, existem regiões do SNC especializadas em controlar partes específicas do corpo e partes associadas à integração da informação que circula pelo SNC. Desta forma, nesta seção, está descrito o mecanismo de funcionamento básico dos neurônios, a anatomia do encéfalo associada ao sistema sensorio-motor e suas funções.

#### 2.1.1 O Potencial de Ação

O neurônio é a unidade básica de processamento de informação pelo sistema nervoso. Estas células são responsáveis pela condução e geração dos potenciais de ação. O potencial de ação é a mudança rápida do potencial elétrico que se propaga pela membrana celular (HALL, 2011). A forma de onda típica de um potencial de ação medido dentro da célula com a referência ao meio externo está ilustrada na Figura 2.1. Nota-se que a membrana do neurônio possui potencial de repouso de  $-65$  mV, e que este potencial se torna menos negativo, caracterizando a despolarização da membrana devido à abertura de canais de sódio e entrada deste íon, que está mais concentrado fora do que dentro da célula. Após atingir cerca de  $+35$  mV, ocorre a

repolarização da membrana a partir da abertura de canais de potássio, que está mais concentrado dentro do que fora da célula, fazendo com que o potencial de membrana retorne ao valor de repouso.

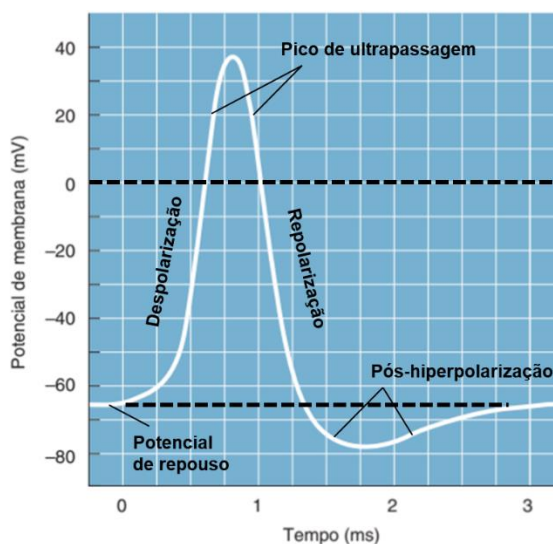


Figura 2.1: Forma de onda típica de um potencial de ação. Modificada de BEAR; CONNORS; PARADISO, 2008

Um neurônio é constituído por corpo celular, axônios e dendritos. No corpo celular se encontra o núcleo, que contém o material genético. O axônio é uma estrutura alongada por onde ocorre a geração e condução do potencial de ação, via corrente iônica. Os dendritos são neuritos mais curtos do que os axônios e que, através de sinapses químicas (mediadas por neurotransmissores), se comunicam com os outros neurônios. Assim, nota-se que o fenômeno de geração e condução dos potenciais de ação é um fenômeno bioquímico resultante de fluxo de íons entre os meios intra e extracelular, e vice-versa.

### 2.1.2 O Encéfalo

O encéfalo é o órgão mais complexo dos vertebrados, sendo constituído pelo cérebro, cerebelo e tronco encefálico (BEAR; CONNORS; PARADISO, 2008). Para o controle motor, o cérebro é responsável pela ativação de padrões funcionais contidos nas outras estruturas, com apenas algumas vias diretas até a medula. O cerebelo é responsável por controlar o ritmo dos movimentos, coordenando tanto a intensidade das contrações musculares quanto a relação entre grupos musculares agonistas e antagonistas. O cérebro pode ser dividido anatomicamente em lobos (Figura 2.2) e, funcionalmente, pelo mapa citoarquitetônico de Broadman (Figura 2.3).




Figura 2.2: Lobos cerebrais. Adaptado de GRAY H; GRAY; CLEMENTE, 1985




Figura 2.3: Mapa citoarquitetônico de Brodmann. Extraído de (BEAR; CONNORS; PARADISO, 2008).

Cada número do mapa citoarquitetônico de Brodmann representa uma região do córtex de acordo com sua função e arquitetura analisada em cortes histológicos. As áreas 4 e 6 formam o córtex motor, responsável pelas funções motoras. A área 8 corresponde ao córtex pré-frontal e está envolvida na realização de movimentos complexos. As áreas 1, 2 e 3 formam o córtex sensorial somático, responsável por processar informações principalmente de tato, temperatura e dor. As áreas 17 e 18 formam o córtex visual e as áreas 5, 7 e 19 são regiões de integração de informação sensorial somática e visual. Estas são as regiões principais de interesse no estudo da IM. Além disto, por meio de experimentos de estimulação elétrica pelo corpo, foi possível mapear quais áreas do corpo estão relacionadas a quais regiões dos córtex motor e somato-sensitivo (Figura 2.4).



No estágio de planejamento, o indivíduo possui apenas instruções vagas sobre o movimento a ser executado, como, por exemplo, “pegue aquele livro”. Já no estágio de preparação, o indivíduo já tem as informações completas do movimento. Um exemplo de informação completa seria “pegue aquele livro com sua mão direita usando pouca força”. Por último, o estágio de execução é quando há contração/relaxamento explícito de uma dada musculatura.

A explicitude do movimento indica se a imaginação foi realizada de forma intencional (explícita) ou não (implícita). A forma convencional de IM é a explícita. Para entender o que seria uma IM implícita imagine o seguinte experimento: ao ver um primeiro sinal visual, uma pessoa deve se preparar para imaginar ou executar o movimento de girar a mão direita, mas a instrução de executar ou imaginar é dada por um segundo sinal visual. Neste intervalo entre os sinais, o indivíduo já passa pelo processo de recuperar uma representação abstrata do movimento exigido, indicando um tipo possível de IM implícita.

A modalidade sensorial é relativa à forma como a pessoa imagina o movimento e pode ser visual, quando ela visualiza o movimento, ou cinestésica, quando outras modalidades sensoriais (como o tato) estão envolvidas na imaginação.

Por último, o agente corresponde à perspectiva pela qual o movimento é imaginado, podendo ser em primeira pessoa ou em terceira pessoa.

Hanakawa (2016) concluiu que paradigmas para controle de ICMs devem funcionar melhor se os movimentos forem imaginados de forma cinestésica e em primeira pessoa, pois estas modalidades parecem modular melhor os ritmos sensório-motores, mais facilmente identificados em regiões adjacentes ao córtex motor e somato-sensitivo, ou seja, na região fronto-central e centro-parietal.

Resumindo, os quatro fatores de IM e suas características são:

- Controle motor: estágio de planejamento ou estágio de preparação;
- Explicitude: explícito (intencional) ou não-explícito (não intencional);
- Modalidade sensorial: visual ou cinestésico;
- Agente: primeira pessoa ou terceira pessoa.

### 2.2.1 Dessincronização e Sincronização Relacionada a Evento

O sinal de EEG é comumente dividido nas seguintes faixas de frequência: delta ( $\delta$ :  $< 3,5$  Hz), teta ( $\theta$ :  $4 - 7,5$  Hz), alfa ( $\alpha$ :  $8 - 13$  Hz), beta ( $\beta$ :  $14 - 30$  Hz) e gama ( $\gamma$ :  $> 30$  Hz) (NIEDERMEYER *et al.*, 2016). A banda alfa, quando identificada no córtex motor, é também chamada de banda mu ( $\mu$ ) (NIEDERMEYER *et al.*, 2016). Estas bandas também são comumente referidas como “ondas do EEG”. A dessincronização relacionada a evento (DRE) corresponde à diminuição da potência do sinal em uma faixa de frequência específica, em relação a uma potência de referência (normalmente a potência do EEG de repouso), quando um evento (e.g. imaginação do movimento) ocorre. A sincronização (SRE) é o fenômeno contrário, um aumento da potência durante a ocorrência do evento. Na literatura, o fenômeno mais consistente usado para identificação da IM é a DRE na banda alfa, porém, há relatos de SRE concomitante em beta, fenômeno também chamado de rebote em beta (*beta rebound*) (PFURTSCHELLER; LOPES DA SILVA, 1999; PFURTSCHELLER; SOLIS-ESCALANTE, 2009). Uma das formas mais clássicas de calcular a DRE/SRE é, a partir de  $N$  ensaios sincronizados com o evento, realizar a seguinte sequência de processamento (PFURTSCHELLER; LOPES DA SILVA, 1999):

- i) Filtrar o sinal de cada ensaio na banda de interesse;
- ii) Elevar ao quadrado as amostras do sinal para obter um sinal de potência para cada ensaio;
- iii) Realizar a média ponto-a-ponto dos sinais de potência calculados em ii);
- iv) Filtrar o sinal resultante de iii) ou calcular seu envelope para suavização;
- v) Dividir o sinal obtido pela potência média de um intervalo de referência (usualmente EEG antes da estimulação) para obter uma medida de DRE/SRE.

A Figura 2.5 mostra um exemplo do passo a passo descrito, resultando em sinais de DRE em alfa e SRE em beta durante imagética motora (PFURTSCHELLER; LOPES DA SILVA, 1999).

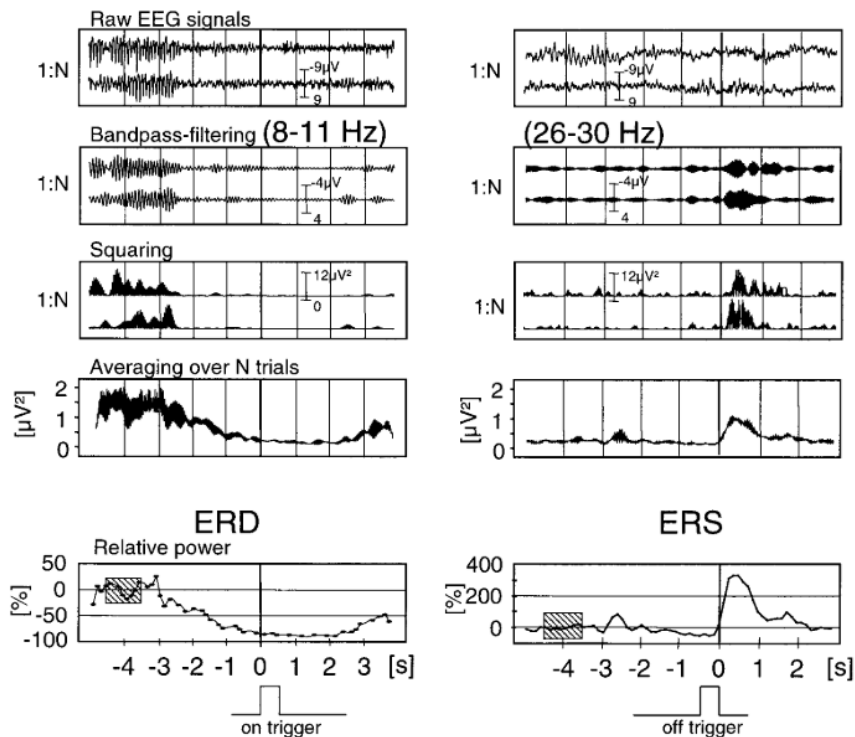


Figura 2.5: Passo a passo para identificação de DRE e SRE. Extraído de (PFURTSCHELLER; LOPES DA SILVA, 1999).

Apesar do fenômeno de DRE/SRE, o sinal de EEG durante IM é reconhecido na literatura como um sinal fortemente não-estacionário e não-linear, dependente da condição mental do indivíduo como cansaço, frustração e atenção.

### 2.3 Modelo para Interfaces Cérebro-Máquina

Uma interface cérebro-máquina é composta dos seguintes blocos: aquisição do sinal, condicionamento, processamento, classificação e atuação (Figura 2.6). O processamento pode ser subdividido nas etapas de pré-processamento, extração de características e seleção de características, esta última sendo opcional. No caso de métodos baseados em aprendizado profundo de máquinas (e.g.: redes neurais convolucionais), as etapas de processamento e classificação são agrupadas em um único bloco. O bloco de atuação consiste na interação da máquina com o mundo externo, podendo ser o controle de um equipamento qualquer, como uma cadeira de rodas (KIM; CARLSON; LEE, 2013), um quadricóptero (DUAN *et al.*, 2019), ou simplesmente uma tela para dar *feedback* ao usuário. As subseções a seguir descrevem os blocos de uma ICM com exceção do bloco de atuação, dando mais atenção aos blocos de processamento e classificação.




Figura 2.6: Diagrama de blocos de uma ICM.

### 2.3.1 Aquisição e Condicionamento de Sinais de EEG

A coleta de sinais de EEG usa posicionamento de eletrodos que segue tipicamente o sistema internacional 10-20 ou o sistema internacional 10-10, que contém todos os eletrodos do 10-20 e derivações intermediárias (Figura 2.7).

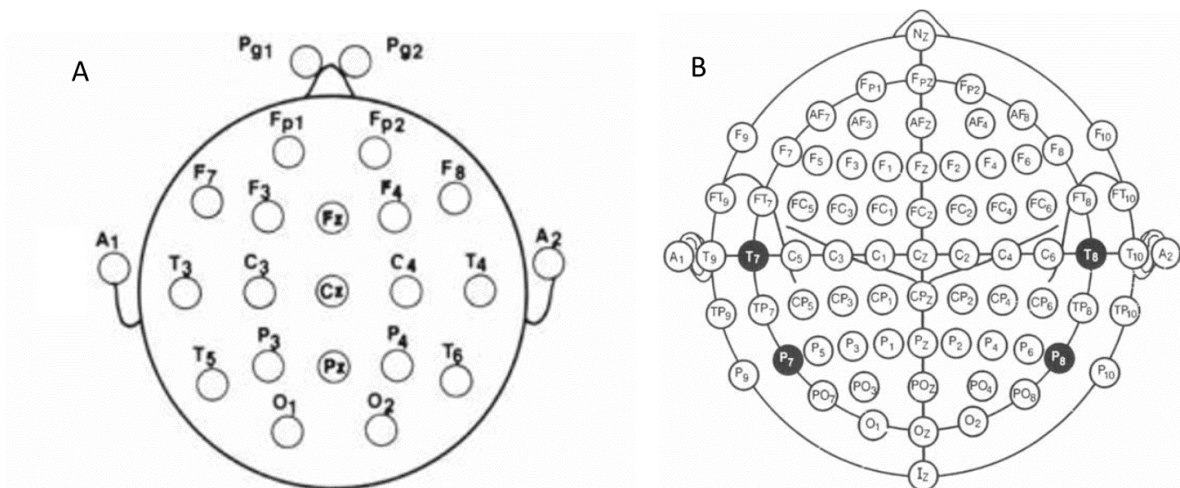


Figura 2.7: Sistema 10-20 de posicionamento (A) e sistema 10-10 (B). Modificado de NIEDERMEYER et al., 2016.

Os sinais de EEG costumam ser da ordem de microvolts e, dada a divisão de frequências usadas para seu estudo (NIEDERMEYER *et al.*, 2016), os sinais costumam ser filtrados de forma a conservar somente a faixa de 0,5 a 100 Hz, com filtragem notch na frequência da rede elétrica do local onde o sinal foi coletado (e.g.: 60 Hz no Brasil e 50 Hz na Europa).

Um dos desafios no processamento de EEG durante IM é a escolha de derivações (canais de registro) em que a IM estará melhor representada (maior razão sinal-ruído). Por um lado, se poderia usar apenas as derivações adjacentes ao córtex sensório-motor, que são as derivações fronto-centrais (sigla FC), centrais (sigla C) e centro-parietais (sigla CP), considerando a concentração espacial de DRE/SRE nas bandas alfa e beta desta região, conforme reportado na literatura. Por outro lado, pode ocorrer de uma determinada IM recrutar atividade em ampla

gama de derivações EEG, caso em que se teria informação evocada mais difusa e amplamente espalhada pelo escalpo, ou seja, casos em que há alta correlação entre derivações, ainda que distantes. Isto pode ocorrer pelo recrutamento de outras regiões para a construção da imagem mental por se tratar de uma tarefa cognitiva. Por outro lado, para a ampla aplicabilidade de uma ICM, procura-se utilizar o menor número de derivações possível (*e.g.*: C3, Cz e C4 são amplamente empregadas em trabalhos sobre IM) (GE; WANG; YU, 2014; SADIQ; YU; YUAN; FAN; et al., 2019; SHAHLAEI et al., 2019; STEYRL et al., 2014).

Neste contexto, Martinez-Leon et al. (2016) compararam o desempenho de classificação entre um equipamento de coleta de EEG clínico e um *headset* muito popular em pesquisas de ICM (Emotiv Epoc ®), para verificar se o headset seria suficiente para aplicações de ICM baseadas em IM, visto que se trata de um equipamento com menor número de derivações. Neste trabalho, os autores identificaram que a qualidade do EEG bruto é inegavelmente superior em equipamentos clínicos. Seu experimento consistiu em executar três tarefas mentais: imaginar movimento da mão direita, da mão esquerda e pensar em palavras que começassem com uma determinada letra. Apesar das limitações do estudo duas constatações foram feitas:

1. Para pessoas que apresentam um bom desempenho no uso de ICMs, o *headset* mostrou desempenho próximo do equipamento clínico, ambos em torno de 80% de acurácia para as tarefas motoras; porém para pessoas com desempenho médio e baixo no uso de ICMs, a acurácia com o equipamento clínico chega a ser 20 pontos percentuais superior (cerca de 80% com o clínico e de 60% com o *headset*).
2. A ausência de eletrodos adjacentes ao córtex motor no Emotiv Epoc ® prejudica consideravelmente o desempenho de classificação de uma ICM baseada em IM.

### 2.3.2 Pré-processamento

Nas etapas de coleta e condicionamento espera-se alterar minimamente o sinal registrado de forma a garantir qualidade e fidedignidade com relação ao fenômeno a ser estudado. Já na etapa de pré-processamento, é comum a aplicação de técnicas para i) filtragem visando a obter um sinal de banda estreita (*e.g.*: para o cálculo do envelope), ii) remoção de artefatos (*e.g.* descarte automático ou manual de épocas) e/ou iii) remoção de outros tipos de ruído (*e.g.* cálculo de média coerente para remoção de EEG de fundo).

Um dos métodos de pré-processamento mais empregados na análise de potenciais relacionados-a-evento (PRE) é o re-referenciamento, que consiste em alterar a referência de

sinal das derivações registradas, no caso de registros monopolares. Por exemplo, se poderia subtrair de cada uma das derivações do Sistema Internacional 10-20, a derivação correspondente a Fpz (eletrodo frontopolar na linha média). O trabalho de Hong et al. (2018) compara e discute extensivamente diferentes formas de re-referenciamento de eletrodos, como CAR (*common average reference*), bipolar e laplaciano, todos com o intuito de reduzir o impacto de artefatos de movimento.

### 2.3.3 Extração de Características e Classificação

Normalmente os sinais são filtrados nas bandas alfa, beta, alfa+beta (combinadas), ou ainda são usados bancos de filtros para otimizar a escolha de bandas de frequência de acordo com o usuário (ANG *et al.*, 2012).

Em 2008 foi realizada a quarta Competição de Interfaces Cérebro-Máquina de Berlim (CICMB), competição que teve como objetivo o desenvolvimento de algoritmos para resolver problemas de ICM a partir de bases de dados públicas disponibilizadas pelos organizadores. Em 2012 os responsáveis pela competição compilaram os resultados (TANGERMANN *et al.*, 2012). Para os problemas de imagética motora os participantes usaram em sua maioria técnicas baseadas em *Common Spatial Patterns* (CSP), uma técnica para determinação de um filtro espacial que otimiza a discriminação entre sinais de IM pré-processados de classes distintas. Os resultados foram reportados em termos do coeficiente *kappa* de Cohen, com os vencedores tendo valores médios  $\pm$  desvio-padrão de  $\kappa = 0,57 \pm 0,21$  para o problema de 4 classes e  $\kappa = 0,60 \pm 0,28$  para o problema de duas classes (ANG *et al.*, 2012). Estes valores de *kappa* correspondem, respectivamente, às acurácias médias  $\pm$  desvios-padrão de  $68 \pm 16 \%$  e  $80 \pm 14 \%$ .

Desde então a pesquisa em ICM baseada em IM continuou a se popularizar. O estudo de revisão de Hong et al. (2018) investigou quais as técnicas mais comumente utilizadas no processamento de sinais de EEG durante IM. Dentre as técnicas mais empregadas estão aquelas derivadas da CSP e métodos baseados na estimativa de potência nas bandas alfa e beta. Porém, os trabalhos que usam CSP junto com classificadores simples e populares como Máquina de Vetores de Suporte (SVM, de *Support Vector Machine*), Análise de Discriminante Linear (LDA, de *Linear Discriminant Analysis*) ou Regressão Logística (RL) costumam não atingir valores de acurácia superiores a 70% (MASHAT, LIN E ZHANG, 2019; RIQUELME-ROS et al., 2020). Ainda, alguns dos pontos negativos da CSP e variantes são a ocorrência de sobreajuste

(*overfitting*) quando muitas derivações são utilizadas, a variabilidade inter-individual de desempenho e a necessidade de calibração para cada indivíduo (SAHA *et al.*, 2018), o que dificulta uma aplicabilidade mais ampla de ICMs baseadas em IM.

### 2.3.4 Desafios para o Desenvolvimento de ICMs Baseadas em IM

Um desafio no uso de ICMs baseadas em EEG em geral é a prevalência de 15%-30% de pessoas que tem dificuldades em usá-las, por motivos ainda não muito bem esclarecidos. O termo mais comum na literatura para estas pessoas é o analfabetismo em ICM (*BCI-illiteracy*, em inglês). Porém devido à dificuldade inerente ao controle de ICMs mesmo com instruções adequadas e, para evitar a estigmatização pelo uso do termo analfabetismo, Riquelme-Ros *et al.* (2020) sugeriram o uso do termo “ineficiência em ICM” (*BCI-inefficiency* em inglês). De fato, mesmo pessoas com coordenação motora fenomenal como pianistas profissionais podem não conseguir operar uma ICM, sendo reportados valores de acurácia de classificação inferior a 60% (RIQUELME-ROS *et al.*, 2020).

Portanto, uma exploração de características tempo-frequência poderia expandir o entendimento da IM, buscando fatores que sejam invariantes aos indivíduos, ou que permitam identificar a necessidade de ajustes e executá-los de forma mais rápida e simplificada do que uma recalibração completa do sistema. Por exemplo, o estudo de Mashat, Lin e Zhang (2019) indicou que a análise da banda gama pode trazer informações sobre o estado mental do usuário, possibilitando diferenciar se a tarefa de IM é complexa ou simples para ele.

Outros trabalhos aplicaram a TDH e a TW a sinais de EEG durante IM. O trabalho de Bagh *et al.* (2020), por exemplo, usou a amplitude instantânea obtida pela TDH, alcançando uma acurácia de  $83 \pm 11$  % (média  $\pm$  desvio-padrão) para o problema de 2 classes da quarta Competição de ICM de Berlim (TANGERMANN *et al.*, 2012), e identificaram que o classificador SVM foi melhor do que o classificador por regressão logística. Embora similar, não é uma melhora substancial quando comparado aos  $80 \pm 14$  % de acurácia obtidos pelos vencedores da competição à época.

O trabalho de Sadiq *et al.* (2019) usou a TW empírica em conjunto com a TDH, aplicando-as às bases de dados IVa, IVb e IVc da terceira Competição de ICM de Berlin (BLANKERTZ *et al.*, 2006) ocorrida em 2005 (problemas de 2 classes de IM), atingindo acurácias médias entre 85% e 97% para a base IVa, para as diversas características e classificadores testados. O vencedor para este mesmo conjunto de dados na época da

competição obteve acurácia de 94,2% usando CSP, o segundo e terceiro colocados atingindo 85,1% e 83,5%, respectivamente (BLANKERTZ *et al.*, 2006).

Apesar dos desempenhos de classificação promissores reportados acima e a criação de *benchmarks* com os dados das competições de ICM, cabe salientar que muitos dos algoritmos citados foram desenvolvidos e testados com poucos indivíduos. Por exemplo, a base de dados 2A da quarta CICMB possui sinais de 9 indivíduos, sendo a maior base dentre as competições aqui citadas. Porém, um problema comum dos estudos apresentados até o momento é a ausência de uma classe de repouso, uma vez que o usuário nem sempre terá a intenção de executar um movimento/comando. Além disso, alguns conjuntos de dados não descrevem adequadamente a característica dos sujeitos, por exemplo, não informando a lateralidade (canhoto ou destro) nem a experiência em atividades que requerem elevada habilidade motora.

Felizmente, mais bases de dados públicas vêm sendo disponibilizadas, como o projeto BNCI Horizon (BRUNNER *et al.*, 2015), que compila dados de coleta de diferentes institutos europeus, incluindo os dados das CICMB. Como evolução na qualidade das coletas pode-se apontar a base de dados “*A Large Electroencephalographic Motor Imagery Dataset for Electroencephalographic Brain Computer Interfaces*” (KAYA *et al.*, 2018), com paradigmas experimentais de IM sincronizados com estímulos e paradigmas de IM espontânea (imaginada no ritmo do voluntário), e que incluem a classe de repouso. Esta base conta com sinais coletados de 13 indivíduos e descreve em mais detalhes os movimentos imaginados e o grau de ineficiência com ICMs, mas a lateralidade dos voluntários não foi registrada e o referenciamento dos eletrodos usado não é convencional.

Outro exemplo é a base de dados “*Continuous Sensorimotor Rhythm Based Brain Computer Interface Learning in a Large Population*” (STIEGER; ENGEL; HE, 2021) usada no trabalho de STIEGER *et al.* (2021), em que 76 dos 144 voluntários inscritos originalmente completaram todos os requisitos experimentais. Nesta base foram realizados experimentos também sincronizados com estímulo, porém, diferente das bases das CICMBs e da base de Kaya *et al.* (2018), a duração da IM variava de acordo com o tempo necessário para o usuário controlar a ICM para atingir um alvo. Esta base registrou diversas informações pertinentes dos voluntários como preferência manual, experiência prévia com esportes e instrumentos musicais ou outras habilidades motoras.

## 2.4 Análise Tempo-Frequência

Esta seção começa relembrando a Transformada Discreta de Fourier e o princípio de incerteza para a resolução tempo-frequência. Em seguida são apresentadas a Transformada de Fourier de Tempo Curto e a Transformada de Hilbert, usadas para analisar a evolução temporal de parâmetros espectrais. Então são discutidas as semelhanças e diferenças teóricas e práticas entre algumas técnicas tempo-frequência, tendo em vista a análise da SRE/DRE. Por último é apresentada uma teoria geral de análise tempo-frequência com base na distribuição de Wigner-Ville, que permite relacionar as principais distribuições tempo-frequência de sinais.

### 2.4.1 Transformada Discreta de Fourier

As transformadas e séries de Fourier compõem um ferramental matemático poderoso essencial para diversas áreas do conhecimento, como física, engenharia, matemática e ciência da computação. Desenvolvida pelo matemático Jean-Baptiste-Joseph Fourier (1768 - 1830) durante seu estudo da propagação de calor em corpos sólidos no começo do século XIX (LATHI, 2007), a transformada de Fourier é uma transformação linear que permite decompor um sinal (uni- ou multivariado) em seu espectro de frequência usando funções de base senoidais. As equações 2.1 e 2.2 (LATHI, 2007) descrevem a Transformada Discreta de Fourier (TDF) direta e inversa, respectivamente, para o sinal no tempo  $x[n]$  e seu espectro  $X[k]$ :

$$\mathcal{F}\{x[n]\} = X[k] = \sum_{n=0}^{N-1} x[n] e^{-jk\Omega_0 n}, \quad k = 0, 1, 2, \dots, N-1 \quad (2.1)$$

$$\mathcal{F}^{-1}\{X[k]\} = x[n] = \frac{1}{N} \sum_{k=0}^{N-1} X[k] e^{jk\Omega_0 n}, \quad n = 0, 1, 2, \dots, N-1 \quad (2.2)$$

$$\Omega_0 = \omega_0 T_s = \frac{2\pi}{N} \quad (2.3)$$

$$\omega_0 = 2\pi\Delta f = 2\pi \frac{F_s}{N}, \quad \Delta t = N \cdot T_s, \quad (2.4)$$

sendo  $\Omega_0$  a frequência fundamental angular normalizada,  $N$  o número de pontos do sinal,  $\omega_0$  a frequência fundamental angular em rad/s;  $F_s$  em Hz e  $T_s$  em s correspondem, respectivamente, à frequência e ao período de amostragem;  $\Delta f$  em Hz à resolução em frequência (ou, de forma

equivalente, à frequência fundamental) e  $\Delta t$  em s à duração do sinal (ou, de forma equivalente, à resolução temporal).

A TDF assume que o sinal  $x[n]$ , finito e discreto, é a representação de um único período de sua extensão periódica. Repare também que, caso se deseje interpretar a amplitude da TDF como a amplitude das senoides presentes no sinal, é necessário normalizá-la dividindo pelo número de pontos  $N$ . Porém, observe que a TDF fornece o espectro do sinal considerando a totalidade do tempo de coleta. Em outras palavras, é sabido que aquelas frequências estão presentes, mas não há informação de *quando* exatamente elas ocorreram. Como visto na seção 2.2.1 sobre a sincronização e dessincronização relacionada a evento, existem fenômenos não-estacionários para os quais é interessante estudar não somente o espectro do sinal, mas também como este espectro varia ao longo do tempo. Desta forma podemos entrar no campo da análise tempo-frequência. O conceito mais importante da análise tempo-frequência é o princípio de incerteza para as resoluções temporal e espectral. Repare que para um sinal digital de duração  $\Delta t$  com  $N$  pontos, sua representação pela TDF também possui  $N$  pontos com resolução em frequência  $\Delta f$ . O problema é que, na TDF, estas resoluções estão amarradas pela relação (que pode ser deduzida da eq. 2.4)

$$\Delta t \cdot \Delta f = 1, \quad (2.5)$$

ilustrando o princípio de incerteza. Em outras palavras, para se ter uma riqueza de informação do espectro do sinal é preciso renunciar à precisão sobre quando aquele espectro ocorreu, e vice-versa.

#### 2.4.2 Transformada de Fourier de Tempo Curto e o Espectrograma

Pensando em como analisar a variação do espectro de um sinal ao longo do tempo, uma solução simples é dividir o sinal de duração  $T$  em segmentos de duração  $T_B$  usando uma função janela simétrica  $g(t)$  e, em seguida, calcular a transformada de Fourier de cada um dos segmentos separadamente. Matematicamente, em tempo contínuo, este procedimento pode ser descrito pela expressão

$$SF\{x(t)\}(u, f) = SF_x(u, f) = \int_{-\infty}^{+\infty} x(t)g(t - u)e^{-j2\pi ft} dt. \quad (2.6)$$

chamada de transformada de Fourier de tempo curto (*short time Fourier transform*, em inglês) ou transformada de Fourier janelada (*windowed Fourier Transform*, em inglês), introduzida por Gabor (GABOR, 1946). Observe que, apesar dos limites de integração serem infinitos, a função de janela é tipicamente finita, limitando a região de integração. Ou seja, para cada deslocamento  $u$  da janela, é calculada a transformada de Fourier do sinal no intervalo  $\left[u - \frac{T_B}{2}, u + \frac{T_B}{2}\right]$ , o que permite associar o espectro resultante aos valores correspondentes de  $u$ .

O mesmo procedimento pode ser usado no caso discreto usando a TDF. Primeiramente, o sinal precisa ser segmentado em janelas de  $L < N$  amostras, deslocadas de  $r$  em  $r$  amostras. As janelas podem ou não ter sobreposição segundo a escolha de  $r$ . Se  $r = L$ , então as janelas possuem o máximo de sobreposição; se  $r = L$ , então as janelas não têm nenhuma sobreposição. Em seguida, a TDF é calculada para cada janela, gerando a TFTC. Matematicamente, a TFTC pode ser descrita pela expressão

$$TFTC_x[m, k] = \frac{1}{C} \sum_{n=0}^{N-1} x[n]g[n - mr]e^{-jk\Omega_0 n}, \quad (2.7)$$

$$k = 0, 1, 2, \dots, L - 1, \quad m = 0, 1, 2, \dots, \frac{N - L + r}{r} - 1, \quad \Omega_0 = \frac{2\pi}{L}$$

onde  $g[n]$  é a função janela discreta de tamanho  $L$ , normalmente sendo simétrica ou quase simétrica em torno de  $L/2$  e  $C$  corresponde a uma constante de correção de amplitude devido à aplicação do janelamento. Assim, para que a amplitude dos coeficientes da TFTC corresponda às amplitudes das senoides presentes no sinal original, é preciso usar o fator de correção

$$C = \sum_{n=0}^{L-1} |g[n]|, \quad (2.8)$$

que corresponde à amplitude total da janela. Alternativamente, para que a amplitude dos coeficientes da TFTC corresponda aos valores eficazes das senoides presentes no sinal original, utiliza-se o fator de correção

$$C = \sqrt{L \left( \sum_{n=0}^{L-1} |g[n]|^2 \right)}. \quad (2.9)$$

O espectrograma de um sinal representa a evolução temporal de sua densidade espectral de potência, podendo ser calculado como o quadrado da amplitude da TFTC.

Com vistas a ilustrar o funcionamento da TFTC, será usado um exemplo com base em sinal simulado para mostrar o espectrograma e discutir brevemente o efeito da escolha da função janela. A janela retangular é a que altera menos o sinal, ao mesmo tempo que é a que gera o maior efeito de vazamento espectral na representação devido a eventuais descontinuidades ao se considerar o trecho de sinal analisado como periódico (HARRIS, 1978). Outras janelas, como a *Hann*, eliminam este efeito de borda ao custo de alterarem o sinal original. Considere o sinal amostrado em 250 Hz com 10 s de duração (Figura 2.8) descrito por

$$x(n) = x_1(n) + x_2(n) + x_3(n) \quad (2.10)$$

onde  $x_1(n)$  é um *chirp* linear com frequência variando de 100 Hz a 10 Hz,  $x_2(n)$  é *chirp* quadrático com frequência variando de 0 a 100 Hz, e  $x_3(n)$  uma senoide de 25 Hz com começo em  $t=1$  s e final em  $t=3$  s e multiplicada pela janela gaussiana definida por  $g(t) = \exp\left(-\frac{(t-2)^2}{2(0.33)^2}\right)$ .

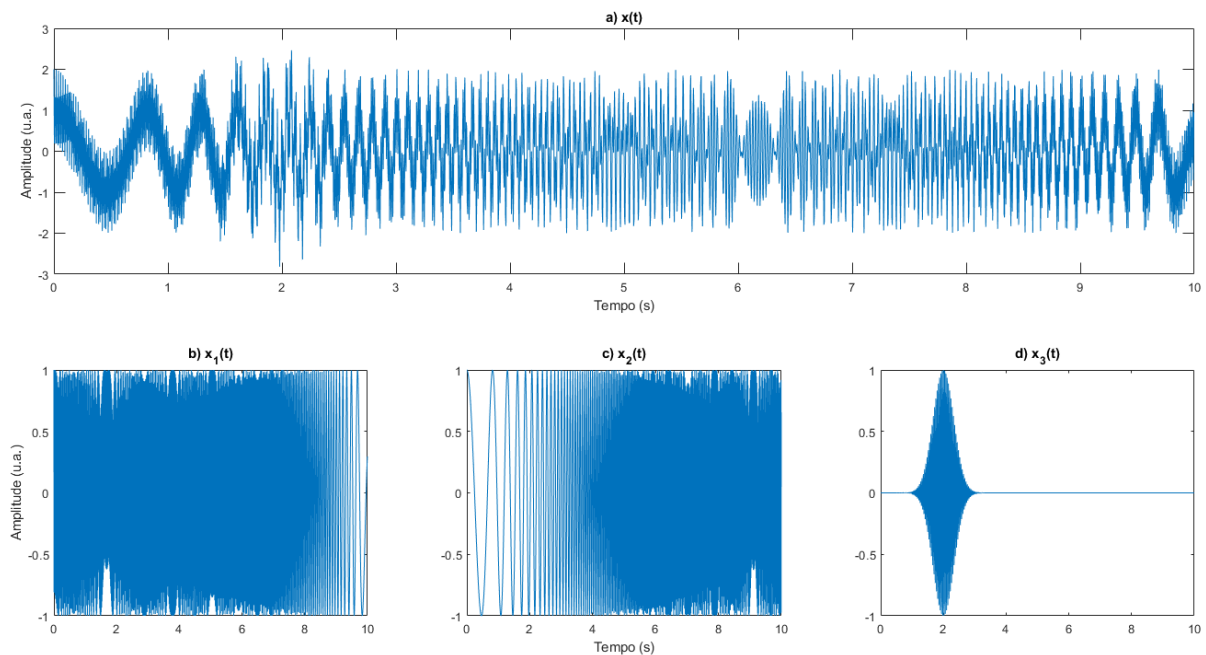


Figura 2.8: Sinal (a) composto por um *chirp* linear decrescente (b), um *chirp* quadrático crescente (c), e uma senoide monotônica localizada no tempo (d).

A Figura 2.9 mostra o espectrograma do sinal da eq. (2.10), usando-se, respectivamente, uma janela retangular e uma janela *Hann* com duração de 1 s e sobreposição máxima entre as janelas. O eixo das abcissas representa o tempo, o eixo das ordenadas a frequência e a escala de cor indica a potência. Observe como a distribuição é mais dispersa (curvas com rastro mais espalhado) usando uma janela retangular do que usando a janela *Hann* devido ao vazamento espectral. Observe também o visual quadriculado de ambas, parecendo “escadinhas”, que ilustra a resolução temporal e em frequência, ou seja, na verdade, representam informação não de um único instante e frequência, mas sim de uma região do plano tempo-frequência. São claras as 3 componentes do sinal: i) uma reta decrescente correspondente a  $x_1$ , ii) uma parábola ascendente correspondente a  $x_2$ , e iii) um segmento de reta na frequência de 25Hz entre 1 e 3 segundos correspondente a  $x_3$ . Para uma revisão mais aprofundada entre os vários tipos de funções janela, sugere-se a leitura de Harris (1878) e Heinzel; Rüdiger; Schilling (2002).




Figura 2.9: Espectrogramas obtidos da TFTC usando janela retangular e janela *Hann*.

### 2.4.3 Sinal Analítico e a Transformada de Hilbert

Outra forma de analisar as características tempo-frequência de um sinal real é tentar representá-lo por sua versão analítica. Um sinal analítico é, por definição, todo sinal cuja transformada de Fourier possui apenas frequências não-negativas, portanto, se trata de um sinal complexo. Dessa forma um sinal analítico  $x_a(t)$  pode ser expresso como

$$x_a(t) = a_i(t)e^{j\phi_i(t)},$$

$$a_i(t) \stackrel{\text{def}}{=} |x_a(t)|, \quad \phi_i(t) \stackrel{\text{def}}{=} \arg(x_a(t)).$$
(2.11)

A partir do sinal analítico podem ser obtidos os parâmetros espectrais dinâmicos (PED)

do sinal. A função  $a_i(t)$  é a amplitude instantânea ( $A_i$ ), ou envelope, e  $\phi_i(t)$  é a fase instantânea do sinal, ambas funções reais. A partir de  $a_i(t)$  e  $\phi_i(t)$  podem ser obtidas a potência instantânea  $p_i(t)$ , a frequência angular instantânea  $\omega_i(t)$  e a frequência instantânea  $f_i(t)$  ( $F_i$ ), de acordo com as expressões

$$p_i(t) = [a_i(t)]^2, \quad (2.12)$$

$$\omega_i(t) = \frac{d}{dt} \phi_i(t), \quad f_i(t) = \frac{1}{2\pi} \omega_i(t). \quad (2.13)$$

Note que o sinal real associado ao sinal analítico pode ser descrito como a multiplicação de duas funções, uma moduladora de amplitude multiplicada por uma modulada em frequência

$$\mathcal{R}e[x_a(t)] = x(t) = a_i(t) \cos\left(\phi_i(t_0) + 2\pi \int_{t_0}^t f_i(\tau) d\tau\right), \quad (2.14)$$

desta forma os PEDs do sinal analítico são os mesmos do sinal real de interesse.

Uma forma de obter a representação analítica de um sinal real é a partir de sua transformada de Hilbert (TH). A TH é um operador linear e pode ser definido de três maneiras (BENDAT; PIERSOL, 2011), como descrito a seguir, sendo que as duas últimas são de maior interesse para a implementação computacional.

Definição 1) *A transformada de Hilbert é a parte imaginária de um sinal analítico.*

$$\mathcal{H}\{x(t)\} = \tilde{x}(t) = \mathcal{I}m[x_a(t)]. \quad (2.15)$$

Portanto

$$x_a(t) = x(t) + j\tilde{x}(t). \quad (2.16)$$

Definição 2) *A transformada de Hilbert é o resultado da convolução de  $x(t)$  com  $(1/\pi t)$ .*

$$\tilde{x}(t) = x(t) * \frac{1}{\pi t} = \int_{-\infty}^{+\infty} \frac{x(\tau)}{\pi(t - \tau)} d\tau \quad (2.17)$$

Definição 3) A transformada de Hilbert é um Sistema Deslocador de Fase de  $\pi/2$  radianos.

Nesse caso  $\tilde{x}(t)$  é obtido pela transformada inversa de Fourier de tempo contínuo de  $\tilde{X}(f)$

$$\tilde{x}(t) = \mathcal{F}^{-1}\{\tilde{X}(f)\} = \int_{-\infty}^{+\infty} \tilde{X}(f)e^{j2\pi ft} df, \quad (2.18)$$

que por sua vez é obtida de  $X(f)$  pela expressão

$$\tilde{X}(f) = \begin{cases} -jX(f), & \text{se } f > 0 \\ jX(f), & \text{se } f < 0 \\ 0, & \text{se } f = 0 \end{cases} \quad (2.19)$$

uma vez que

$$\mathcal{F}\left\{\frac{1}{\pi t}\right\} = \begin{cases} -j, & \text{se } f > 0 \\ j, & \text{se } f < 0 \end{cases}. \quad (2.20)$$

Como para aplicações do mundo real os sinais coletados são geralmente reais, limitados e de duração finita, a transformada de Fourier e, portanto, a transformada de Hilbert sempre existirão.

A partir das definições 2 e 3, é possível definir a Transformada Discreta de Hilbert (TDH). A TDH pode ser obtida tanto através da TDF de um sinal, quanto pela aproximação da resposta ao impulso por um filtro FIR. A resposta ao impulso discreta da TDH é dada por (OPPENHEIM; SCHAFER, 2014)

$$h[n] \stackrel{\text{def}}{=} \begin{cases} \frac{2}{\pi n}, & \text{se } n \text{ for ímpar} \\ 0, & \text{se } n \text{ for par} \end{cases}, \quad (2.21)$$

assim

$$\tilde{x}[n] = x[n] * h[n]. \quad (2.22)$$

Para obter a TDH a partir da TDF, basta aplicar a mesma operação de deslocamento de fase descrita anteriormente, seguida pela transformada inversa

$$\tilde{X}[k] = \begin{cases} -jX[k], & \text{se } k = 1, 2, \dots, \lfloor \frac{N}{2} \rfloor \\ jX[k], & \text{se } k = \lfloor \frac{N}{2} \rfloor + 1, \lfloor \frac{N}{2} \rfloor + 2, \dots, N - 1 \\ 0, & \text{se } k = 0 \end{cases} \quad (2.23)$$

$$\tilde{x}[n] = \mathcal{F}^{-1}\{\tilde{X}[k]\},$$

lembrando que o índice  $\lfloor N/2 \rfloor$  corresponde à  $F_s/2$ , onde  $F_s$  é a frequência de amostragem; assim os índices da metade superior correspondem às frequências negativas.

Como  $x_a(t) = x(t) + j\tilde{x}(t)$ , então a amplitude instantânea pode ser prontamente obtida combinando o sinal original e sua transformada de Hilbert pela expressão

$$a_i(t) = \sqrt{x^2(t) + \tilde{x}^2(t)}. \quad (2.24)$$

Como  $\phi_i(t) = \tan^{-1}\left(\frac{\tilde{x}(t)}{x(t)}\right)$ , dessa forma ao se aplicar a regra da cadeia a  $\phi_i(t)$ , a frequência instantânea pode ser obtida de  $x(t)$  e  $\tilde{x}(t)$  com a expressão

$$f_i(t) = \frac{1}{2\pi} \frac{\tilde{x}'(t)x(t) - \tilde{x}(t)x'(t)}{x^2(t) + \tilde{x}^2(t)} = \frac{1}{2\pi} \frac{\tilde{x}'(t)x(t) - \tilde{x}(t)x'(t)}{a_i^2(t)}. \quad (2.25)$$

Isto mostra que podem surgir artefatos nos pontos onde a  $A_i$  é nula ou muito pequena, levando  $f_i(t)$  a valores equivocadamente elevados. Por último observe que os PEDs para sinais discretos são calculados usando as mesmas expressões para o caso contínuo, devendo ter atenção para a forma como a operação de diferenciação será aproximada.

A TDH não é a única forma de decompor um sinal em componentes moduladas em amplitude e em frequência. Outros métodos como a Decomposição em Médias Locais (*Local Mean Decomposition* em inglês) (SMITH, 2005), a Decomposição em Modos Empíricos (*Empirical Mode Decomposition*) (HUANG *et al.*, 1998) ou uso iterativo da TDH podem ser

utilizados para extrair o envelope e a frequência instantânea de um sinal, como descrito no trabalho “*On Instantaneous Frequency*” (HUANG *et al.*, 2011).

A seguir são mostrados alguns exemplos do uso da TDH para a obtenção do envelope e da frequência instantânea de alguns sinais e são discutidos alguns aspectos práticos. A Figura 2.10 contém 3 sinais simulados com 10 s de registro a uma frequência de amostragem de 250 Hz, cada um com particularidades desejadas de serem recuperadas em uma análise Tempo-Frequência: a) sinal de frequência constante em 5 Hz e amplitude variável segundo janela Hann; b) sinal de amplitude constante com frequência variando conforme uma parábola, com frequência inicial e final em 1 Hz e valor máximo em 5 Hz; c) um *chirp* linear com frequência aumentando de 1 Hz a 5 Hz, com amplitude seguindo uma janela Tukey com 50% de fração cosseno.




Figura 2.10 - Sinais de exemplo para processamento com TDH.

Na Figura 2.11 estão a amplitude instantânea (à esquerda, traçado espesso vermelho) e a frequência instantânea (à direita) obtida de cada sinal usando a TDH. As características do sinal a) foram recuperadas quase perfeitamente, a menos de artefato de borda na frequência instantânea nas extremidades do sinal. Em b) a  $A_i$  e a  $F_i$  ficaram ainda bem fidedignas às características do sinal, mas apresentam oscilações devido a efeito de borda por conta de discontinuidades no sinal. Embora o envelope do sinal c) tenha sido bem recuperado, a  $F_i$  apresentou espículas nas bordas do sinal.

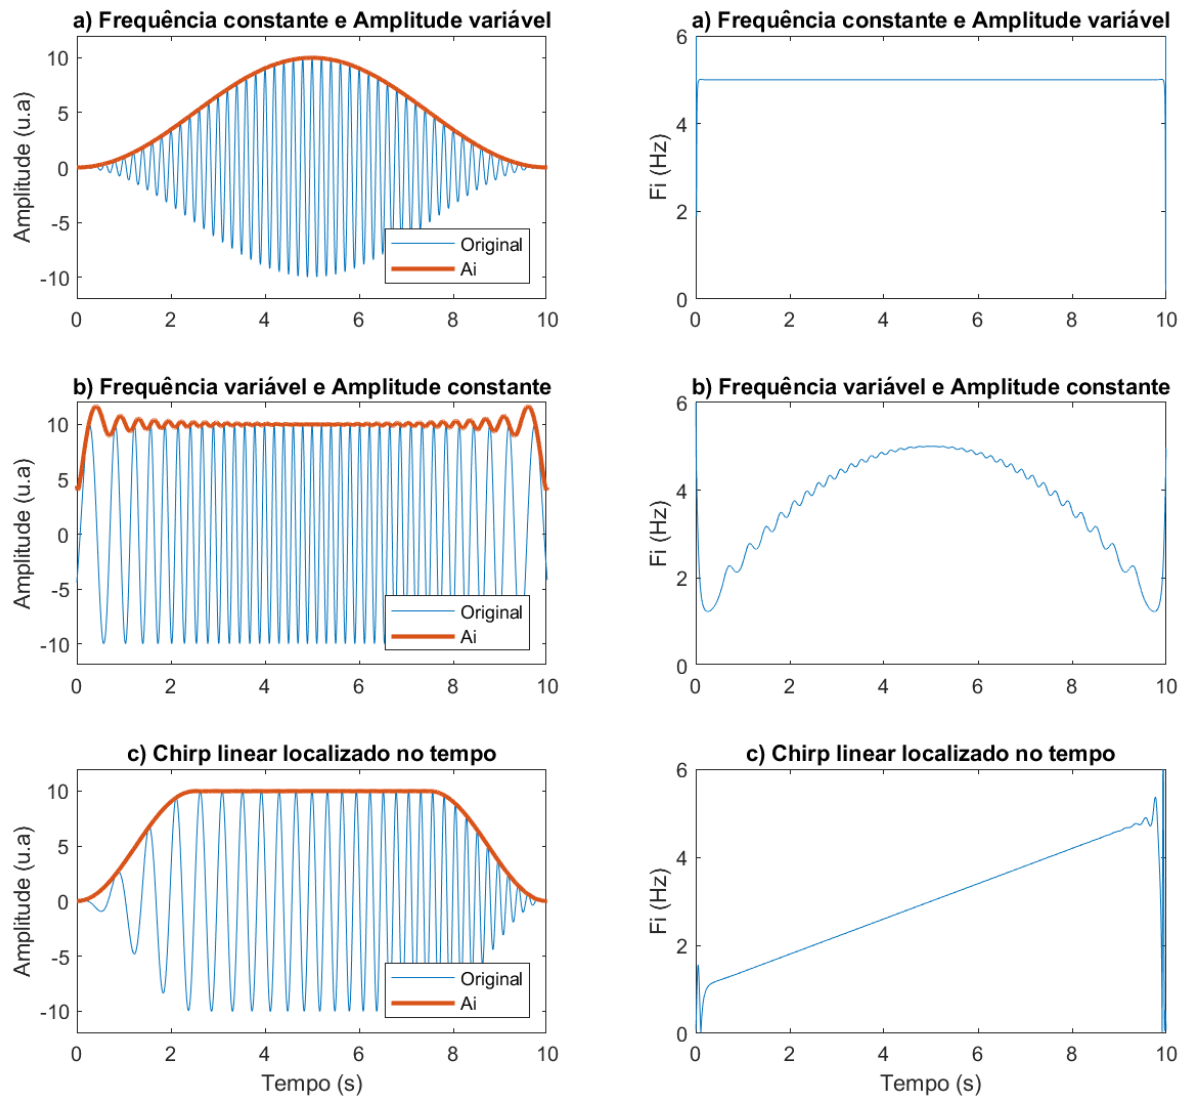


Figura 2.11 - Amplitudes e frequências instantâneas dos sinais da Figura 2.10.

Observe que para obter  $A_i$  e  $F_i$  foi necessário usar a duração completa do sinal, demonstrando que, ao menos da forma calculada a partir da função *hilbert()* em MATLAB®, se trata de um processamento não causal. Uma forma causal de se obter a TDH de um sinal seria usando o truncamento do filtro de resposta ao impulso finita definido na equação 2.21, adicionando um atraso na saída. Outra forma, a usada neste trabalho, consiste em usar uma janela deslizante, calcular a sequência de  $A_i$  e  $F_i$  para a janela, e usar a mediana dos PEDs como o valor único de  $A_i$  e de  $F_i$  correspondente ao índice de tempo final daquela janela. Por exemplo, se a janela tem duração 1,0 s e está processando o trecho de 4,5 s a 5,5 s de um sinal, o resultado das medianas dos PEDs serão atribuídos ao índice correspondente a  $t = 5,5$  s.

A Figura 2.12 mostra o resultado de aplicar esta estratégia aos sinais da Figura 2.10, usando janelas de 1,0 s. A menos do atraso de processamento, os envelopes e frequências

instantâneas dos três sinais foram recuperados com sucesso. Para o sinal a) o envelope obtido usando a TDH do sinal completo e obtido pela TDH de janelas do sinal são igualmente suaves, enquanto a frequência instantânea apresenta oscilações de baixa amplitude no início e no final do sinal usando a janela deslizante. Para o sinal b) os PEDs obtidos usando a janela deslizante não possuem as oscilações características de artefatos de descontinuidade ou borda. Por último, os PEDs do sinal c) obtidos usando janela deslizante são menos suaves do que os obtidos usando a TDH do sinal completo, e a frequência instantânea usando janela deslizante não apresentou espículas nas bordas.

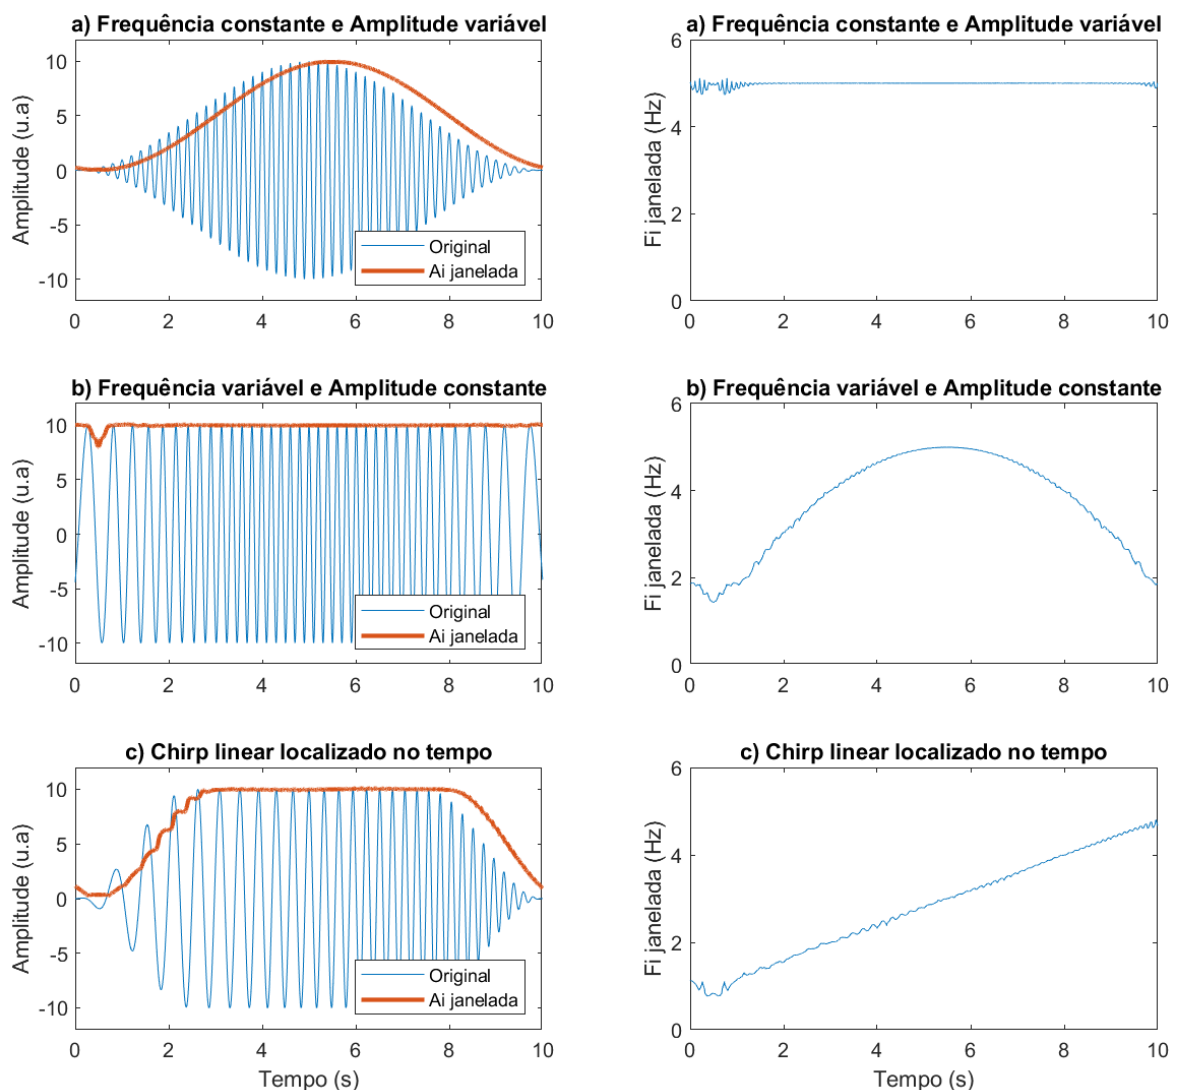


Figura 2.12 - Amplitudes e frequências instantâneas dos sinais da Figura 2.10, usando a estratégia de janela deslizante.

Concluindo, há uma diferença entre poder representar um sinal pela expressão como o produto de um envelope por um sinal modulado em frequência, e o fenômeno subjacente

gerador do sinal ser bem modelado por ela. Esta observação é resultado do teorema de Bedrosian (BEDROSIAN, 1963), que diz que se  $x(t) = f(t)g(t)$ , com  $|G(f)| = 0$  para  $|f| < f_0$  e com  $|F(f)| = 0$  para  $|f| > f_0$ , ou seja, que os espectros de  $f(t)$  e  $g(t)$  não se cruzam, então  $\tilde{x}(t) = f(t)\tilde{g}(t)$ . Dessa forma, se o sinal de interesse for da forma  $x(t) = a_i(t) \cos(\phi_i(t))$  e as funções  $a_i(t)$  e  $\cos(\phi_i(t))$  respeitarem as condições do teorema de Bedrosian, ou seja, se o envelope variar lentamente em relação a  $\cos(\phi_i(t))$ , então  $\tilde{x}(t) = a_i(t) \sin(\phi_i(t))$ , permitindo recuperar o envelope e a fase instantânea a partir do sinal original e sua transformada de Hilbert.

Na seção seguinte se discute a resolução temporal e espectral dos PEDs. A resolução espectral é  $F_s/N$ , a mesma resolução da TDF utilizada para computar a TDH, o que implica que a  $F_i$  é quantizada e só poderia assumir valores múltiplos de  $F_s/N$ , sendo  $N$  o número de amostras do sinal.

#### 2.4.4 Relações entre Distribuições Tempo-Frequência

Pode ser demonstrado que diferentes distribuições de energia tempo-frequência, como o espectrograma e o escalograma, são relacionadas, sendo todas versões suavizadas da distribuição de Wigner-Ville (MALLAT, 1999). Para análise de sinais não-estacionários, pode-se usar o auto espectro instantâneo definido por

$$\mathcal{W}_{xx}(f, t) = \int_{-\infty}^{+\infty} E \left[ x \left( t - \frac{\tau}{2} \right) x^* \left( t + \frac{\tau}{2} \right) \right] e^{-j2\pi f \tau} d\tau. \quad (2.26)$$

A equação 2.26 sem o operador de valor esperado  $E[\cdot]$  é a distribuição de Wigner-Ville de um sinal (WIGNER, 1932; VILLE, 1948)

$$WD_x(t, f) = \int_{-\infty}^{+\infty} x \left( t - \frac{\tau}{2} \right) x^* \left( t + \frac{\tau}{2} \right) e^{-j2\pi f \tau} d\tau, \quad (2.27)$$

usada por Ville para estudar a frequência instantânea e estudada previamente por Wigner. A partir do sinal analítico

$$x_a(t) = x(t) + j\tilde{x}(t) = a(t)e^{j\theta(t)}, \quad (2.28)$$

$$a(t) = \sqrt{x(t) + \tilde{x}(t)}, \quad \theta(t) = \text{atan} \left( \frac{\tilde{x}(t)}{x(t)} \right) \quad (2.29)$$

é possível provar que a frequência instantânea é a média da frequência ponderada pela distribuição de Wigner-Ville do sinal analítico (MALLAT, 1999):

$$\theta'(t) = \frac{\int_{-\infty}^{+\infty} f W D_{x_a}(f, t) df}{\int_{-\infty}^{+\infty} W D_{x_a}(f, t) df}. \quad (2.30)$$

Apesar de poder ser usada para determinar a frequência instantânea de um sinal, a representação tempo-frequência gerada pela distribuição de Wigner-Ville pode dificultar a análise da informação por apresentar termos cruzados de interferência. A presença destes termos faz com que a distribuição de Wigner-Ville apresente valores negativos, o que é indesejado para interpretá-la como uma distribuição de energia. Já métodos como o espectrograma obtido pela TFTC ou o escalograma obtido da transformada *Wavelet* são representações não-negativas, adequadas para descrever uma distribuição de energia. Porém, é possível demonstrar que tanto o escalograma quanto o espectrograma são versões suavizadas da distribuição de Wigner-Ville. De forma geral, uma distribuição quadrática tempo-frequência qualquer  $D_{TF}$  pode ser obtida da distribuição de Wigner-Ville por uma operação de suavização (MALLAT, 1999)

$$D_{TF}\{x(t)\}(t, f) = \frac{1}{2\pi} \int \int W V_x(t', f') W V_\phi(t', f') dt' df', \quad (2.31)$$

onde  $W V_\phi(t, f)$  é a distribuição de Wigner-Ville das funções de base  $\phi(t, f)$  da transformada utilizada, sendo que esta pode ser descrita de forma genérica como uma função janela  $g(t)$  multiplicada pela exponencial complexa (BRUNS, 2004) para o caso da TFTC, TDH e da transformada *Wavelet* com *wavelets* analíticas:

$$\phi(t, f) = g(t) e^{j2\pi f t}. \quad (2.32)$$

Para ilustrar as diferentes representações, considere o sinal da Figura 2.8, usado na seção 2.4.2 para estudar a TFTC e o espectrograma. A Figura 2.13 mostra a distribuição de Wigner-Ville, o espectrograma e o escalograma deste sinal. O espectrograma foi obtido pelo quadrado da amplitude da TFTC do sinal usando uma janela *Hann* de 1 s com o máximo de sobreposição.

O escalograma e a distribuição de Wigner-Ville foram gerados usando os parâmetros padrão, respectivamente, das funções *cwt* e *wvd* no MATLAB®. Foram preservados apenas os valores positivos da distribuição de Wigner-Ville para facilitar a visualização. A Distribuição de Wigner-Ville e o espectrograma estão representados com os ambos os eixos em escala linear, enquanto o escalograma está com o eixo de frequência em escala logarítmica. Apesar da magnitude do escalograma estar em unidade diferente das outras duas, repare como é possível identificar os *chirps* e a senoide localizada no tempo em todas as representações, além de identificar os padrões de interferência na Distribuição de Wigner-Ville, padrão inexistente nas outras duas.




Figura 2.13: Comparação entre a distribuição de Wigner-Ville (apenas valores positivos), o espectrograma e o escalograma do sinal de exemplo.

Bruns (2004), em seu trabalho *Fourier-, Hilbert- and wavelet-based signal analysis: Are they really different approaches?* discute a equivalência matemática entre a transformada Wavelet, TDH, e TFTC para análise tempo-frequência, tendo em vista aplicações em neurologia. Para tal ele desconsidera a complexidade computacional, o que permite equiparar a TFTC e a TDH à transformada *Wavelet* em termos de compromisso entre as resoluções temporal e espectral. Ele considera o uso convencional da TFTC, que a transformada *Wavelet* usa *wavelets* analíticas convencionais como a de Morse, e que a análise pela TDH é feita usando os envelopes do sinal após passá-lo por um banco de filtros passa-faixa equivalentes às frequências da TFTC. Feitas estas considerações, Bruns conclui que as técnicas são matematicamente equivalentes, estando a diferença somente na função janela que multiplica a exponencial complexa. Entretanto, note que se o sinal não for de banda estreita, ao processá-lo com a TDH, o envelope pode não ser mais diretamente relacionado à densidade espectral da faixa de frequência analisada (violando o teorema de Bedrosian). Além disso, no caso da TW, pode-se usar *wavelets* não analíticas e técnicas adaptativas como a TW empírica, o que também levar à não equivalência entre as técnicas.

Por último, cada uma destas técnicas possui complexidade computacional distinta, com a TW podendo chegar a  $O(N)$  no melhor caso e a TFTC chegando a  $O(M\log_2(L))$ , onde  $N$  é o número de amostras do sinal e  $L$  o tamanho da janela. Já a análise pela TDH é a mais custosa, por precisar de  $N$  operações de filtragem seguida por  $N$  TDF diretas e  $N$  TDF inversas, ou seja,  $O(N^2\log_2(N))$ .

## Capítulo 3: Materiais e métodos

Este capítulo contém as informações sobre o conjunto de dados público usado e seu protocolo de coleta. Em seguida, estão descritas as etapas de processamento dos sinais de EEG, o detalhamento das estratégias para analisar as diversas formas de onda e os testes estatísticos usados.

### 3.1 Base de Dados

Para este trabalho foi selecionado um conjunto de dados público e gratuito de registro de EEG durante IM, o conjunto de *benchmark* “2A – Imagética Motora Contínua Multi-Classe” da quarta CICMB realizada em 2008 (TANGERMANN *et al.*, 2012). Para facilitar, este conjunto será referido como “CICMB-2A” daqui em diante. A Tabela 3.1 resume as características da base.

Tabela 3.1: Resumo comparativo dos conjuntos de dados

	CICMB-2A
Nº de indivíduos	9
Nº de derivações	22
Classes	4 classes: IM da mão direita, mão esquerda, ambos os pés e língua.
Nº de ensaios/classe	72 por sessão de coleta.
Nº de sessões/indivíduo	2
Duração média de um ensaio	7,5 s
Duração da IM	4,0 s
Frequência de amostragem	250 Hz

#### 3.1.1 Coleta e Condicionamento do Conjunto de Dados CICMB-2A

Os sinais foram coletados de 9 voluntários para 4 tarefas de IM: mão esquerda (ME), mão direita (MD), ambos os pés, e língua. Cada voluntário participou de duas sessões realizadas em dias diferentes. Cada sessão foi dividida em 6 blocos com 48 ensaios (sendo 12 para cada classe de movimento), ou seja, 72 ensaios para cada classe no total com um descanso curto entre os

blocos. Esse conjunto de dados pode ser baixado de <http://www.bbci.de/competition/iv/>.

Em cada sessão, os voluntários ficaram sentados, em uma poltrona confortável com descanso de braço, em frente a uma tela de computador. O protocolo experimental dos ensaios é descrito a seguir e ilustrado na Figura 3.1:

- Em  $t = 0$  s, foi apresentado um sinal acústico e uma cruz de fixação apareceu na tela preta.
- Em  $t = 2$  s, foi mostrada uma seta que poderia assumir quatro direções: direita, esquerda, para cima e para baixo, sendo que cada direção correspondia a uma classe de movimento, MD, ME, língua ou pés, respectivamente. Esta seta indicava o início da IM.
- Em  $t = 3,25$ s, a seta sumia, sendo preservada a cruz de fixação.
- Em  $t = 6$  s, a cruz de fixação desaparecia da tela, sinalizando o fim da imaginação de movimento solicitada ao voluntário.
- Em seguida, realizou-se uma pequena pausa, na qual a tela do monitor mantinha-se preta durante pelo menos 1,5 s.




Figura 3.1: Protocolo experimental de um ensaio do conjunto CICMB-2A. Modificada de (TANGERMANN et al., 2012).

Os sinais de EEG foram coletados a partir de 22 eletrodos de Ag/AgCl posicionados em locais correspondentes a um subconjunto de derivações do Sistema Internacional 10-10 (Figura 3.2). Para todos os sinais utilizou-se a mastoide esquerda como referência de sinal e a mastoide direita como terra. A frequência de amostragem ( $F_s$ ) foi de 250 Hz e os sinais passaram por um filtro passa-banda de 0,5 a 100 Hz e por um filtro *notch* em 50 Hz para reduzir a influência da rede elétrica, uma vez que os sinais foram coletados na Europa. É seguro assumir apenas que se trata de IM explícita. Neste trabalho foram usados apenas os dados da primeira sessão de coleta.




Figura 3.2: Disposição dos eletrodos para coleta de EEG do conjunto CICMB-2A. Extraída de (TANGERMANN *et al.*, 2012).

### 3.2 Pré-Processamento: Média Coerente e Filtragem

Nesta seção estão descritos como foram aplicadas as técnicas de média coerente e filtragem. Estas técnicas têm como função a redução do ruído frente ao potencial relacionado a evento (imagética motora).

Com base na informação de início de ensaio, os ensaios de cada classe foram segmentados em janelas de 7,5 segundos. Para reduzir o efeito do EEG de fundo, foi calculada a média coerente (MC) para uma mesma classe e voluntário, que consiste na média ponto-a-ponto de janelas de EEG, expressa matematicamente por:

$$x[n] = \bar{y}[n] = \frac{1}{M} \sum_{i=1}^M y_i[n], \quad (3.1)$$

onde  $y_i[n]$  corresponde à  $i$ -ésima janela de EEG para uma dada classe e  $M$  é o número de janelas. O uso da média coerente parte do pressuposto que o sinal coletado  $y_i[n]$  é formado por um sinal sincronizado com o estímulo  $s[n]$  somado à atividade de fundo  $r_i[n]$ . Como a atividade de fundo se comporta como um ruído branco gaussiano de média nula, ao se tomar a média entre as épocas é possível isolar somente a atividade relacionada a evento. Matematicamente:

$$\bar{y}[n] = \frac{1}{M} \sum_{i=1}^M y_i[n] = \frac{1}{M} \sum_{i=1}^M s[n] + \frac{1}{M} \sum_{i=1}^M r_i[n] = \frac{1}{M} \sum_{i=1}^M s[n] + 0 = s[n]. \quad (3.2)$$

Visando uniformizar a análise para todos os voluntários, foram utilizadas  $M = 45$  janelas, que foi o menor número de ensaios considerados válidos (sem presença de artefato) computados dentre todos os voluntários. Os ensaios considerados ruidosos ou comprometidos por artefatos foram descartados com base em identificação realizada por inspeção visual de um especialista e indicada por marcadores nos arquivos do próprio conjunto de dados (TANGERMANN *et al.*, 2012). Após a aplicação da MC, os sinais foram filtrados por *Butterworth* digital, passa-baixa de ordem 4, fase nula, com frequência de corte em 50 Hz.

### 3.3 Processamento: Parâmetros Espectrais Dinâmicos (PEDs)

Nas seções consecutivas estão descritos os cálculos usados para obter os PEDs a partir da TDH (seção 3.3.1) e a partir da TFTC (seção 0). Em seguida (seção 3.3.3) estão descritos os procedimentos feitos para permitir a análise estatística destes.

#### 3.3.1 PEDs pela Transformada Discreta de Hilbert

Primeiramente a média coerente do sinal,  $x[n]$ , foi dividida em  $N$  janelas retangulares de 1,0 s com o máximo de sobreposição entre as janelas, de forma que o índice  $n$  se alinhasse com o final de cada janela, gerando as  $N$  janelas  $x_j[n]$  com  $L$  amostras cada. Para garantir que os PEDs tivessem a mesma duração que o sinal original, o sinal  $x[n]$  foi completado com as  $L - 1$  primeiras amostras do sinal, porém espelhadas no tempo. A TDH de cada janela do sinal foi calculada de acordo com a expressão 2.23, com a operação de deslocamento de fase da TDF. Considerando-se a  $j$ -ésima janela da média coerente,  $x_j[n]$  e sua TDH  $\tilde{x}_j[n]$ , a amplitude instantânea janelada foi obtida por

$$A_i[j] = med\left(\sqrt{x_j^2[n] + \tilde{x}_j^2[n]}\right), \quad j = 0, \dots, N - 1, \quad (3.3)$$

Sendo  $med(\cdot)$  a mediana da janela.

Para obter frequência instantânea, primeiro é preciso obter o sinal de fase instantânea de cada janela. Esta foi obtida pela expressão,

$$\theta_i[n] = \begin{cases} \text{atan2}(\tilde{x}_j[n], x_j[n]), & \text{se } x_j[n] \neq 0 \\ 0, & \text{se } x_j[n] = 0 \end{cases} \quad (3.4)$$

A frequência instantânea de cada janela foi calculada por (BENDAT; PIERSOL, 2011),

$$F_i[n] = \frac{\theta_i[n+1] - \theta_i[n]}{(2\pi T_s)}, \quad (3.5)$$

onde  $T_s$  é o período de amostragem. Antes de calcular  $F_i[n]$ , a fase instantânea  $\theta_i[n]$  foi ajustada somando-se múltiplos inteiros de  $2\pi$  até que:

$$|\theta_i[n+1] - \theta_i[n]| < \pi, \forall n. \quad (3.6)$$

Por último, para obter o sinal final de  $F_i$  janelada, foi usada a mediana da  $F_i$  de cada janela:

$$F_i[j] = \text{med}(F_i^j[n]), \quad j = 0, \dots, N-1. \quad (3.7)$$

A Figura 3.3 esquematiza os procedimentos adotados para a obtenção dos PEDs a partir da TDH descritos nesta seção.

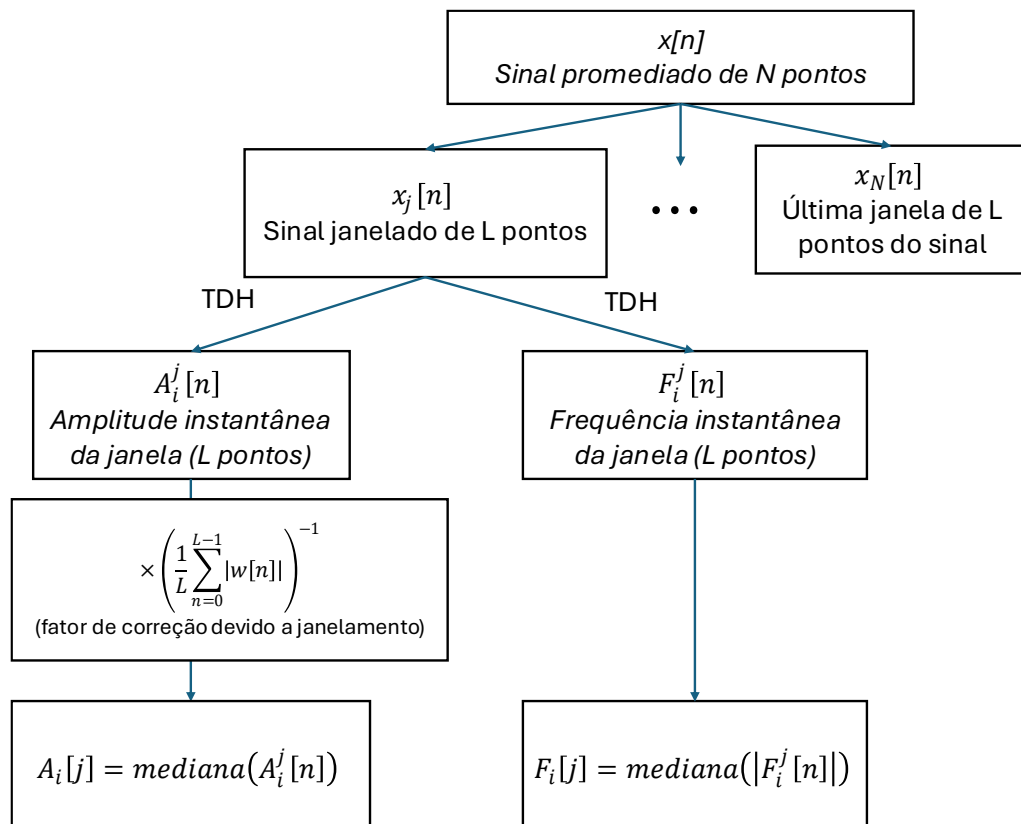


Figura 3.3 - Diagrama de processamento para obtenção dos PEDs pela TDH.

### 3.3.2 PEDs pela Transformada de Fourier de Tempo Curto

Assim como na seção anterior, o sinal  $x[n]$  foi dividido em  $N$  janelas retangulares de 1 s com o máximo de sobreposição entre as janelas, de forma que o índice  $n$  do sinal original se alinhasse com o final de cada janela, gerando as  $N$  janelas  $x_j[n]$  com  $L$  amostras cada. Para garantir que os PEDs tivessem a mesma duração que o sinal original, o sinal  $x[n]$  foi completado com as  $L - 1$  primeiras amostras do sinal, porém espelhadas no tempo. Desta forma, a amplitude eficaz instantânea  $A_{ef}$  do sinal foi calculada partir das janelas pela expressão

$$A_{ef}[j] = \sqrt{\frac{1}{L} \sum_{n=0}^{L-1} (x_j[n])^2}. \quad (3.8)$$

Para obter a frequência central instantânea  $F_{ce}$  foram calculadas as TDFs unilaterais  $X_j[k]$  de cada janela  $x_j[n]$ . A partir dos espectros das janelas a  $F_{ce}$  foi calculada pela expressão, baseada em Phinyomark et al.:

$$F_{ce}[j] = \sum_k f_k |X_j[k]|^2 / \sum_k |X_j[k]|^2, \quad (3.9)$$

em que  $f_k$  é a frequência em Hertz correspondente ao índice  $k$  da TDF. A Figura 3.4 esquematiza os procedimentos adotados para a obtenção dos PEDs a partir da TFTC descritos nesta seção.

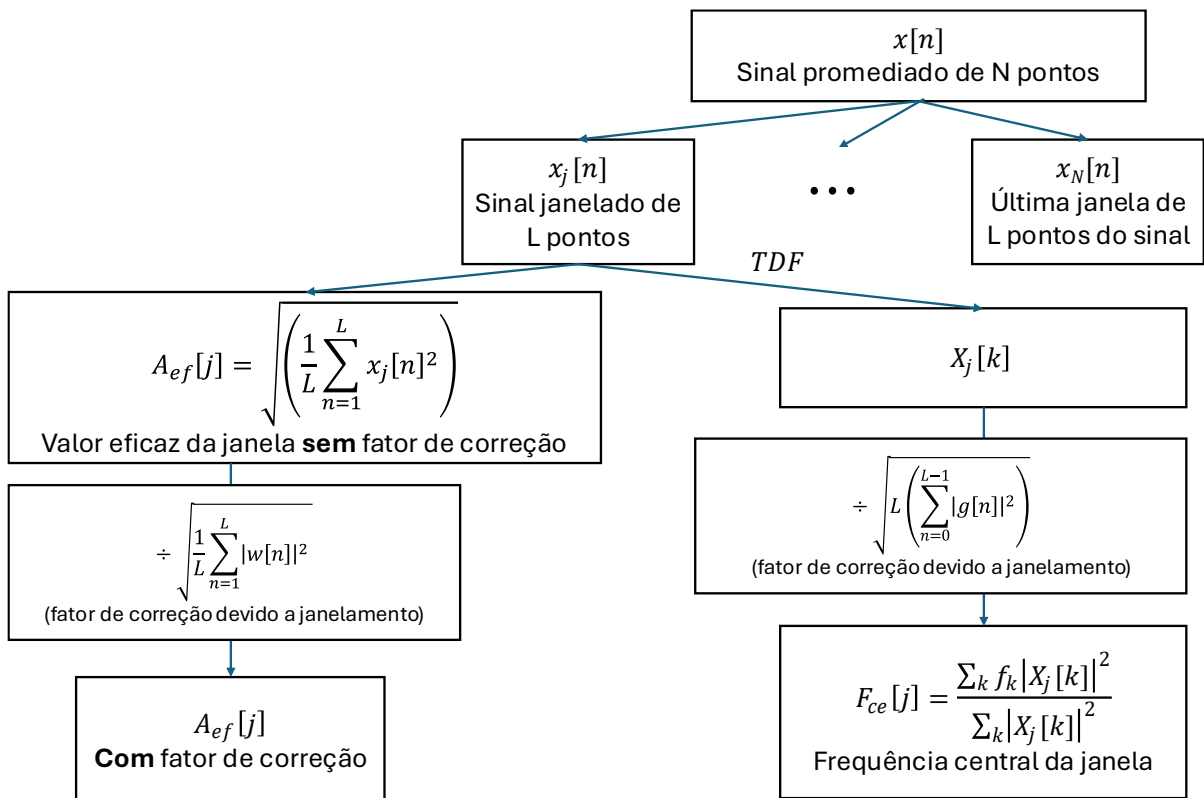


Figura 3.4 - Diagrama de processamento para obtenção dos PEDs pela TDFC.

### 3.3.3 Métricas para Análise Estatística dos PEDs

Para a análise estatística dos PEDs obtidos pela TDH e pela TDFC, calculou-se as integrais numéricas em intervalos de 1,0 s sem sobreposição, gerando sete valores correspondentes aos intervalos  $t_0$ - $t_6$  ( $t_0=0$ -1 s,  $t_1=1$ -2 s,  $t_2=2$ -3 s etc.). Assim, foram gerados os sinais correspondentes às estatísticas de interesse  $sA_i$  e  $sF_i$ , respectivamente para integral da amplitude instantânea e integral da frequência instantânea, e  $sA_{ef}$  e  $sF_{ce}$ , respectivamente para integral da amplitude eficaz e integral da frequência central. Ainda nos mesmos intervalos foram calculadas as correlações de Pearson entre  $A_i[n]$  e  $F_i[n]$ ,  $corr(A_i, F_i)$ , e entre  $A_{ef}[n]$  e  $F_{ce}[n]$ ,  $corr(A_{ef}, F_{ce})$ .

## 3.4 Análise Estatística da Forma de Onda

A análise estatística nesta seção busca responder à duas perguntas:

- dada uma derivação de EEG num intervalo de tempo específico, será que o valor do PED varia de acordo com o movimento imaginado?
- dada uma derivação de EEG de uma classe específica, será que o valor do PED

varia ao longo do ensaio?

Neste contexto, foi realizado o teste de Friedman (ZAR, 2010) ( $\alpha_i = 0,05$ ) para investigar diferenças estatisticamente significativas para os parâmetros  $sA_i$ ,  $sF_i$ ,  $corr(A_i, F_i)$ ,  $sA_{ef}$ ,  $sF_{ce}$ ,  $corr(A_{ef}, F_{ce})$  entre as 4 classes de tarefas mentais (MD, ME, pés e língua) para cada intervalo (t0 a t6). Para os intervalos t3 (3 – 4 s) e t4 (4 – 5 s), foi aplicado o teste *post hoc* de Tukey-Kramer (ZAR, 2010), por serem os intervalos que apresentaram valores significativos no teste de Friedman em mais derivações. O *post hoc* foi realizado visando a identificar entre quais classes, duas a duas, foram observadas diferenças significativas. Foram usadas 9 amostras (indivíduos) por classe de IM. Além dos valores-p, também foram calculados valores de W de Kendall, medida de tamanho de efeito para interpretar a magnitude das diferenças (ZAR, 2010).

O teste de Friedman foi realizado também para investigar as diferenças estatisticamente significativas para os parâmetros entre os 7 intervalos (t0 – t6), para cada classe de IM. Devido aos valores de tamanho de efeito serem elevados em todas as combinações derivação-IM, a análise da evolução temporal dos PEDs foi feita via *boxplots* ao invés de testes *post hoc*.

## Capítulo 4: Resultados

Neste capítulo são apresentados os traçados dos PEDs, bem como os resultados da análise estatística, permitindo avaliar se houve diferença entre as classes de IM e entre os intervalos (há algum padrão de evolução temporal dos PEDs?), e se os PEDs da forma como foram processados são suficientes para prever a classe de IM.

### 4.1 Traçados dos PEDs

#### 4.1.1 Passo-a-passo do processamento

Nesta seção são mostrados exemplos dos sinais a cada etapa de processamento: ensaio bruto, média coerente dos ensaios, obtenção dos PEDs, e cálculo das métricas para os testes estatísticos.

A Figura 4.1 mostra o efeito da média coerente calculada a partir dos ensaios de IM dos pés para o voluntário A01 do conjunto CICMB-2A na derivação Cz. Enquanto no sinal bruto não é possível enxergar nenhum padrão, no sinal promediado nota-se um sinal transitório, logo no início do ensaio, encontrado em outros indivíduos, que parece estar relacionado ao *beep* sonoro. As três componentes seguintes, pico em torno de 2,2 s, um vale em torno de 2,7 s e um pico em torno de 3,5 s, estão relacionados diretamente com a imaginação do movimento (dos pés, neste caso). Por fim, nota-se um pico em torno de 6,2 s que parece estar relacionado ao comando de término de imaginação (apagar da cruz de fixação na tela). Além disso percebe-se uma atenuação na amplitude do ruído do sinal bruto (EEG de fundo) para o promediado. O sinal bruto possui uma amplitude na ordem de dezenas de microvolts (cerca de 30  $\mu\text{V}$ ), enquanto o sinal promediado possui uma amplitude em torno de 10  $\mu\text{V}$ .

Para o mesmo voluntário, a Figura 4.2 mostra os PEDs  $A_i$  e  $F_i$  obtidos a partir da TDH do sinal promediado, as integrais dos PEDs nos intervalos disjuntos,  $sA_i$  e  $sF_i$  indicadas pelos asteriscos azuis e o patamar correspondente, assim como as correlações entre os PEDs nos intervalos. Em linhas gerais, observa-se um aumento de  $A_i$  no começo da IM, em torno de 2,0 s que persiste até cerca de 5,0 s. Durante este mesmo intervalo observa-se que  $F_i$  reduz até atingir um patamar baixo, em torno de 2 Hz, voltando ao valor inicial de 6 Hz aos 5,0 s. A partir de 1,0 s as curvas de  $A_i$  e de  $F_i$  oscilam em sentidos opostos, o que é confirmado pela correlação inferior a -0,71 no período.




Figura 4.1: Exemplo de aplicação da média coerente no conjunto CICMB-2A. Voluntário A01, derivação Cz, IM dos pés.

A Figura 4.3 contém os PEDs  $A_{ef}$  e  $F_{ce}$  obtidos da TFTC do sinal promediado, as integrais dos PEDs nos intervalos disjuntos,  $sA_{ef}$  e  $sF_{ce}$ , indicadas pelos asteriscos azuis e o patamar correspondente, assim como as correlações entre os PEDs nos intervalos. As observações são similares àquelas feitas para  $A_i$  e  $F_i$ . Entretanto, nota-se que a  $F_{ce}$  apresenta espículas, o que resulta em sua maior variabilidade, se comparada a  $F_i$ . Além disso, correlações negativas abaixo de  $-0,70$  ocorrem somente para  $t_2$  e  $t_4$ , diferente do que ocorre para as PEDs da TDH, com correlação menor que  $-0,70$  para todo o intervalo  $t_1$ - $t_6$ .

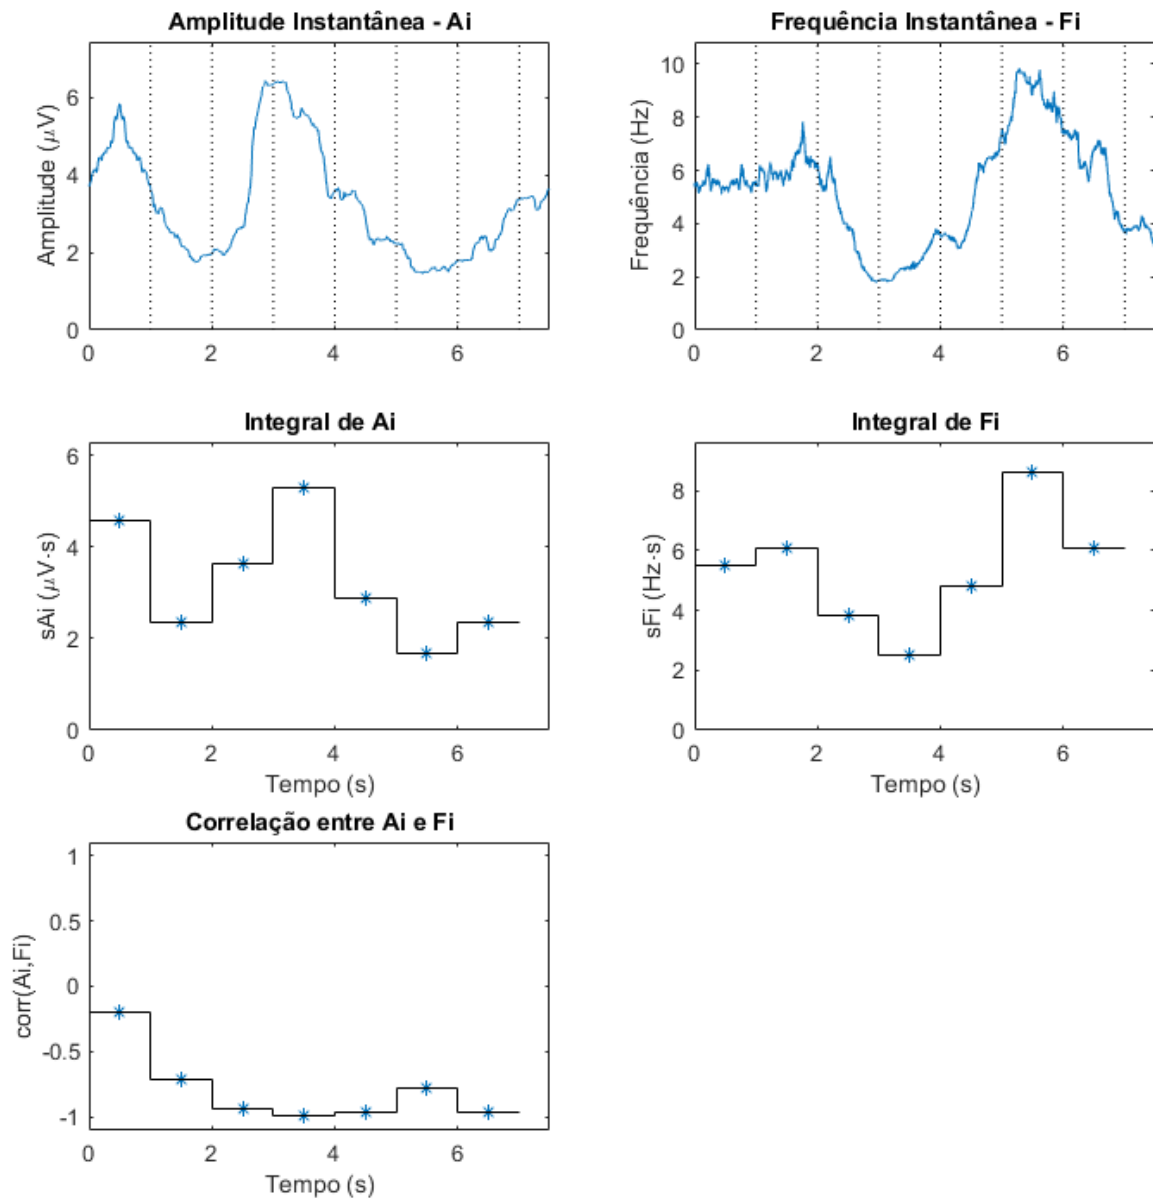


Figura 4.2: Exemplo do processamento para obtenção dos PEDs pela TDH no conjunto CICMB-2A. Voluntário A01, derivação Cz, IM dos pés.

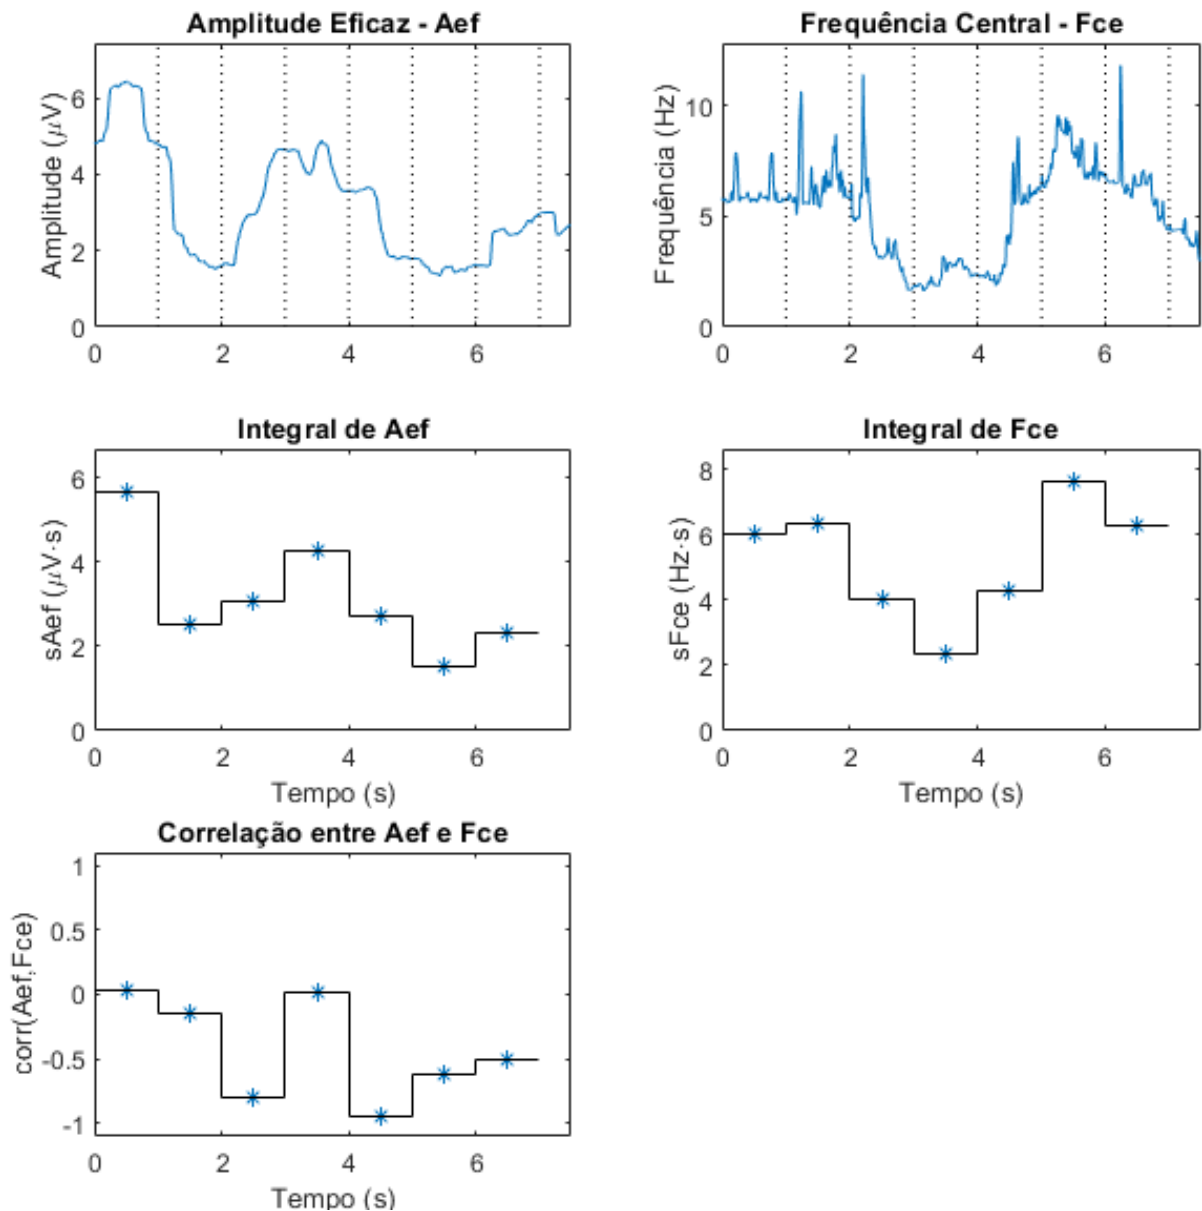


Figura 4.3: Exemplo do processamento para obtenção dos PEDs pela TFTC no conjunto CICMB-2A. Voluntário A01, derivação Cz, IM dos pés.

#### 4.1.2 Traçados dos PEDs

A Figura 4.4 mostra a evolução temporal de  $A_i$  (gráficos à esquerda) e  $F_i$  (à direita) para as derivações FC3, FCz, FC4, C3, Cz, C4, CP3, CPz, CP4, P1, Pz, P2 para o voluntário A01. Como se pode notar, os traçados de Amplitude Instantânea (Figura 4.4 à esquerda) apresentam morfologia similar em todas as derivações, inclusive com amplitudes similares. Observa-se um pico em 3,0s, durante a IM, seguida de uma redução de amplitude de 4,0 s a 6,0 s para quaisquer

das IMs (MD, ME, pés e língua). Esta redução é consistente com o fenômeno de Dessincronização Relacionada a Evento (DRE). Por fim observa-se um pico aos 6,5 s. Ainda, para a IM dos pés nas derivações mid-sagitais Cz, CPz e Pz, nota-se que, após atingir o pico em torno de 3,0 s a  $A_i$ , os traçados demoram um pouco mais para atingir o vale do que para IM de outras classes. Estas observações podem ser estendidas para a maior parte dos voluntários.

Observando a  $F_i$  do mesmo voluntário (Figura 4.4 à direita), constata-se que ela oscila de forma inversa ao traçado de  $A_i$  também para estas derivações, apresentando um vale em torno de 3,0 s ( $F_i$  variando entre 2,5 e 3,5 Hz) e morfologia variável entre 4,0 s e 6,0 s com  $F_i$  variando entre 4 e 13 Hz, ou seja, frequências instantâneas correspondentes à banda teta e alfa.

Os traçados de  $A_i$  e de  $F_i$  para o voluntário A02 (Figura 4.5) são similares aos do voluntário A01. Entretanto os picos de  $A_i$  em 3,0 s são mais elevados nas derivações fronto-centrais e centrais (FC3, FCz, FC4, C3, Cz, C4) em relação às demais para o voluntário A01, e mais elevados nas derivações centro-parietais e parietais (CP3, CPz, CP4, P1, Pz, P2) para o voluntário A02. Poderia se especular que tal diferença se deve ao uso de recursos mais visuais de imaginação para o voluntário A02 do que para o voluntário A01. Além disso, nota-se diferença nas amplitudes dos picos em 3,0 s entre as classes de IM, para todas as derivações e em ambos os voluntários. No patamar de baixa amplitude de t4 a t6, parece não haver diferenças de amplitude consistente entre as classes.

Já os traçados de  $F_i$  para o voluntário A02 (Figura 4.5 à direita) pode-se fazer as mesmas observações que foram feitas para A01: a existência de um vale consistente em 3,0 s com valores de  $F_i$  na banda delta (0-4 Hz) e  $F_i$  nas banda teta e alfa (4-13 Hz) de 4,0 a 6,0 s.

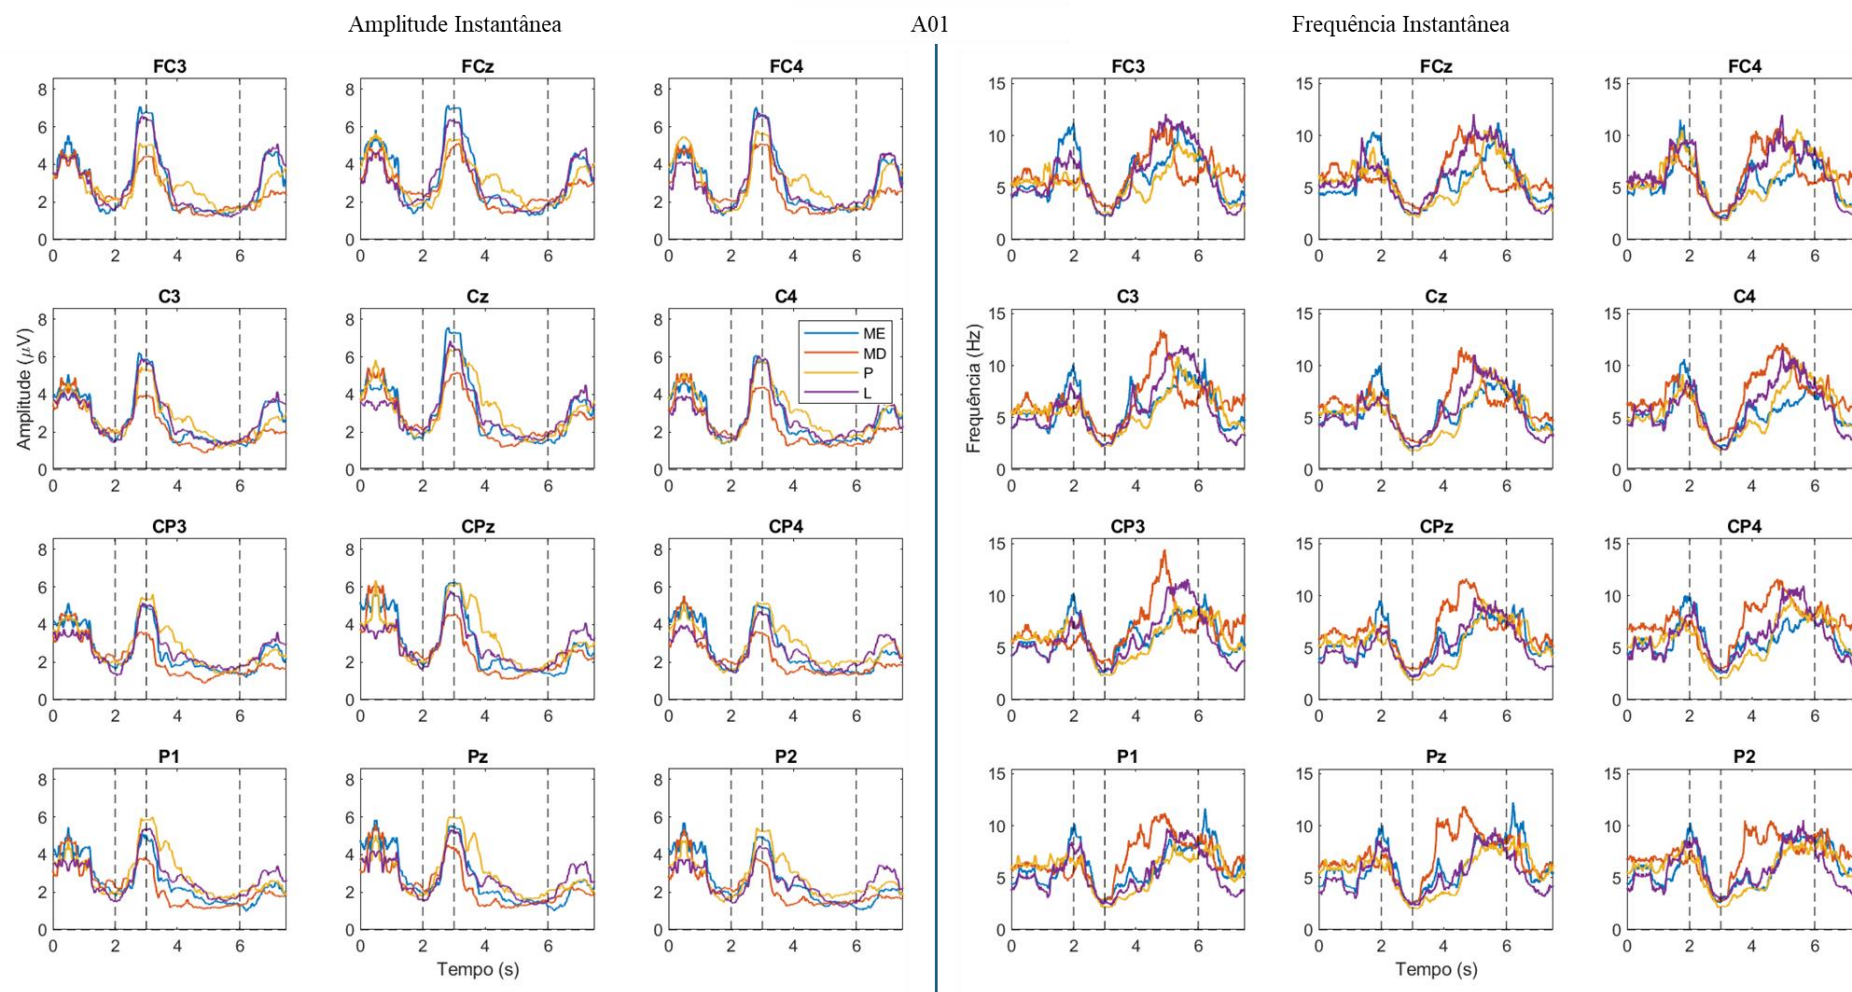


Figura 4.4: Evolução temporal de  $A_i[n]$  (esquerda) e  $F_i[n]$  (direita) para as 4 classes de IM (ME – mão esquerda, MD – mão direita, P – pés, L – língua) nas derivações indicadas para o voluntário A01, sessão de treinamento do conjunto de dados.

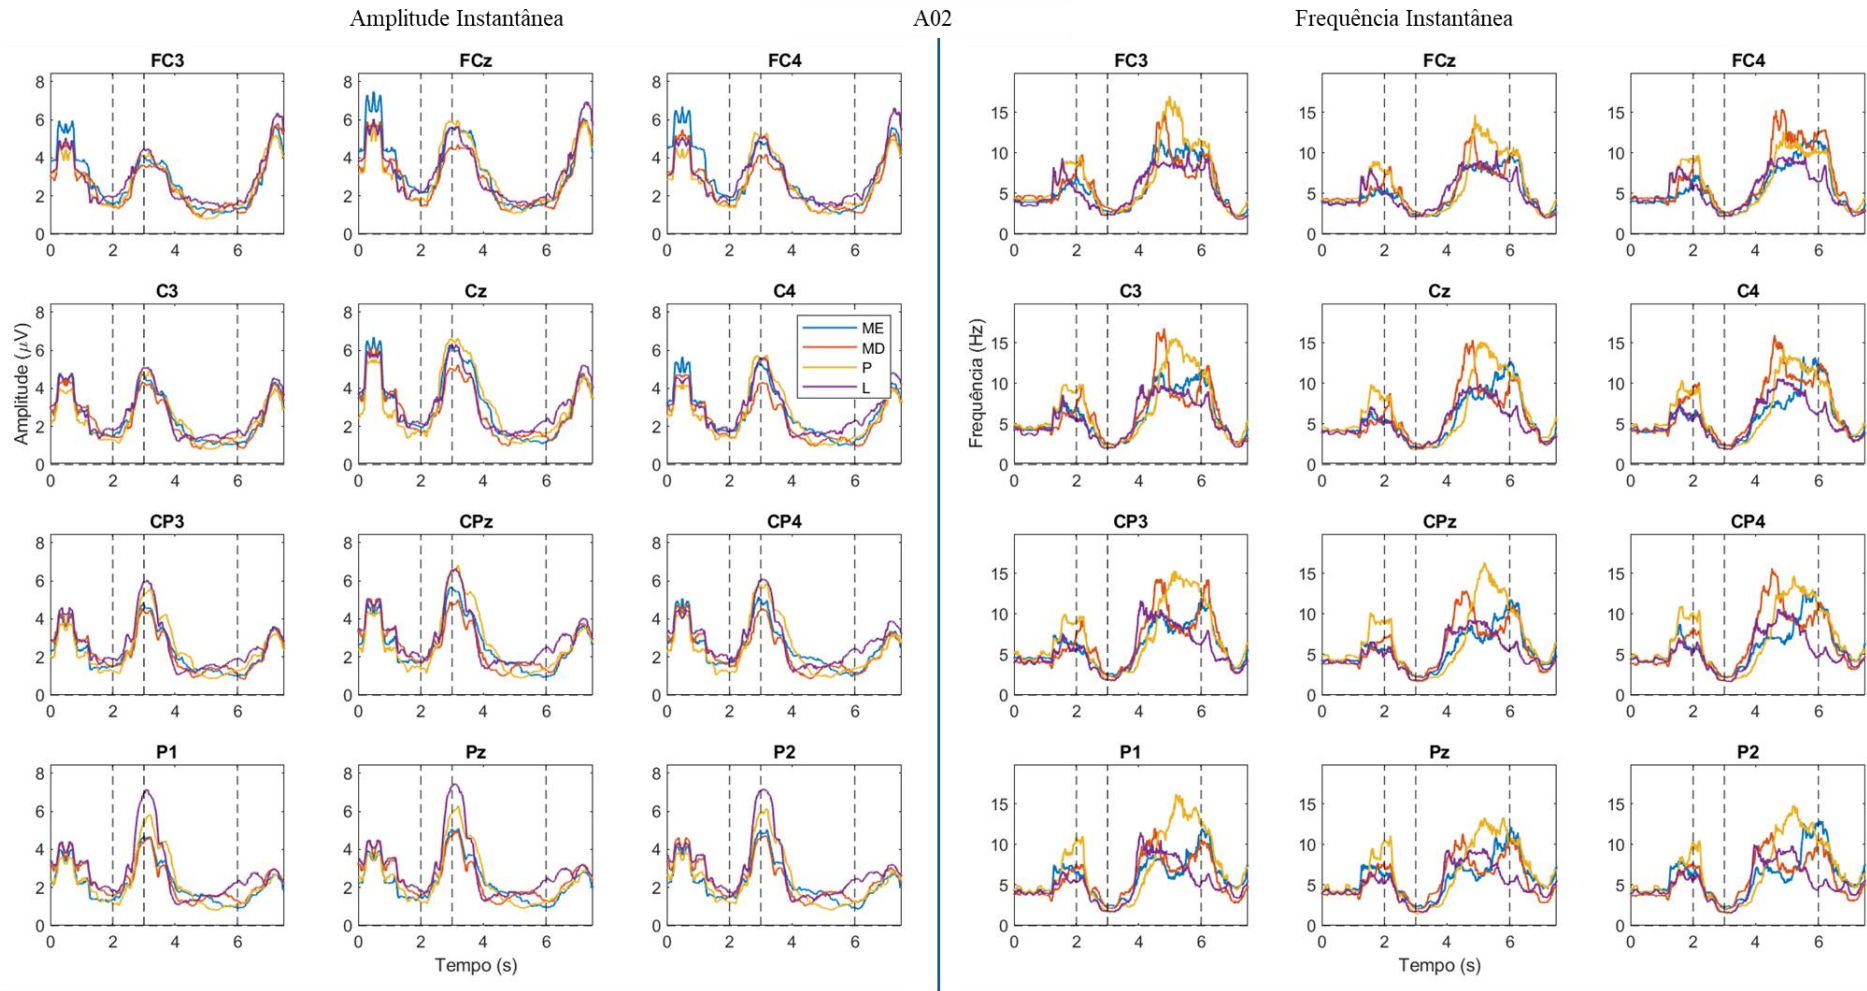


Figura 4.5: Evolução temporal de  $A_i[n]$  (esquerda) e  $F_i[n]$  (direita) para as 4 classes de IM (ME – mão esquerda, MD – mão direita, P – pés, L – língua) nas derivações indicadas para o voluntário A02, sessão de treinamento do conjunto de dados.

A seguir estão descritas as observações para os traçados dos PEDs obtidos a partir da TFTC de ambos os voluntários, registrados na Figura 4.6 e Figura 4.7. Assim como para os PEDs da TDH, os traçados mostram que um aumento de  $A_{ef}$  é acompanhado por uma diminuição de  $F_{ce}$ , e mostram que quando  $A_{ef}$  atinge platôs em valores baixos, há um aumento de  $F_{ce}$ . Também se nota que os valores de  $F_{ce}$  parecem oscilar em frequências das bandas teta e alfa no intervalo de 4,0 s a 6,0 s, o mesmo observado para  $F_i$ .

Os traçados de  $F_{ce}$  tem aspecto mais ruidoso do que os traçados de  $F_i$ , com mais *spikes* de frequência. Isso ocorre provavelmente porque o cálculo de  $F_{ce}$  se baseia na média ponderada das frequências pelo quadrado do valor absoluto dos coeficientes da TDF de cada janela de sinal, sendo mais sensível a valores extremos, enquanto  $F_i$  é calculada pela mediana do traçado de frequência instantânea de cada janela. Comparando os traçados em relação as técnicas tempo-frequência utilizadas, se constata que os traçados de  $A_i$  e  $A_{ef}$  são similares, enquanto os traçados de  $F_{ce}$  são mais ruidosos do que os de  $F_i$ . A menos do ruído adicional em  $F_{ce}$ , os PEDs obtidos de ambas as técnicas tempo-frequência apresentam a mesma morfologia no geral.

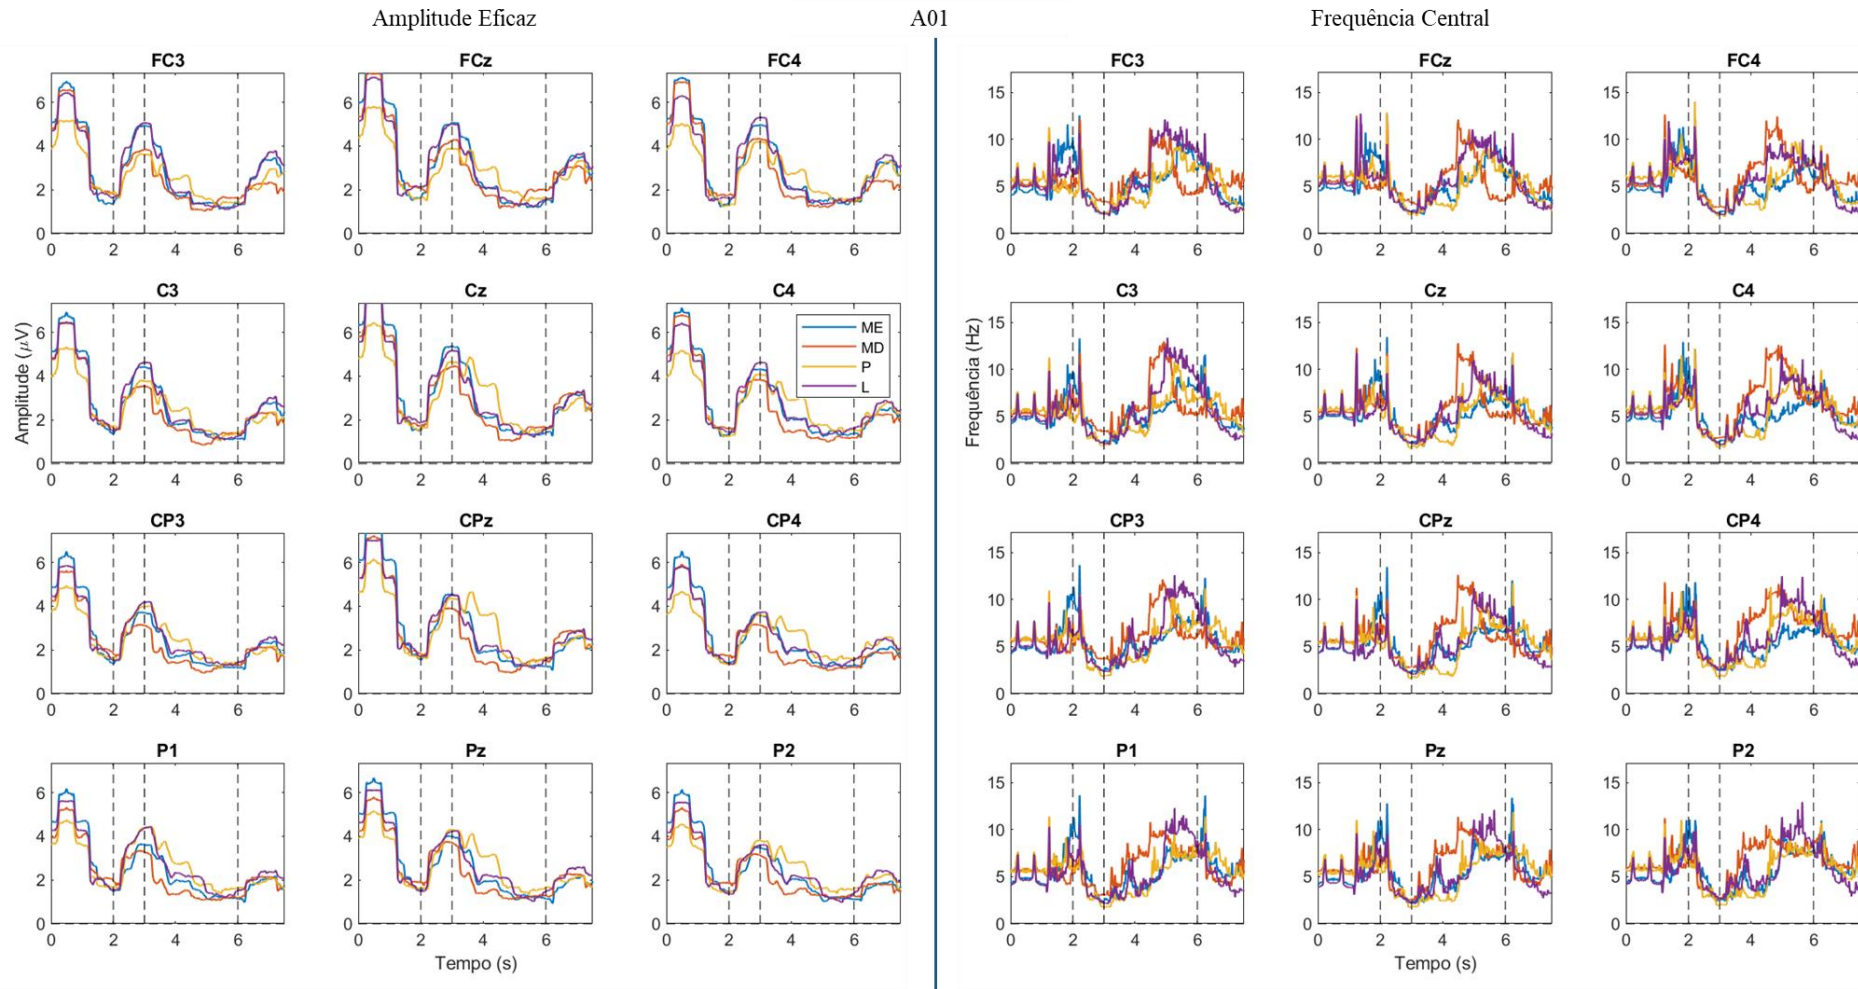


Figura 4.6: Evolução temporal de  $A_{ef}[n]$  (esquerda) e  $F_{ce}[n]$  (direita) para as 4 classes de IM (ME – mão esquerda, MD – mão direita, P – pés, L – língua) nas derivações indicadas para o voluntário A02, sessão de treinamento do conjunto de dados.

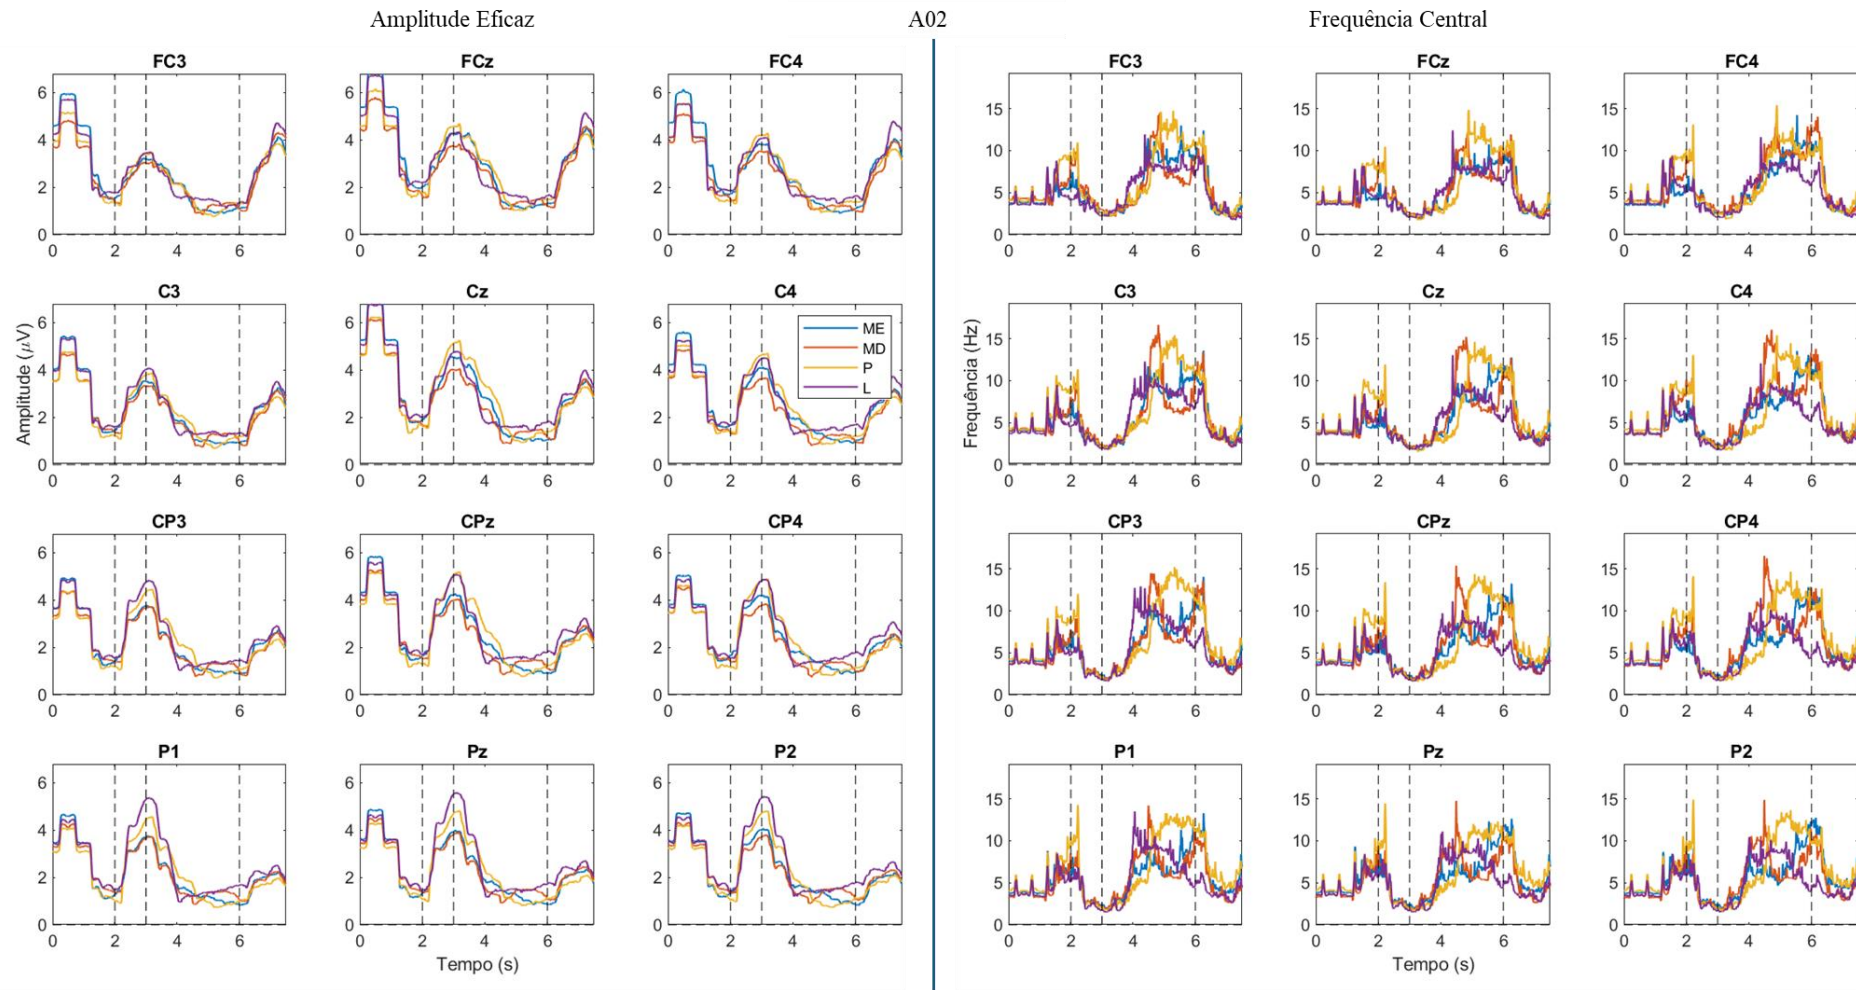


Figura 4.7: Evolução temporal de  $A_{ef}[n]$  (esquerda) e  $F_{ce}[n]$  (direita) para as 4 classes de IM (ME – mão esquerda, MD – mão direita, P – pés, L – língua) nas derivações indicadas para o voluntário A02, sessão de treinamento do conjunto de dados.

## 4.2 Diferenças entre as classes

### 4.2.1 Diferenças entre as classes – PED $sA_i$

A Tabela 4.1 contém os valores de  $W$  de Kendall para os testes de Friedman realizados para detectar diferença estatisticamente significativa para  $sA_i$  (integral de  $A_i$  em cada intervalo  $t_n$ ) entre as classes, dado um intervalo de tempo e derivação específicos. As células destacadas em cinza indicam as combinações de derivação e intervalo com valor  $p$  inferior a 0,05, e as células em negrito indicam os maiores tamanhos de efeito observados (intervalo t3:  $W = 0,52$  em Cz e intervalo t4:  $W = 0,49$  em C5). Observa-se que houve diferença significativa para 18 das 22 derivações no intervalo t3, pouco após o início da IM, com  $W$  de Kendall em torno de 0,38. E para 14 das 22 derivações no intervalo t4, já durante sustentação da IM, com  $W$  de Kendall em torno de 0,33. Estes valores dos  $W$  de Kendall significativos representam um tamanho de efeito médio. Também se observa diferenças estatisticamente significativas entre as classes em t2 (derivações FC1, C3 e CP3) e em t5 (FC2, FC4, C2, C4, P1).

Como os intervalos t3 e t4 apresentaram diferenciação em mais derivações, para eles foi feito o *post hoc* de Tukey-Kramer, com os valores  $p$  do *post hoc* indicados na Tabela 4.2 e na Tabela 4.3. Também foram gerados *boxplots* de  $sA_i$  para as derivações FC3, FCz, FC4, C3, Cz, C4, CP3, CPz, CP4, P1, POz e P2 (Figura 4.8 e Figura 4.9).

Para t3 (Tabela 4.2 e Figura 4.8) foi possível diferenciar IM dos pés de IM da mão direita na maioria das derivações centrais, centro-parietais e parietais, e diferenciar IM dos pés de IM da língua nas derivações fronto-centrais e centrais. Os *boxplots* em t3 indicam que  $sA_i$  (que pode ser interpretada como um tipo de estimativa da energia do sinal de EEG) é maior para a IM dos pés do que para as imaginações da mão direita e da língua.

Já em t4 (Tabela 4.3 e Figura 4.9) a diferenciação foi apenas entre IM dos pés e da mão direita na maioria das derivações, cobrindo da região fronto-central até a parietal. Neste intervalo, os *boxplots* seguem o mesmo padrão, com  $sA_i$  superior para IM dos pés quando comparada a IM da mão direita.

Tal fato poderia ser explicado a partir do mapa somatotópico (Homúnculo Motor, Figura 2.4), no qual se observa que os pés estão representados na região central, enquanto a língua está representada lateralizada próximo ao lobo temporal; a representação da mão encontra-se a meio caminho entre os pés e a língua.

Tabela 4.1 - Tamanhos de efeito (W de Kendall) dos testes de Friedman para diferenças interclasses no PED  $sA_i$ , dado um par de derivação e intervalo de tempo. Valores sombreados correspondem a  $p < 0,05$ . Valores em negrito representam os maiores tamanhos de efeito nos intervalos t3 e t4.

Intervalo	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
t0	0,10	0,09	0,06	0,11	0,02	0,05	0,10	0,02	0,06	0,07	0,08	0,06	0,01	0,01	0,04	0,09	0,16	0,16	0,16	0,09	0,21	0,37
t1	0,04	0,02	0,01	0,09	0,05	0,09	0,14	0,02	0,02	0,02	0,02	0,06	0,09	0,10	0,04	0,06	0,14	0,09	0,14	0,06	0,03	0,09
t2	0,09	0,19	0,25	0,16	0,21	0,19	0,23	0,27	0,21	0,24	0,24	0,16	0,12	0,29	0,14	0,12	0,12	0,11	0,14	0,21	0,06	0,05
t3	0,34	0,30	0,42	0,38	0,41	0,27	0,09	0,16	0,45	0,52	0,42	0,35	0,21	0,36	0,41	0,48	0,43	0,22	0,39	0,34	0,27	0,25
t4	0,22	0,14	0,12	0,34	0,27	0,38	0,49	0,21	0,21	0,34	0,32	0,32	0,26	0,27	0,24	0,24	0,19	0,31	0,36	0,34	0,32	0,19
t5	0,04	0,06	0,01	0,04	0,29	0,34	0,12	0,16	0,02	0,11	0,27	0,26	0,24	0,04	0,17	0,21	0,13	0,12	0,26	0,19	0,17	0,14
t6	0,18	0,04	0,11	0,13	0,20	0,17	0,06	0,06	0,07	0,09	0,14	0,14	0,09	0,12	0,02	0,02	0,15	0,09	0,11	0,08	0,08	0,10

Tabela 4.2 - Valores p dos testes *post hoc* de Tukey-Kramer feitos no intervalo t3 para o PED  $sA_i$ . Valores sombreados correspondem a  $p < 0,05$ .

Células vazias tiveram valor  $p < 2.2204e-16$ .

Comparação	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
ME Vs. MD	0,80	1,00	0,98	0,69	0,46	0,13	0,95	1,00	0,88	0,58	0,46	0,13	0,18	0,95	0,98	0,69	0,58	0,88	1,00	0,95	0,95	0,88
ME Vs. Pés	0,88	0,35	0,46	0,80	0,88	0,98	0,69	0,26	0,18	0,35	0,46	0,80	0,98	0,05	0,02	0,08	0,18	0,26	0,02	0,05	0,13	0,18
ME Vs. Língua	0,08	0,46	0,13	0,08	0,05	0,46	0,95	1,00	0,35	0,13	0,26	0,58	0,80	0,58	0,88	0,80	0,69		0,58	0,95	1,00	0,95
MD Vs. Pés	0,35	0,46	0,26	0,18	0,13	0,05	0,35	0,18	0,03	0,02	0,02	0,01	0,08	0,01	<0,01	<0,01	<0,01	0,05	0,01	0,01	0,03	0,03
MD Vs. Língua	0,46	0,35	0,26	0,58	0,69	0,88	0,69	0,98	0,80	0,80	0,98	0,80	0,69	0,26	0,69	1,00	1,00	0,88	0,46	0,69	0,88	0,58
Pés Vs. Língua	0,01	0,01	<0,01	<0,01	<0,01	0,26	0,95	0,35	<0,01	<0,01	<0,01	0,13	0,58	0,58	0,13	<0,01	0,01	0,26	0,35	0,18	0,18	0,46

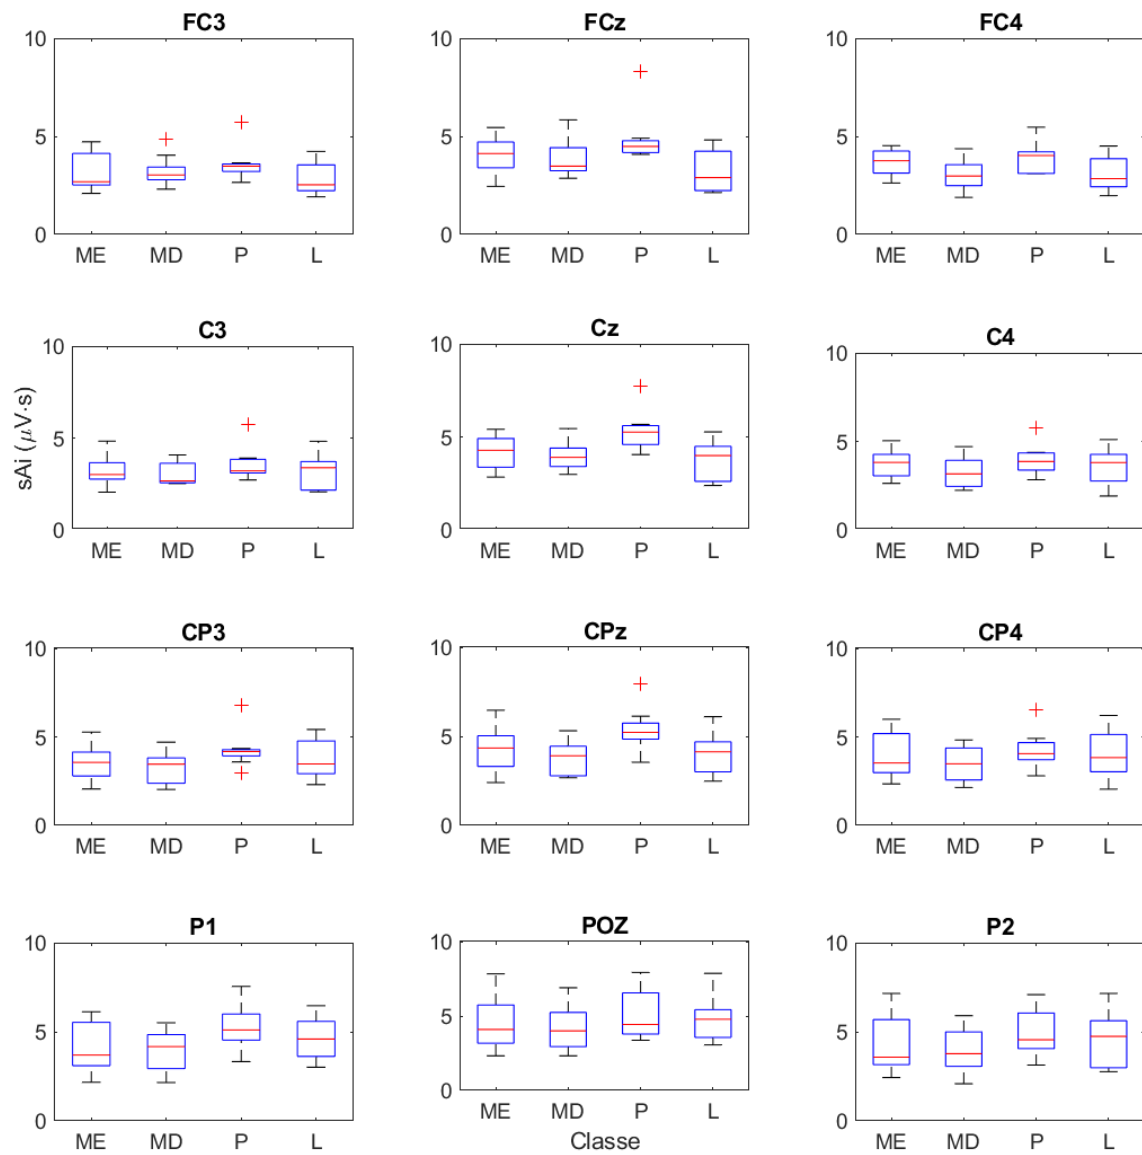


Figura 4.8 - *Boxplot* do PED  $sA_i$  no intervalo  $t_3$ .

Tabela 4.3 - Valores p dos testes *post hoc* de Tukey-Kramer feitos no intervalo t4 para o PED  $sA_i$ . Valores sombreados correspondem a  $p < 0,05$ .Células vazias tiveram valor  $p < 2.2204e-16$ .

Comparação	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
ME Vs. MD	1,00	1,00	0,98	0,80	0,58	0,05	0,88	0,98	0,98	0,80	0,13	0,08	0,13	0,69	0,80	0,80	0,35	0,08	0,13	0,13	0,46	0,58
ME Vs. Pés	0,18	0,46	0,46	0,18	0,35	1,00	0,05	0,08	0,18	0,13	0,80	0,95		0,26	0,26	0,26	0,88	0,98	0,69	0,80	0,46	0,80
ME Vs. Língua	0,46	0,58		0,88		0,95	0,13	0,58	1,00	1,00	0,95		0,98	0,98	1,00	1,00	1,00	1,00		1,00	0,69	0,88
MD Vs. Pés	0,13	0,35	0,26	0,02	0,02	0,03	<0,01	0,18	0,08	0,01	0,01	0,02	0,13	0,02	0,03	0,03	0,08	0,03	<0,01	0,01	0,02	0,13
MD Vs. Língua	0,35	0,46	0,98	1,00	0,58	0,01	0,02	0,80	0,95	0,88	0,35	0,08	0,05	0,46	0,69	0,69	0,46	0,05	0,13	0,08	0,05	0,18
Pés Vs. Língua	0,95	1,00	0,46	0,03	0,35	0,98	0,98	0,69	0,26	0,08	0,46	0,95	0,98	0,46	0,35	0,35	0,80	1,00	0,69	0,88	0,98	1,00

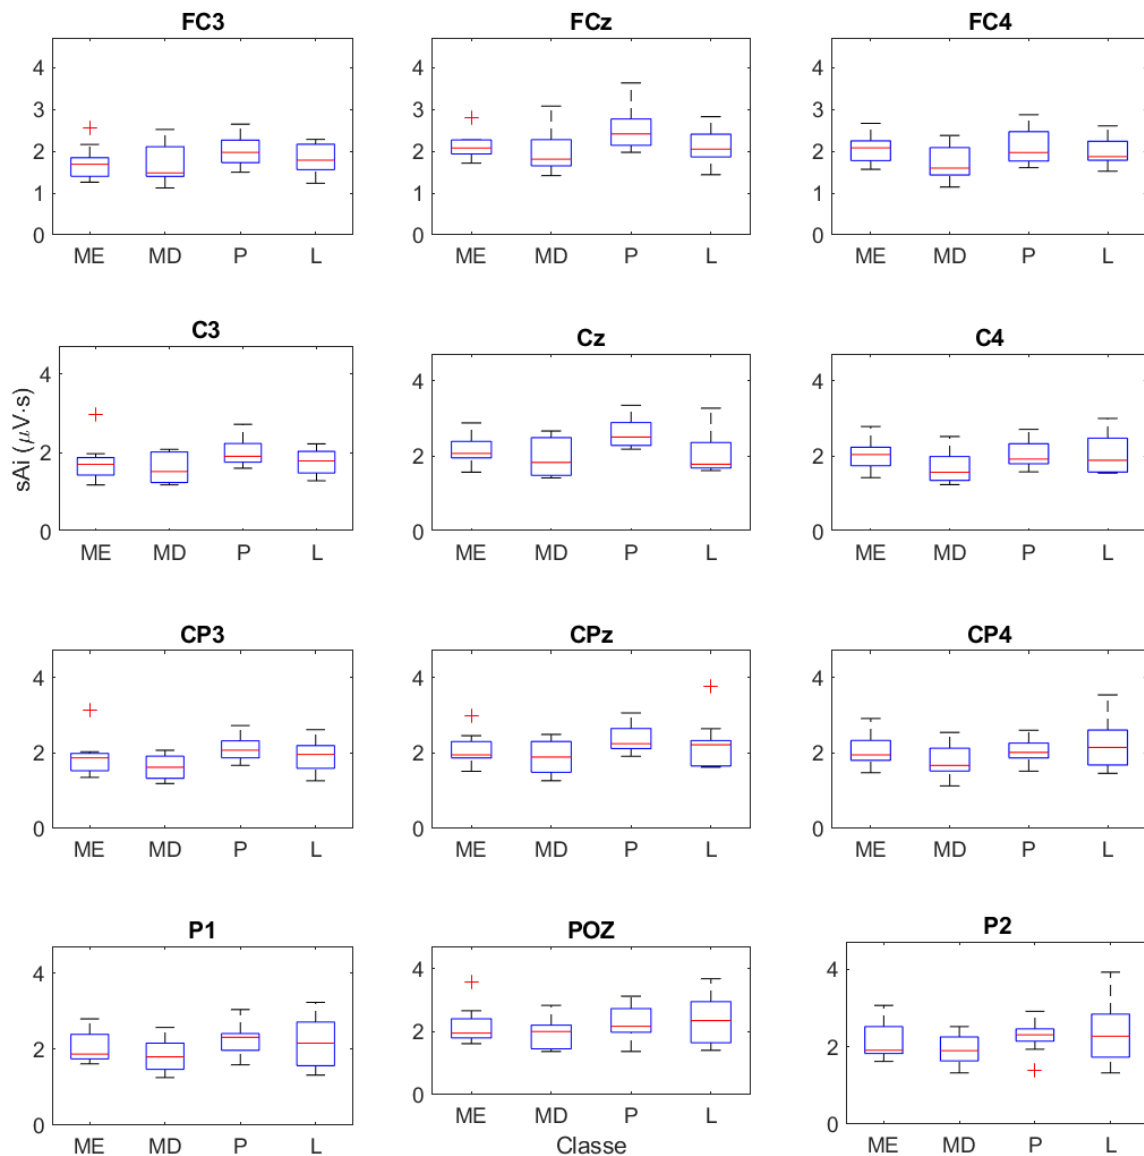


Figura 4.9 - *Boxplot* do PED  $sA_i$  no intervalo  $t_4$ .

#### 4.2.2 Diferenças entre as classes – PED $sF_i$

A Tabela 4.4 contém os valores de  $W$  de Kendall para os testes de Friedman realizados para detectar diferença para  $sF_i$  (integral de  $F_i$  em cada intervalo  $t_n$ ) entre as classes, dado um intervalo de tempo e derivação específicos. As células destacadas em cinza indicam as combinações de derivação e intervalo com valor  $p$  inferior a 0,05, e as células em negrito indicam os maiores tamanhos de efeito observados (intervalo  $t_3$ :  $W = 0,64$  em C1 e P2 e intervalo  $t_4$ :  $W = 0,54$  em C4). Observa-se que houve diferença estatisticamente significativa

para 20 dos 22 derivações no intervalo t3, com W de Kendall em torno de 0,50. E para 15 dos 22 derivações no intervalo t4, com W de Kendall em torno de 0,35. Estes valores dos W de Kendall significativos representam um tamanho de efeito médio para alto, e são superiores aos encontrados para  $sA_i$ . Não foram detectadas diferenças estatisticamente significativas entre as classes nos intervalos t2 e t5, diferente dos resultados obtidos para  $sA_i$ .

Como os intervalos t3 e t4 apresentaram diferenciação em mais derivações, para eles foi feito o *post hoc* de Tukey-Kramer, com os valores p do *post hoc* indicados na Tabela 4.5 e na Tabela 4.6. Também foram gerados *boxplots* de  $sF_i$  para as derivações FC3, FCz, FC4, C3, Cz, C4, CP3, CPz, CP4, P1, POz e P2 (Figura 4.8 e Figura 4.9).

Em t3 foi possível diferenciar IM dos pés de IM da mão direita e diferenciar IM dos pés de IM da língua assim como com  $sA_i$ , porém para a frequência instantânea essas distinções foram possíveis em quase todas as derivações. Os *boxplots* para este intervalo (Figura 4.10) indicam que  $sF_i$  (métrica relacionada à região do espectro onde a energia do sinal está centrada) é menor para a IM dos pés do que para as IM da mão direita e da língua.

Em t4, assim como observado para  $sA_i$ , a diferenciação foi apenas entre IM dos pés e da mão direita. Porém, ao invés da diferença ter sido detectada nas derivações centrais até parietais como ocorrido para  $sA_i$ , com  $sF_i$ , a diferenciação foi encontrada nas derivações fronto-centrais e centrais. Os *boxplots* para este intervalo seguem o mesmo padrão, com  $sF_i$  inferior para IM dos pés do que para IM da mão direita. Nota-se que, assim como apresentado na seção 4.1.2,  $sF_i$  segue um padrão inverso ao de  $sA_i$ .

Tabela 4.4 - Tamanhos de efeito (W de Kendall) dos testes de Friedman para diferenças interclasses no PED  $sF_i$ , dado um par de derivação e intervalo de tempo. Valores sombreados correspondem a  $p < 0,05$ . Valores em negrito representam os maiores tamanhos de efeito nos intervalos t3 e t4.

Intervalo	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
t0	0,19	0,28	0,25	0,26	0,15	0,14	0,12	0,21	0,34	0,16	0,36	0,09	0,09	0,19	0,26	0,11	0,11	0,12	0,19	0,12	0,05	0,09
t1	0,09	0,04	0,04	0,19	0,14	0,20	0,03	0,04	0,09	0,04	0,09	0,04	0,06	0,04	0,06	0,09	0,06	0,01	0,14	0,10	0,14	0,06
t2	0,00	0,04	0,16	0,04	0,04	0,02	0,05	0,16	0,10	0,10	0,07	0,12	0,07	0,14	0,13	0,07	0,09	0,06	0,04	0,05	0,03	0,05
t3	0,62	0,39	0,60	0,62	0,52	0,37	0,12	0,24	<b>0,64</b>	0,52	0,54	0,43	0,34	0,36	0,54	0,63	0,59	0,46	0,29	0,54	<b>0,64</b>	0,42
t4	0,23	0,12	0,24	0,29	0,39	0,29	0,19	0,27	0,37	0,34	0,38	<b>0,54</b>	0,21	0,31	0,38	0,37	0,31	0,41	0,22	0,26	0,27	0,11
t5	0,11	0,11	0,07	0,02	0,06	0,11	0,01	0,07	0,02	0,02	0,04	0,09	0,07	0,04	0,04	0,04	0,11	0,18	0,01	0,04	0,04	0,04
t6	0,16	0,11	0,17	0,19	0,11	0,11	0,08	0,14	0,05	0,22	0,06	0,01	0,03	0,25	0,17	0,21	0,07	0,03	0,04	0,09	0,04	0,06

Tabela 4.5 - Valores p dos testes *post hoc* de Tukey-Kramer feitos no intervalo t3 para o PED  $sF_i$ . Valores sombreados correspondem a  $p < 0,05$ .

Células vazias tiveram valor  $p < 2.2204e-16$ .

Comparação	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
ME Vs. MD	0,88	0,95	0,58	0,88	0,26	0,05		1,00	0,69	0,88	0,26	0,05	0,08	0,80	0,35	0,08	0,02	0,13	0,35	0,13	0,05	0,35
ME Vs. Pés	0,18	0,18	0,46	0,18	0,69	0,98	0,35	0,35	0,26	0,26	0,46	0,95	0,88	0,26	0,18	0,35	0,80	0,46	0,69	0,46	0,69	0,46
ME Vs. Língua	0,08	0,46	0,03	0,08	0,05	0,26	1,00	0,69	0,05	0,13	0,13	0,18	0,80	0,58	0,46	0,26	0,18	0,69	0,58	0,26	0,05	0,35
MD Vs. Pés	0,03	0,46	0,03	0,03	0,02	0,02	0,35	0,26	0,02	0,05	<0,01	0,01	0,01	0,03	<0,01	<0,01	<0,01	<0,01	0,03	<0,01	<0,01	0,01
MD Vs. Língua	0,35	0,18	0,46	0,35	0,88	0,88	1,00	0,80	0,46	0,46	0,98	0,95	0,46	0,98	1,00	0,95	0,80	0,69	0,98	0,98		
Pés Vs. Língua	<0,01	<0,01	<0,01	<0,01	<0,01	0,13	0,46	0,03	<0,01	<0,01	<0,01	0,05	0,35	0,01	<0,01	<0,01	0,02	0,05	0,08	<0,01	<0,01	0,01

Tabela 4.6 - Valores p dos testes *post hoc* de Tukey-Kramer feitos no intervalo t4 para o PED  $sF_i$ . Valores sombreados correspondem a  $p < 0,05$ .Células vazias tiveram valor  $p < 2.2204e-16$ .

Comparação	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
ME Vs. MD	0,98	0,88	1,00	0,88	0,35	0,05	1,00	0,35	0,88	0,98	0,69	0,01	0,13	0,08	0,69	0,26	0,26	0,05	0,18	0,08	0,05	0,58
ME Vs. Pés	0,35	0,88	0,58	0,58	0,88	0,69	0,18	0,88	0,88	0,58	0,80	1,00		1,00	0,58	0,98	1,00	1,00	1,00	0,98	0,88	0,80
ME Vs. Língua	0,80	0,69	0,46	0,35	0,08	0,05	0,88	0,35	0,05	0,18	0,08	0,05	0,69	0,26	0,18	0,05	0,08	0,03	0,46	0,18	0,13	0,26
MD Vs. Pés	0,18	0,46	0,46	0,18	0,08	0,46	0,13	0,08	0,46	0,35	0,18	<0,01	0,13	0,05	0,08	0,13	0,18	0,08	0,13	0,18	0,26	0,98
MD Vs. Língua	0,95	0,98	0,58	0,80	0,88		0,80		0,26	0,35	0,58	0,95	0,69	0,95	0,80	0,88	0,95	1,00	0,95	0,98	0,98	0,95
Pés Vs. Língua	0,05	0,26	0,03	0,02	0,01	0,46	0,58	0,08	<0,01	<0,01	<0,01	0,03	0,69	0,18	<0,01	0,02	0,05	0,05	0,35	0,35	0,46	0,80

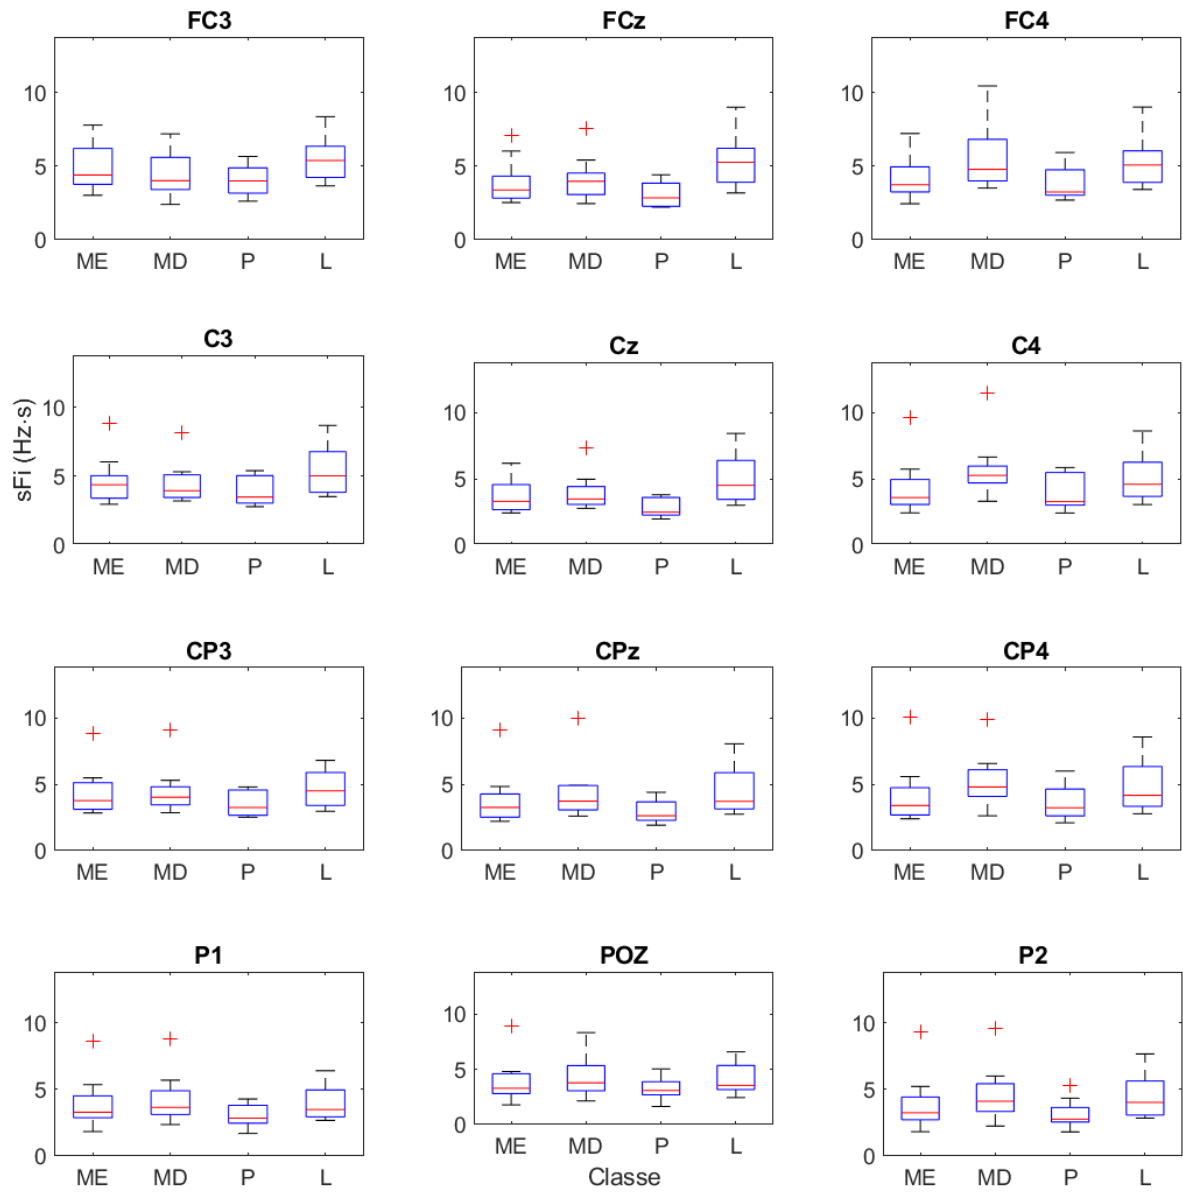


Figura 4.10 - Boxplot do PED  $sF_i$  no intervalo t3.

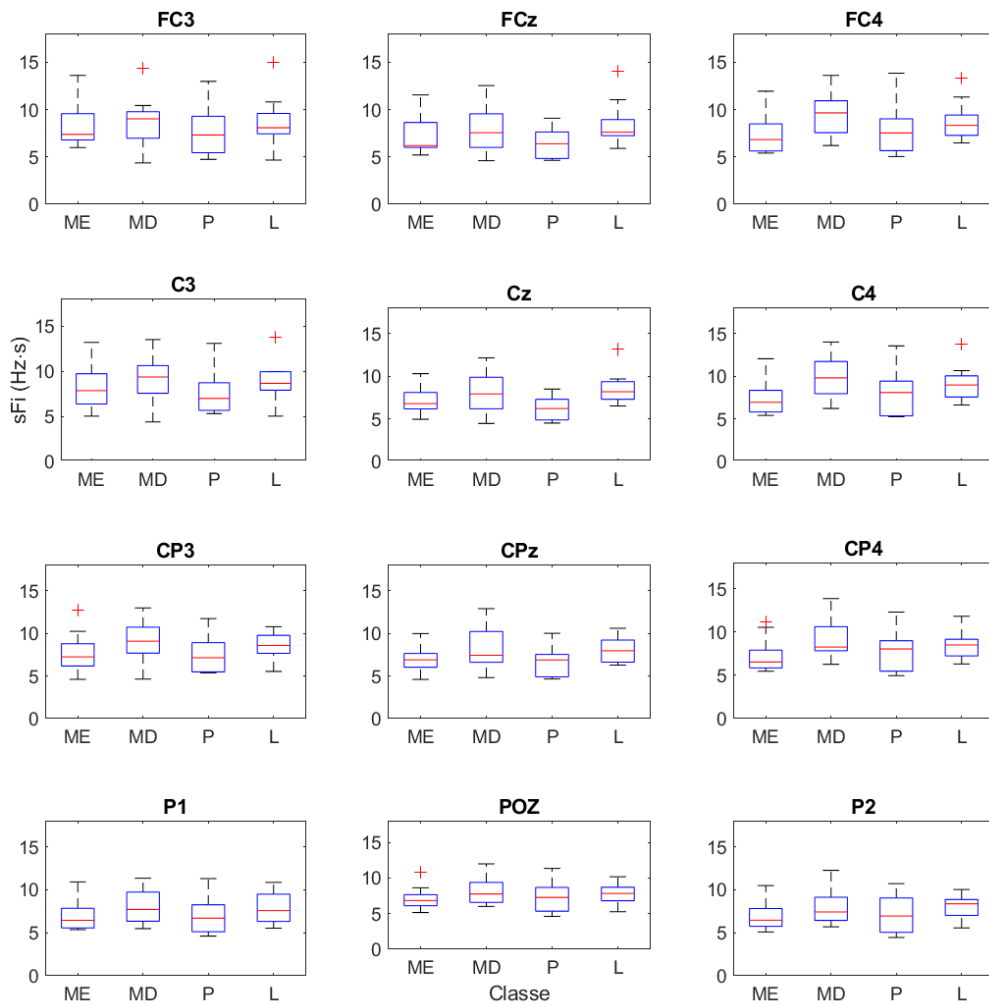


Figura 4.11 - *Boxplot* do PED  $sF_i$  no intervalo t4.

### 4.2.3 Diferenças entre as classes – PED $sA_{ef}$

A Tabela 4.7 contém os valores de  $W$  de Kendall para os testes de Friedman realizados para detectar diferença estatisticamente significativa para  $sA_{ef}$  (integral de  $sA_{ef}$  em cada intervalo  $t_n$ ) entre as classes, dado um intervalo de tempo e derivação específicos. As células destacadas em cinza indicam as combinações de derivação e intervalo com valor  $p$  inferior a 0,05, e as células em negrito indicam os maiores tamanhos de efeito observados (intervalo t3:  $W = 0,54$  em CPz e intervalo t4:  $W = 0,52$  em CPz). Observa-se que houve diferença estatisticamente significativa para 16 dos 22 derivações no intervalo t3 (menos derivações do que com  $sA_i$ ) com  $W$  de Kendall em torno de 0,41 (pouco acima do encontrado para  $sA_i$ ). E para 21 das 22 derivações (muito mais derivações do que com  $sA_i$ ) no intervalo t4, com  $W$  de Kendall em torno de 0,39. Estes valores dos  $W$  de Kendall significativos representam um tamanho de efeito médio. Diferente do observado para  $sA_i$ , não houve distinções significativas em t2 nem

em t5.

Como os intervalos t3 e t4 apresentaram diferenciação em mais derivações, para eles foi feito o *post hoc* de Tukey-Kramer, com os valores p do *post hoc* indicados na Tabela 4.8 e na Tabela 4.9. Também foram gerados *boxplots* de  $sA_i$  para as derivações FC3, FCz, FC4, C3, Cz, C4, CP3, CPz, CP4, P1, POz e P2 (Figura 4.12 e Figura 4.13).

Assim como para  $sA_i$ , em t3 (Tabela 4.8 e Figura 4.12), foi possível diferenciar IM dos pés de IM da mão direita na maioria das derivações centrais, centro-parietais e parietais, e diferenciar IM dos pés de IM da língua nas derivações fronto-centrais e centrais. Adicionalmente foi possível distinguir IM da língua de IM da mão esquerda em Fz, FCz e FC2, e distinguir IM dos pés de IM da mão esquerda nas derivações CP3, CP1, CPz e P1. Assim como para  $sA_i$ , os *boxplots* (Figura 4.12) indicam que a mediana de  $sA_{ef}$  dos pés é superior às outras. Comparando IM da língua com IM da mão esquerda nas derivações fronto-centrais para este intervalo, a mediana de  $sA_{ef}$  da língua é inferior.

Já em t4 (Tabela 4.9 e Figura 4.13), a diferenciação entre IM dos pés e da mão direita foi detectada em todas as derivações com exceção de C6. E, diferente do observado para  $sA_i$ , ainda foram detectadas diferenças estatisticamente significativas entre IM dos pés e da língua em C1 e Cz, e entre IM dos pés e da mão esquerda em FC3, FC1, C5 e C3 (derivações do hemisfério esquerdo). Para este intervalo, é facilmente perceptível como  $sA_{ef}$  dos pés é superior, porém as demais distinções indicadas pelo *post hoc* são mais difíceis de identificar visualmente.

Tabela 4.7 - Tamanhos de efeito (W de Kendall) dos testes de Friedman para diferenças interclasses no PED  $sA_{ef}$ , dado um par de derivação e intervalo de tempo. Valores sombreados correspondem a  $p < 0,05$ . Valores em negrito representam os maiores tamanhos de efeito nos intervalos t3 e t4.

Intervalo	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
t0	0,11	0,01	0,02	0,07	0,09	0,07	0,01	0,02	0,05	0,07	0,11	0,12	0,14	0,09	0,14	0,17	0,19	0,17	0,36	0,30	0,24	0,32
t1	0,01	0,08	0,10	0,09	0,08	0,09	0,10	0,09	0,09	0,07	0,07	0,14	0,06	0,11	0,13	0,09	0,11	0,17	0,13	0,12	0,12	0,19
t2	0,17	0,16	0,20	0,23	0,21	0,17	0,19	0,12	0,09	0,09	0,09	0,04	0,04	0,20	0,14	0,10	0,05	0,04	0,19	0,09	0,14	0,22
t3	0,39	0,27	0,46	0,52	0,44	0,31	0,04	0,11	0,46	0,52	0,44	0,33	0,22	0,35	0,37	<b>0,54</b>	0,37	0,23	0,46	0,39	0,24	0,16
t4	0,41	0,39	0,34	0,34	0,39	0,31	0,51	0,39	0,34	0,39	0,31	0,39	0,20	0,48	0,42	<b>0,52</b>	0,42	0,29	0,47	0,46	0,31	0,29
t5	0,04	0,04	0,04	0,04	0,11	0,21	0,12	0,12	0,09	0,11	0,19	0,19	0,26	0,06	0,17	0,18	0,09	0,24	0,22	0,14	0,17	0,14
t6	0,24	0,42	0,34	0,29	0,39	0,31	0,21	0,27	0,27	0,31	0,24	0,19	0,16	0,21	0,17	0,09	0,19	0,09	0,16	0,09	0,09	0,12

Tabela 4.8 - Valores p dos testes *post hoc* de Tukey-Kramer feitos no intervalo t3 para o PED  $sA_{ef}$ . Valores sombreados correspondem a  $p < 0,05$ . Células vazias tiveram valor  $p < 2.2204e-16$ .

Comparação	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
ME Vs. MD	0,69	0,98	0,69	0,58	0,26	0,08	0,95	0,95	0,69	0,58	0,26	0,18	0,26	1,00	1,00	0,80	0,46	0,80	0,98	0,88	0,69	0,98
ME Vs. Pés	0,95	0,46	0,69	0,80	0,95	1,00	0,95	0,58	0,46	0,35	0,80	0,69	0,88	0,03	0,03	0,03	0,26	0,35	0,01	0,05	0,46	0,35
ME Vs. Língua	0,03	0,46	0,05	0,02	0,03	0,26	0,98	0,98	0,13	0,13	0,08	0,80	0,88	0,46		0,88	0,88	0,98	0,95		0,88	1,00
MD Vs. Pés	0,35	0,26	0,13	0,13	0,08	0,05	0,69	0,26	0,05	0,02	0,03	0,01	0,05	0,02	0,02	<0,01	<0,01	0,05	<0,01	<0,01	0,05	0,18
MD Vs. Língua	0,35	0,69	0,46	0,35	0,80	0,95	0,80	0,80	0,69	0,80	0,95	0,69	0,69	0,35	1,00	1,00	0,88	0,95	0,80	0,88	0,98	1,00
Pés Vs. Língua	<0,01	0,02	<0,01	<0,01	<0,01	0,18	1,00	0,80	<0,01	<0,01	<0,01	0,18	0,46	0,58	0,03	<0,01	0,05	0,18	0,05	0,05	0,13	0,26

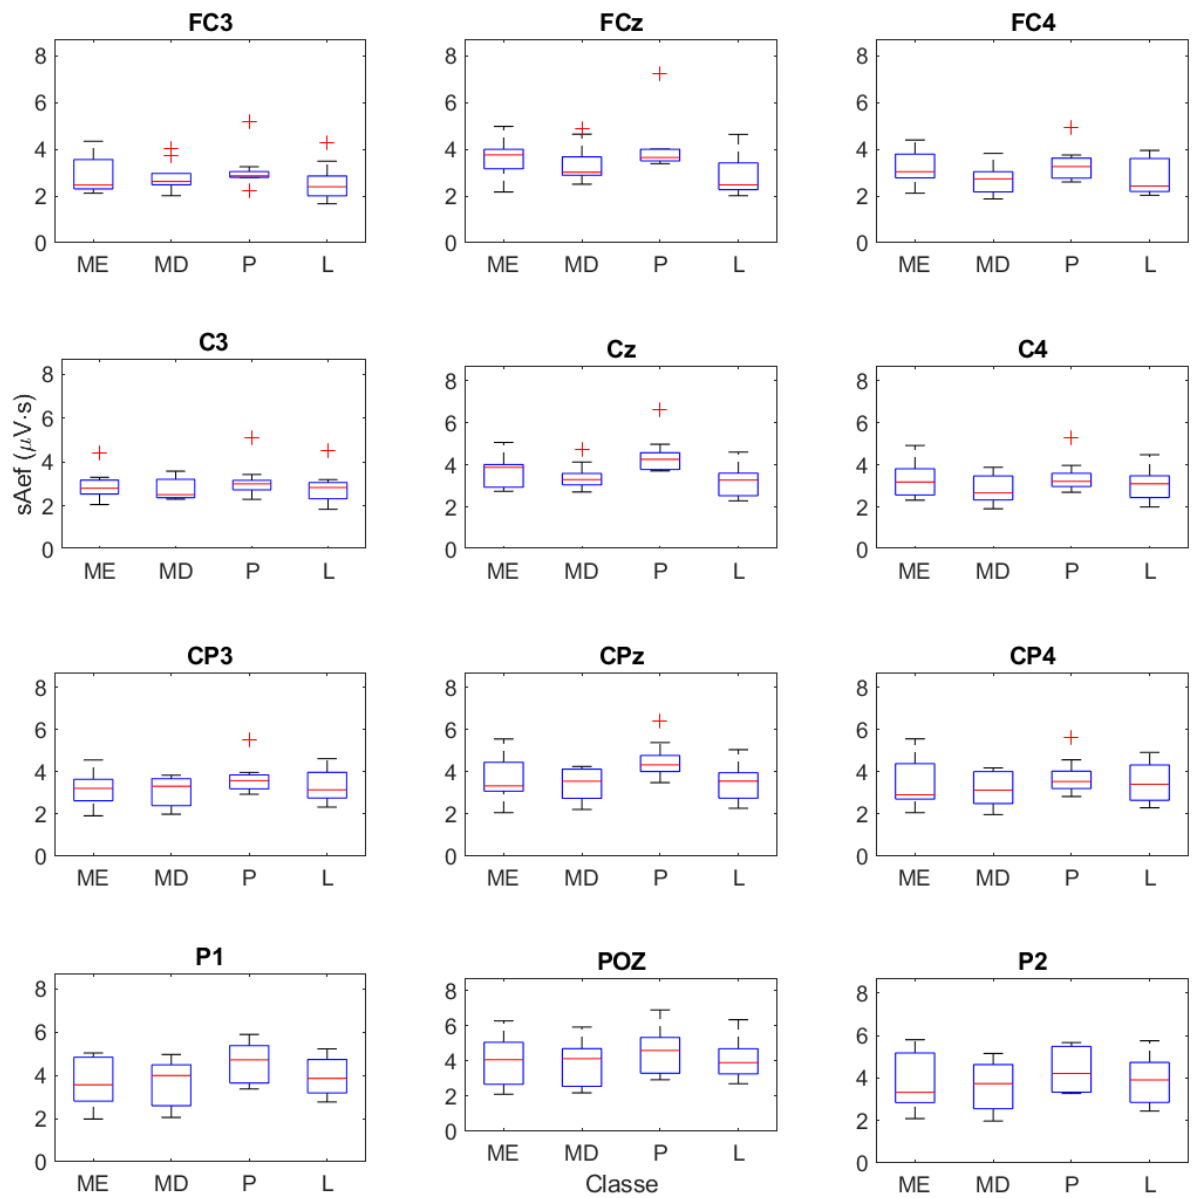


Figura 4.12 - *Boxplot* do PED  $sA_{ef}$  no intervalo t3.

Tabela 4.9 - Valores p dos testes *post hoc* de Tukey-Kramer feitos no intervalo t4 para o PED  $sA_{ef}$ . Valores sombreados correspondem a  $p < 0,05$ .Células vazias tiveram valor  $p < 2.2204e-16$ .

Comparação	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
ME Vs. MD	0,88	0,98	1,00	0,69	0,46	0,18	0,98	1,00	0,88	0,88	0,58	0,18	0,18	0,58	0,35	0,05	0,13	0,13	0,35	0,26	0,26	0,35
ME Vs. Pés	0,05	0,01	0,02	0,18	0,18	0,69	<0,01	0,01	0,18	0,08	0,26	0,46		0,05	0,18	0,46	0,46	0,88	0,13	0,18	0,58	0,69
ME Vs. Língua	0,46	0,18	0,80	0,95	1,00	1,00	0,08	0,88	0,80	0,95	1,00	1,00	1,00	0,95		0,88	0,98	0,98	0,95	1,00	1,00	0,80
MD Vs. Pés	<0,01	0,03	0,03	0,01	<0,01	0,01	0,01	0,02	0,03	0,01	0,01	<0,01	0,18	<0,01	<0,01	<0,01	<0,01	0,02	<0,01	<0,01	0,01	0,03
MD Vs. Língua	0,13	0,35	0,88	0,95	0,58	0,26	0,18	0,95	1,00	1,00	0,69	0,13	0,13	0,26	0,35	0,26	0,26	0,26	0,13	0,18	0,18	0,05
Pés Vs. Língua	0,69	0,69	0,18	0,05	0,13	0,58	0,69	0,08	0,02	0,02	0,18	0,58	1,00	0,18	0,18	0,13	0,26	0,69	0,35	0,26	0,69	1,00

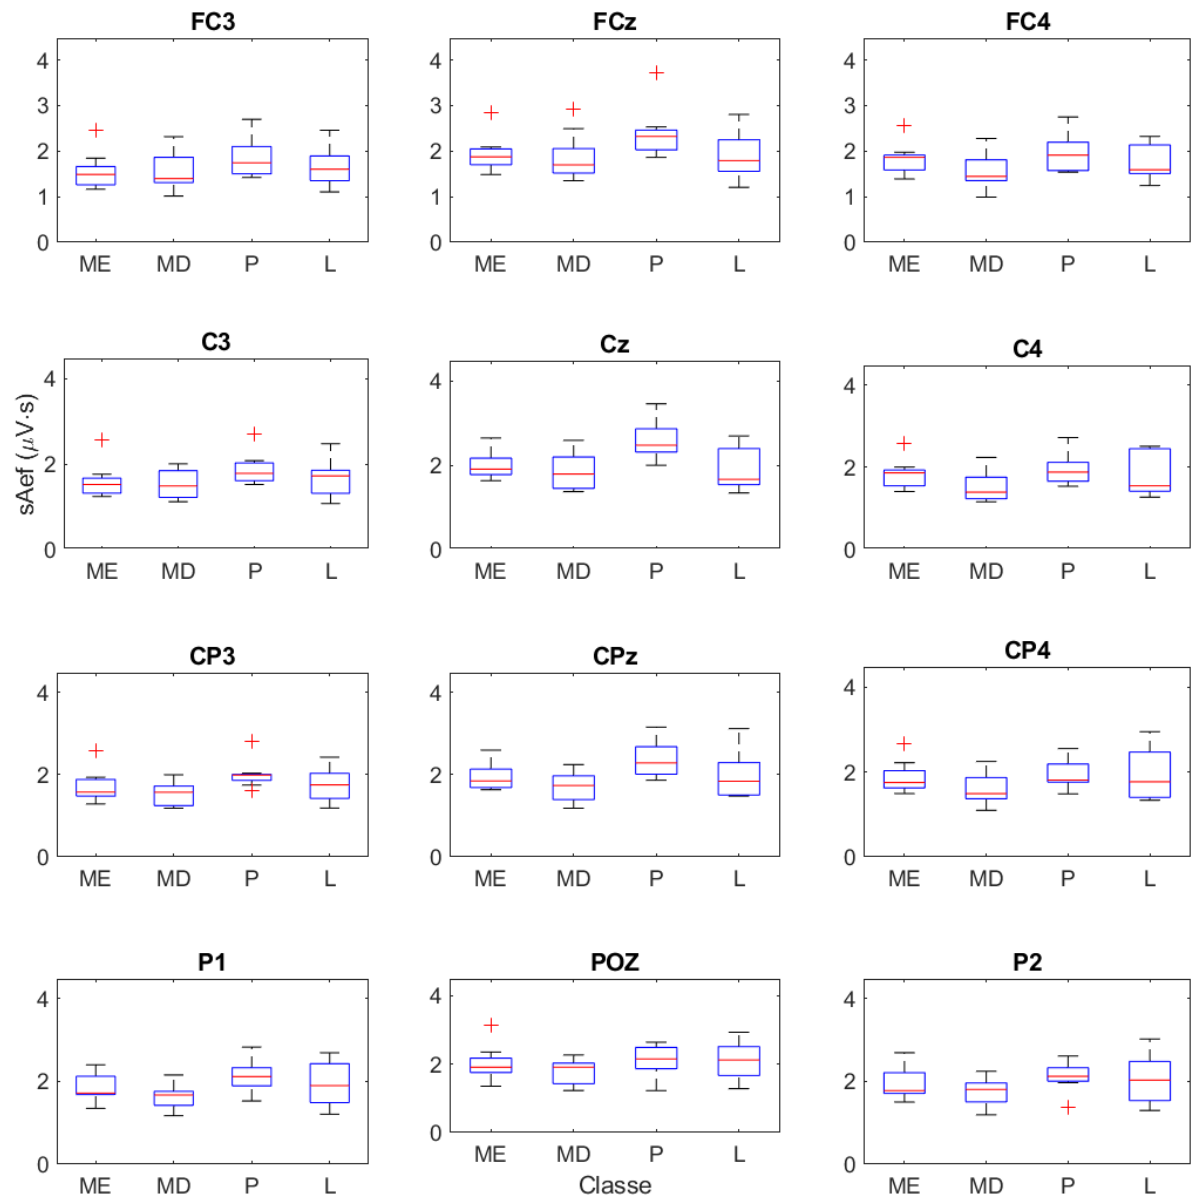


Figura 4.13 - *Boxplot* do PED  $sA_{ef}$  no intervalo t4.

#### 4.2.4 Diferenças entre as classes – PED $sF_{ce}$

A Tabela 4.10 contém os valores de  $W$  de Kendall para os testes de Friedman realizados para detectar diferença estatisticamente significativa para  $sF_{ce}$  (integral de  $sF_{ce}$  em cada intervalo  $t_n$ ) entre as classes, dado um intervalo de tempo e derivação específicos. As células destacadas em cinza indicam as combinações de derivação e intervalo com valor  $p$  inferior a 0,05, e as células em negrito indicam os maiores tamanhos de efeito observados (intervalo t3:  $W=0,62$  em Cz e intervalo t4:  $W=0,57$  em CP4). Observa-se que houve diferença

estatisticamente significativa para 20 das 22 derivações no intervalo t3 com W de Kendall em torno de 0,48. E para 15 das 22 derivações no intervalo t4 com W de Kendall em torno de 0,42. Estes valores dos W de Kendall significativos representam um tamanho de efeito médio. Não foram detectadas diferenças significativas entre as classes nos intervalos t2 e t5, similarmente ao observado para  $sF_i$ .

Como os intervalos t3 e t4 apresentaram diferenciação em mais derivações, para eles foi feito o *post hoc* de Tukey-Kramer, com os valores p do *post hoc* indicados na Tabela 4.11 e Tabela 4.12. Também foram gerados *boxplots* de  $sF_{ce}$  para as derivações FC3, FCz, FC4, C3, Cz, C4, CP3, CPz, CP4, P1, POz e P2 (Figura 4.14 e Figura 4.15).

Em t3 (Tabela 4.11 e Figura 4.14), foi possível diferenciar IM dos pés de IM da mão direita na maioria das derivações centrais, centro-parietais e parietais, e diferenciar IM dos pés de IM da língua na maioria das derivações. Também foi detectada diferença estatisticamente significativa entre IM da mão esquerda e da mão direita em C4. Os *boxplots* para t3 (Figura 4.14) indicam que  $sF_{ce}$  é menor para a IM dos pés do que para as IM da mão direita e da língua.

Em t4 (Tabela 4.12 e Figura 4.15), foram detectadas diferenças estatisticamente significativas entre IM da mão direita e da mão esquerda (em C4, C6, CP4, P1, P2, predominantemente derivações do hemisfério direito), entre IM da mão esquerda e da língua (em C2, C4 e 6 das 8 derivações centro-parietais e parietais), entre IM dos pés e da mão direita (em CP4 e P2) e entre IM dos pés e da língua (em 10 das 22 derivações, em derivações distribuídas pelo escalpo). Para este intervalo, os *boxplots* seguem o mesmo padrão, porém com maior variância.

Tabela 4.10 - Tamanhos de efeito (W de Kendall) dos testes de Friedman para diferenças interclasses no PED  $sF_{ce}$ , dado um par de derivação e intervalo de tempo. Valores sombreados correspondem a  $p < 0,05$ . Valores em negrito representam os maiores tamanhos de efeito nos intervalos t3 e t4.

Intervalo	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
t0	0,32	0,16	0,26	0,32	0,21	0,26	0,19	0,24	0,13	0,19	0,24	0,28	0,24	0,34	0,24	0,17	0,23	0,29	0,22	0,19	0,12	0,09
t1	0,12	0,07	0,12	0,09	0,06	0,10	0,06	0,04	0,02	0,04	0,06	0,09	0,14	0,05	0,06	0,09	0,07	0,06	0,08	0,13	0,15	0,12
t2	0,12	0,06	0,13	0,09	0,04	0,11	0,02	0,04	0,09	0,02	0,07	0,14	0,11	0,09	0,11	0,04	0,06	0,12	0,02	0,09	0,06	0,09
t3	0,56	0,39	0,61	0,61	0,52	0,42	0,07	0,21	0,52	<b>0,62</b>	0,55	0,42	0,31	0,29	0,46	0,59	0,47	0,49	0,38	0,41	0,59	0,42
t4	0,12	0,22	0,21	0,31	0,43	0,27	0,12	0,12	0,44	0,38	0,36	0,44	0,34	0,14	0,31	0,56	0,47	<b>0,57</b>	0,49	0,47	0,54	0,21
t5	0,04	0,14	0,04	0,02	0,16	0,13	0,02	0,07	0,02	0,04	0,07	0,06	0,07	0,11	0,07	0,03	0,09	0,14	0,06	0,05	0,06	0,05
t6	0,26	0,39	0,41	0,41	0,39	0,23	0,16	0,21	0,25	0,24	0,19	0,09	0,04	0,19	0,15	0,18	0,11	0,06	0,05	0,14	0,05	0,13

Tabela 4.11 - Valores p dos testes *post hoc* de Tukey-Kramer feitos no intervalo t3 para o PED  $sF_{ce}$ . Valores sombreados correspondem a  $p < 0,05$ . Células vazias tiveram valor  $p < 2.2204e-16$ .

Comparação	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
ME Vs. MD	0,95	0,95	0,98	0,98	0,58	0,35	0,98	0,98		0,88	0,35	0,03	0,13	0,98	0,58	0,05	0,13	0,08	0,18	0,13	0,05	0,08
ME Vs. Pés	0,26	0,18	0,05	0,13	0,35	0,46	0,69	0,80	0,05	0,18	0,46	1,00	0,88	0,26	0,26	0,58	0,58	0,58	0,58	0,69	0,58	0,95
ME Vs. Língua	0,08	0,46	0,26	0,13	0,13	0,35	0,98	0,35	0,46	0,08	0,08	0,13	0,69	0,69	0,35	0,18	0,35	0,46	0,69	0,46	0,18	0,13
MD Vs. Pés	0,08	0,46	0,13	0,05	0,02	0,01	0,88	0,58	0,05	0,03	0,01	0,02	0,02	0,13	0,01	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01	0,02
MD Vs. Língua	0,26	0,18	0,13	0,26	0,80		0,88	0,58	0,46	0,35	0,88	0,95	0,69	0,88	0,98	0,95	0,95	0,80	0,80	0,88	0,95	1,00
Pés Vs. Língua	<0,01	<0,01	<0,01	<0,01	<0,01	0,01	0,46	0,05	<0,01	<0,01	<0,01	0,08	0,26	0,02	<0,01	<0,01	0,02	0,03	0,08	0,05	<0,01	0,03

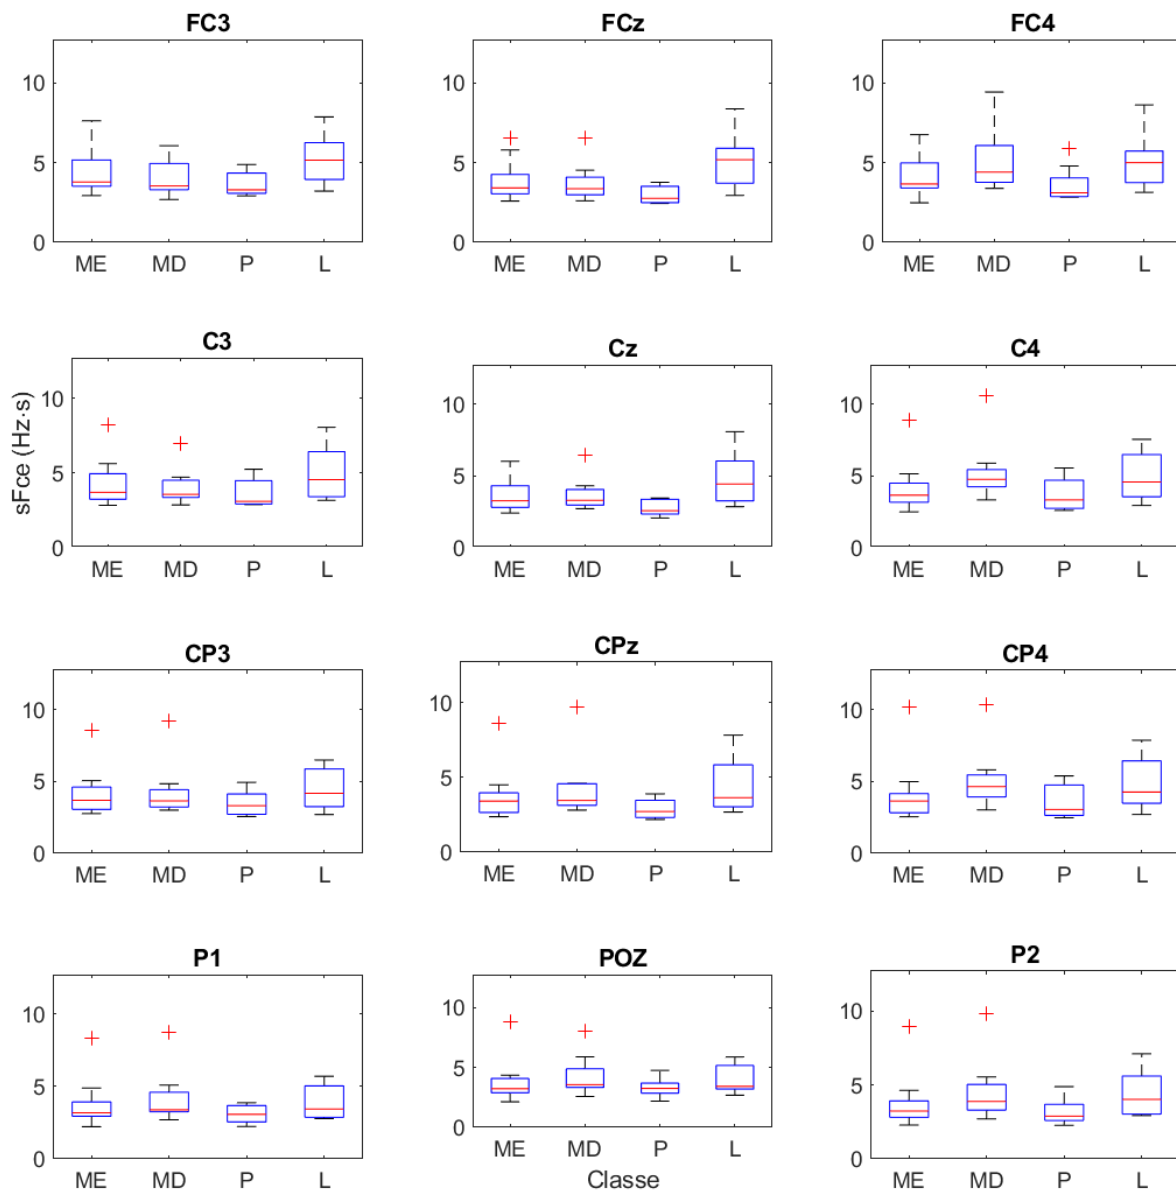


Figura 4.14 - *Boxplot* do PED  $sF_{ce}$  no intervalo  $t_3$ .

Tabela 4.12 - Valores p dos testes *post hoc* de Tukey-Kramer feitos no intervalo t4 para o PED  $sF_{ce}$ . Valores sombreados correspondem a  $p < 0,05$ . Células vazias tiveram valor  $p < 2.2204e-16$ .

Comparação	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ
ME Vs. MD		0,88	0,98	1,00	0,58	0,08	0,69	0,88	0,98	1,00	0,69	<0,01	0,02	0,58	0,69	0,08	0,05	<0,01	<0,01	0,05	0,02	0,05
ME Vs. Pés	0,46	0,69	0,58	0,26	0,69	0,88	0,88	0,98	0,69	0,35		0,80	0,95	1,00	0,88	1,00		0,80	0,88		1,00	0,58
ME Vs. Língua	0,98	0,46	0,58	0,58	0,08	0,08	0,88	0,46	0,05	0,26	0,02	0,03	0,18	0,26	0,13	<0,01	0,02	0,01	0,02	0,02	0,01	0,35
MD Vs. Pés	0,46	0,26	0,80	0,18	0,08	0,35	0,26	0,69	0,46	0,26	0,69	0,08	0,08	0,69	0,26	0,05	0,05	0,03	0,05	0,05	0,03	0,58
MD Vs. Língua	0,98	0,88	0,35	0,69	0,69		0,98	0,88	0,13	0,35	0,26	0,95	0,80	0,95	0,69	0,80	0,98	0,95	0,98	0,98	1,00	0,80
Pés Vs. Língua	0,26	0,05	0,05	0,01	<0,01	0,35	0,46	0,26	<0,01	<0,01	0,02	0,26	0,46	0,35	0,02	<0,01	0,02	0,13	0,13	0,02	0,02	0,98

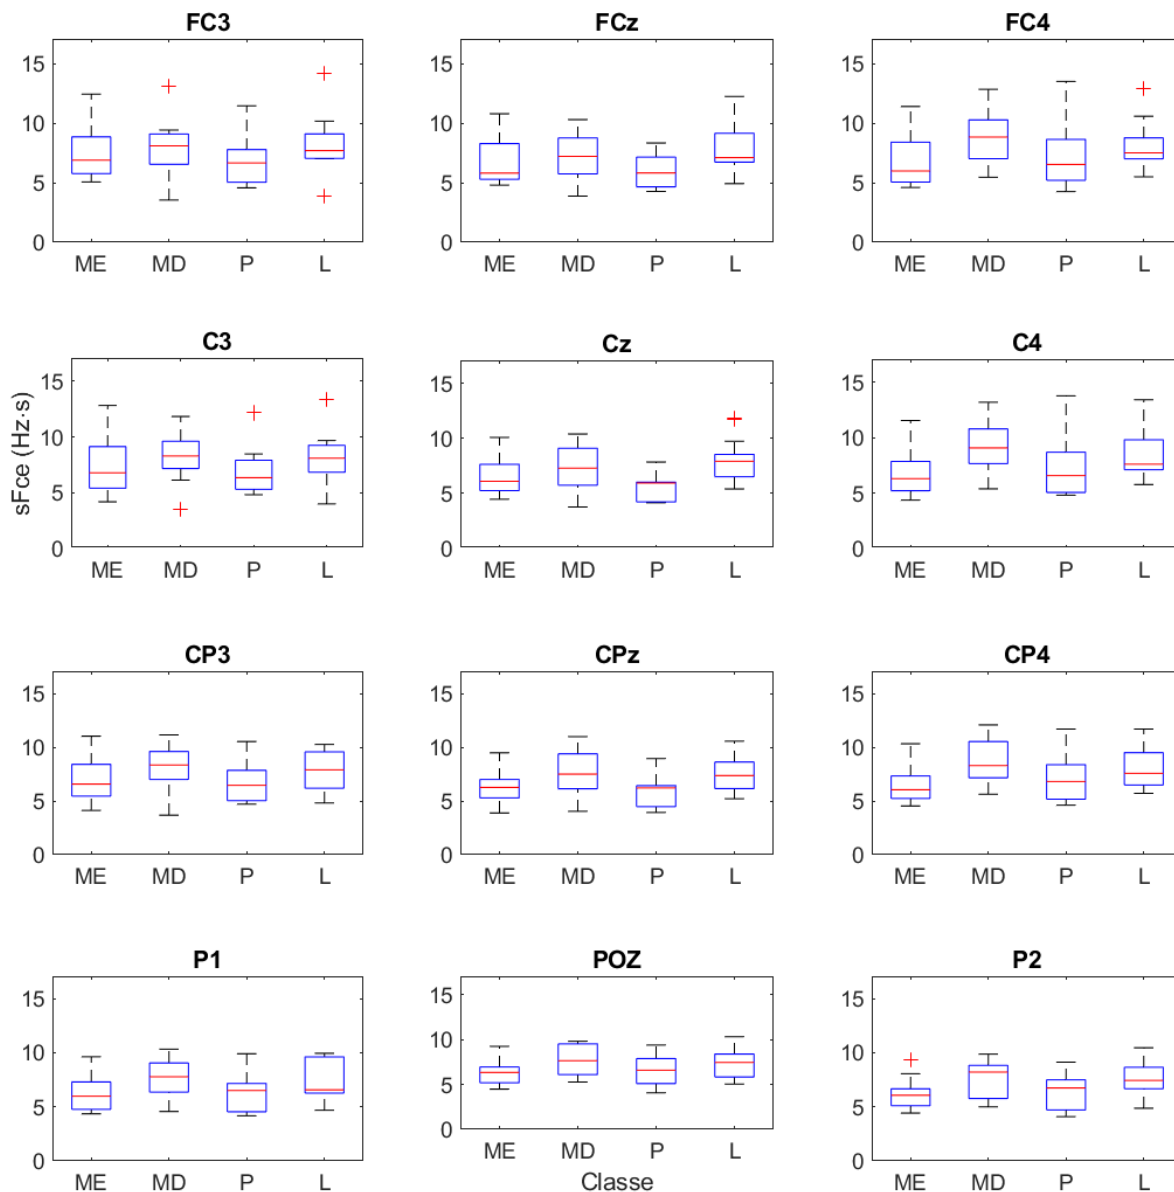


Figura 4.15 - *Boxplot* do PED  $sF_{ce}$  no intervalo t4.

#### 4.2.5 Resumo das diferenças entre classes para os PEDs de amplitude e frequência

Os resultados das seções 4.2.1 a 4.2.4 foram resumidos de forma a salientar as similaridades e diferenças entre os PEDs obtidos da TDH e da TFTC. A Tabela 4.13 lista as derivações para as quais foram identificadas diferenças estatisticamente significativas entre os pares de IM comparadas para cada PED nos intervalos t3 e t4. A Tabela 4.14 lista a quantidade

de derivações em que as diferenças foram detectadas pelos testes *post hoc* de Tukey-Kramer.

Pela Tabela 4.13 é possível perceber primeiramente que o padrão de diferenças estatisticamente significativas em t3 é diferente de t4. Apesar de haver diferença estatisticamente significativa para  $sA_i$  entre IM da língua e da mão direita, em t4, nas derivações FC4 e C5, no geral, nenhum dos PEDs permitiu uma boa discriminação entre estas duas classes.

Ainda, pode-se afirmar que ambas as técnicas, TDH e TFTC, levam a resultados similares quanto a distinção tanto em t3, quanto em t4, entre IM dos pés e da mão direita, e entre IM dos pés e da língua. Para t4, os PEDs de amplitude ( $sA_i$  e  $sA_{ef}$ ) detectam a diferença entre IM da mão direita e dos pés em mais derivações do que os PEDs de frequência ( $sF_i$  e  $sF_{ce}$ ), o contrário acontecendo para a diferença entre IM dos pés e da língua, com os PEDs de frequência detectando-a para um maior número de derivações.

Além disso, os PEDs obtidos a partir da TFTC ( $sA_{ef}$  e  $sF_{ce}$ ) detectaram diferenças estatisticamente significativas nas comparações restantes (mão esquerda vs. direita, mão esquerda vs. pés, mão esquerda vs. língua) para mais derivações do que os PEDs da TDH ( $sA_i$  e  $sF_i$ ).

A Tabela 4.14 fornece a contagem do número de derivações para as quais foi identificada diferença estatisticamente significativa entre pares de IMs para cada PED nos intervalos t3 e t4. A soma por colunas representa a quantidade de trios derivação-PED-intervalo que diferenciam cada par de IM e reforça os resultados dos testes *post hoc*s, indicando que os pares de IMs mais fáceis de distinguir são pés vs. mão direita (soma = 91), e pés vs. língua (soma = 74). Adicionalmente, ela mostra que as outras diferenças são mais difíceis de detectar (soma  $\leq$  13) com particular atenção para a comparação entre mão direita e língua, que foi detectada apenas em 2 derivações usando  $sA_i$ .

A soma por linhas representa a soma dos pares derivação-par de IMs que cada PED-intervalo diferencia e reforça as constatações dos parágrafos anteriores, indicando que, em t3, as técnicas apresentam desempenho semelhante (24 vs 26 para PEDs de amplitude; 36 vs 31 para PEDs de frequência), mas que, em t4, a TFTC é capaz de detectar mais diferenças (soma( $sA_{ef}$ ) + soma( $sF_{ce}$ )=52) do que a TDH (soma( $sA_i$ ) + soma( $sF_i$ )=29).

Tabela 4.13 - Lista de derivações onde houve diferenciação das classes de IM para cada PED em t3 e em t4. --- indica ausência de diferença estatisticamente significativa.

	PED	ME Vs. MD	ME Vs. Pés	ME Vs. Língua	MD Vs. Pés	MD Vs. Língua	Pés Vs. Língua
t3	sAi	---	CP1, P1	---	C1, Cz, C2, C4, CP3, CP1, CPz, CP2, P1, Pz, P2, POz	---	Fz, FC3, FC1, FCz, FC2, C1, Cz, C2, CPz, CP2
	sAef	---	CP3, CP1, CPz, P1	Fz, FCz, FC2	Cz, C2, C4, CP3, CP1, CPz, CP2, P1, Pz	---	Fz, FC3, FC1, FCz, FC2, C1, Cz, C2, CP1, CPz
	sFi	CP2	---	FC1	Fz, FC1, FCz, FC2, FC4, C1, C2, C4, C6, CP3, CP1, CPz, CP2, CP4, P1, Pz, P2, POz	---	Fz, FC3, FC1, FCz, FC2, C3, C1, Cz, C2, CP3, CP1, CPz, CP2, Pz, P2, POz
	sFce	C4	---	---	FC2, FC4, Cz, C2, C4, C6, CP1, CPz, CP2, CP4, P1, Pz, P2, POz	---	Fz, FC3, FC1, FCz, FC2, FC4, C1, Cz, C2, CP3, CP1, CPz, CP2, CP4, P2, POz
t4	sAi	---	---	---	FCz, FC2, FC4, C5, Cz, C2, C4, CP3, CP1, CPz, CP4, P1, Pz, P2	FC4, C5	FCz
	sAef	---	FC3, FC1, C5, C3	---	Fz, FC3, FC1, FCz, FC2, FC4, C5, C3, C1, Cz, C2, C4, CP3, CP1, CPz, CP2, CP4, P1, Pz, P2, POz	---	C1, Cz
	sFi	C4	---	CP4	C4	---	FC1, FCz, FC2, C1, Cz, C2, C4, CP1, CPz
	sFce	C4, C6, CP4, P1, P2	---	C2, C4, CPz, CP2, CP4, P1, Pz, P2	CP4, P2	---	FCz, FC2, C1, Cz, C2, CP1, CPz, CP2, Pz, P2

Tabela 4.14 – Quantidade de derivações para as quais foi identificada diferença estatisticamente significativa entre pares de IMs para cada PED nos intervalos t3 e t4.

Intervalo	PED	ME Vs. MD	ME Vs. Pés	ME Vs. Língua	MD Vs. Pés	MD Vs. Língua	Pés Vs. Língua	Soma dos pares derivação-par de IM que cada PED-intervalo diferencia
t3	sAi	0	2	0	12	0	10	24
	sAef	0	4	3	9	0	10	26
	sFi	1	0	1	18	0	16	36
	sFce	1	0	0	14	0	16	31
t4	sAi	0	0	0	14	2	1	17
	sAef	0	4	0	21	0	2	27
	sFi	1	0	1	1	0	9	12
	sFce	5	0	8	2	0	10	25
<b>Soma dos trios derivação-PED-intervalo que diferenciam cada par de IM</b>		<b>8</b>	<b>10</b>	<b>13</b>	<b>91</b>	<b>2</b>	<b>74</b>	

### 4.3 Diferenças entre os intervalos

#### 4.3.1 Diferenças entre os intervalos – $sA_i$ , $sF_i$ e $\text{corr}(A_i, F_i)$

Nesta seção são descritos os resultados da análise da diferença entre os intervalos para a integral dos PEDs obtidos da TDH, assim como a correlação entre  $A_i$  e  $F_i$  ( $\text{corr}(A_i, F_i)$ ). Ao realizar os testes de Friedman para as várias combinações de derivação de EEG e classe IM todas as comparações foram estatisticamente significativas, tanto para  $sA_i$  quanto para  $sF_i$ . Para  $\text{corr}(A_i, F_i)$ , de todas as 88 comparações (4 classes de IM  $\times$  22 derivações de EEG), apenas 13 delas não foram estatisticamente significativas.

A Tabela 4.15 contém os valores de W de Kendall para cada variável (integrais dos PEDs e correlação) para cada par de IM-derivação, além da mediana e o intervalo interquartil (IIQ) calculados ao longo das derivações para cada classe de IM. Nota-se que os tamanhos de efeito para  $sA_i$  e  $sF_i$  são elevados (medianas entre 0,68 e 0,81) e baixa variância (IIQs  $\leq$  0,12) para todas as imaginações de movimentos. Para a correlação, os tamanhos de efeito também possuem baixa variabilidade (IIQs  $\leq$  0,10), porém com baixos valores de medianas (entre 0,24 e 0,31). Estes resultados mostram que há variação clara das métricas ( $sA_i$ ,  $sF_i$  e  $\text{corr}(A_i, F_i)$ ) ao longo do tempo, indicando que há valor em investigar a relação entre a evolução temporal das variáveis e o protocolo experimental.

A Figura 4.16 apresenta o *boxplot* ao longo dos intervalos das integrais dos PEDs para a IM dos pés, escolhida para ilustrar a variação da evolução temporal das variáveis. Esta Figura reforça as constatações feitas nas análises dos traçados (seção 4.1.2). Observando a metade esquerda da Figura, o padrão aparente de  $sA_i$  é de um vale com valor próximo a  $2,5 \mu V \cdot s$  em t1 (pré IM), um aumento até cerca de  $5,0 \mu V \cdot s$  em t3, um decréscimo até chegar no vale em t5 com valor de cerca de  $1,0 \mu V \cdot s$ , voltando a aumentar em t6. Este padrão pode ser observado para todas as derivações apresentadas. Observando a metade direita da Figura 4.16, nota-se que o padrão de  $sF_i$  é oposto ao de  $sA_i$ , com um pico em torno de  $6,0 Hz \cdot s$  em t1, que decresce até atingir  $3,0 Hz \cdot s$  em t3, voltando a aumentar até cerca de  $9,0 Hz \cdot s$  em t5, voltando a cair em t6.

Por último, observando a Figura 4.17, que apresenta os *boxplots* da correlação entre  $A_i$  e  $F_i$  ( $\text{corr}(A_i, F_i)$ ), nota-se que, para todas as derivações, com exceção dos fronto-centrais, a correlação é fortemente negativa e com baixa variabilidade de t1 a t5, que inclui os intervalos

de IM e o intervalo que precede seu início. Nas derivações fronto-centrais a mediana da correlação continua próxima de -1, porém com maior variabilidade em t1 e t3.

Tabela 4.15 – Tamanho de efeito, W de Kendall, da comparação entre intervalos para  $sA_i$ ,  $sF_i$  e  $\text{corr}(A_i, F_i)$ . Valores em cinza indicam valor  $p < 0,05$ . A mediana e o intervalo interquartil foram calculados para cada classe de IM.

W de Kendall - Entre intervalos - $sA_i$																								
Classe	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ	Mediana	IIQ
ME	0,78	0,73	0,76	0,81	0,74	0,76	0,68	0,74	0,77	0,73	0,71	0,74	0,78	0,78	0,83	0,81	0,84	0,84	0,80	0,76	0,75	0,79	0,77	0,06
MD	0,71	0,76	0,77	0,78	0,76	0,75	0,73	0,72	0,72	0,78	0,79	0,78	0,79	0,77	0,84	0,82	0,81	0,83	0,82	0,79	0,80	0,82	0,78	0,05
Pés	0,68	0,79	0,81	0,79	0,78	0,78	0,80	0,81	0,82	0,81	0,82	0,81	0,76	0,83	0,85	0,86	0,84	0,81	0,87	0,87	0,83	0,85	0,81	0,05
Língua	0,67	0,72	0,70	0,75	0,72	0,71	0,71	0,74	0,66	0,65	0,55	0,60	0,59	0,78	0,73	0,61	0,64	0,60	0,76	0,67	0,66	0,70	0,69	0,08
W de Kendall - Entre intervalos - $sF_i$																								
Classe	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ	Mediana	IIQ
ME	0,72	0,66	0,72	0,73	0,69	0,64	0,67	0,72	0,78	0,75	0,68	0,64	0,63	0,76	0,83	0,77	0,77	0,67	0,83	0,77	0,79	0,81	0,72	0,10
MD	0,54	0,63	0,63	0,55	0,66	0,62	0,66	0,68	0,72	0,64	0,68	0,61	0,72	0,73	0,76	0,70	0,65	0,74	0,75	0,74	0,76	0,80	0,68	0,10
Pés	0,63	0,72	0,70	0,67	0,68	0,65	0,76	0,77	0,75	0,77	0,76	0,76	0,71	0,84	0,83	0,85	0,81	0,82	0,84	0,87	0,87	0,83	0,76	0,12
Língua	0,56	0,70	0,71	0,72	0,67	0,71	0,56	0,65	0,68	0,66	0,70	0,70	0,63	0,74	0,72	0,76	0,71	0,73	0,82	0,78	0,72	0,83	0,71	0,06
W de Kendall - Entre intervalos - $\text{corr}(A_i, F_i)$																								
Classe	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ	Mediana	IIQ
ME	0,30	0,46	0,31	0,41	0,31	0,30	0,30	0,28	0,49	0,45	0,38	0,22	0,14	0,37	0,28	0,34	0,29	0,19	0,35	0,28	0,35	0,39	0,31	0,09
MD	0,19	0,18	0,18	0,27	0,30	0,27	0,29	0,21	0,13	0,23	0,27	0,39	0,36	0,20	0,23	0,12	0,08	0,23	0,31	0,30	0,24	0,27	0,24	0,10
Pés	0,48	0,33	0,27	0,36	0,30	0,23	0,30	0,27	0,34	0,23	0,34	0,31	0,31	0,26	0,33	0,29	0,26	0,33	0,33	0,31	0,32	0,44	0,31	0,06
Língua	0,13	0,28	0,28	0,29	0,27	0,39	0,30	0,30	0,28	0,25	0,46	0,30	0,31	0,42	0,37	0,34	0,28	0,41	0,45	0,33	0,38	0,22	0,30	0,10

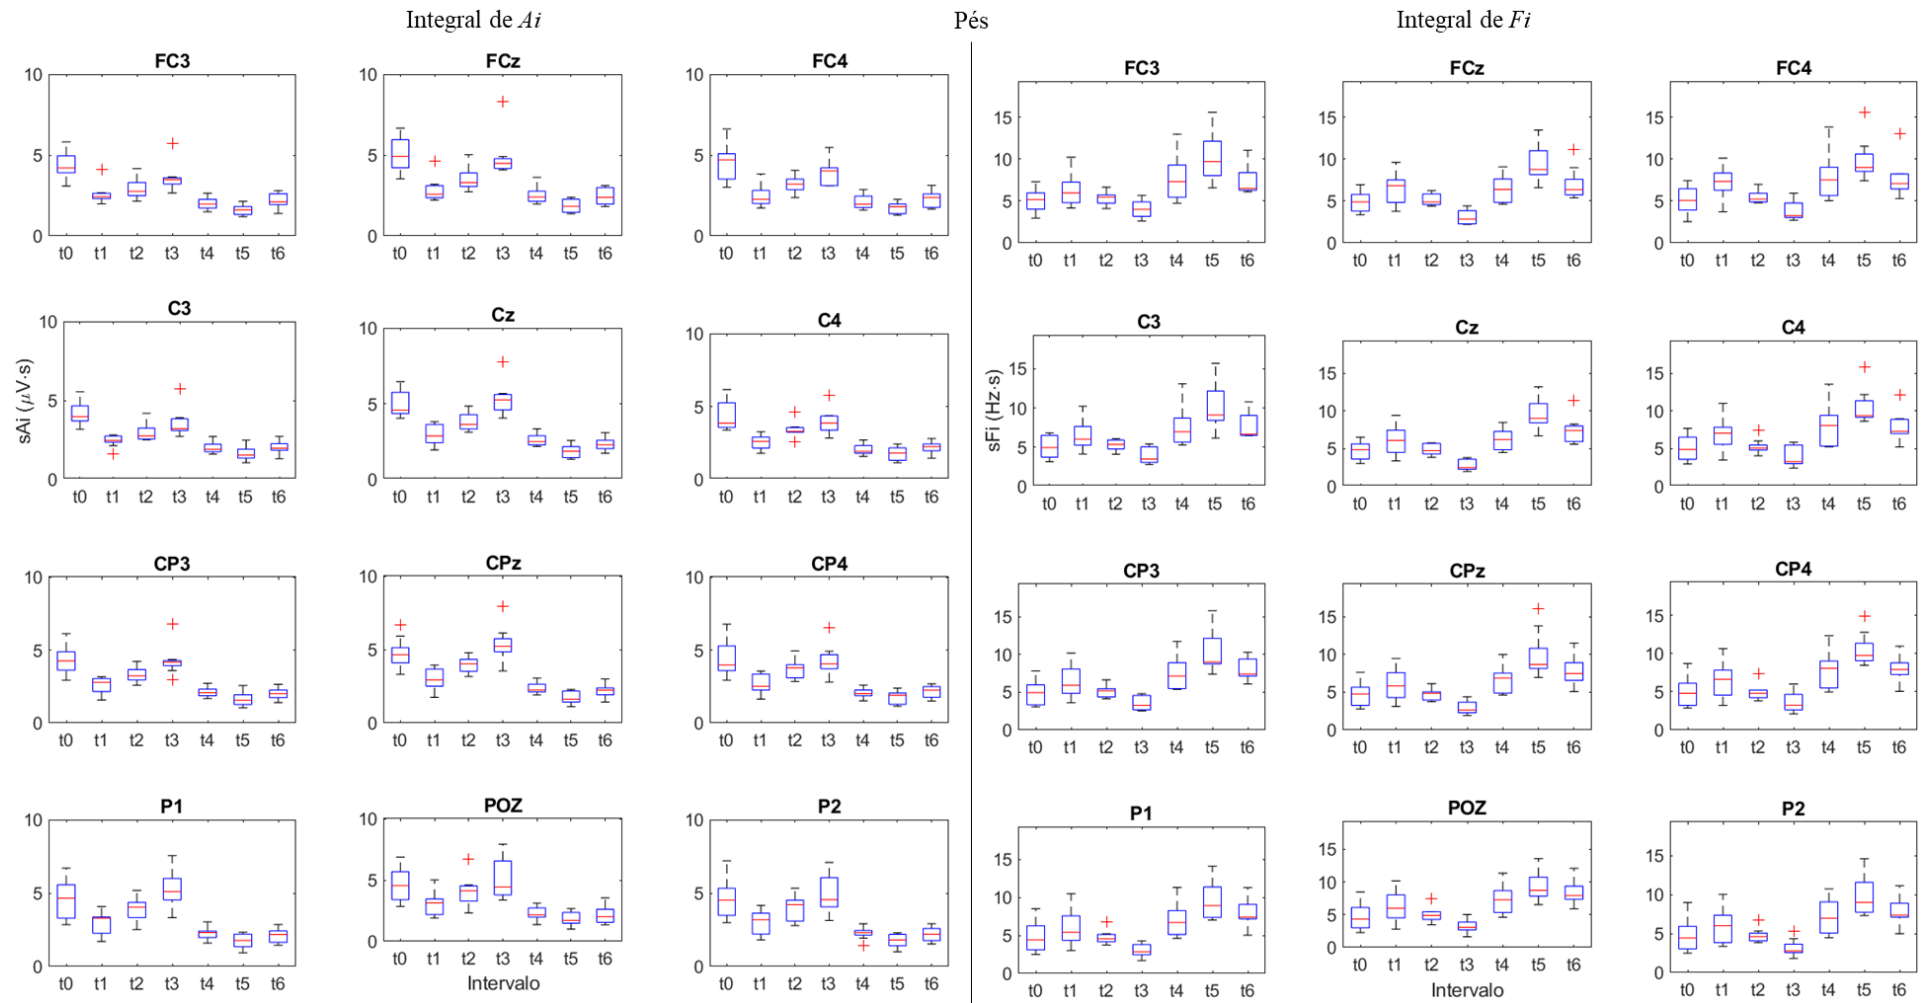


Figura 4.16 - *Boxplots* das integrais de  $A_i$  (esquerda) e  $F_i$  (direita) ao longo dos intervalos para IM dos pés.

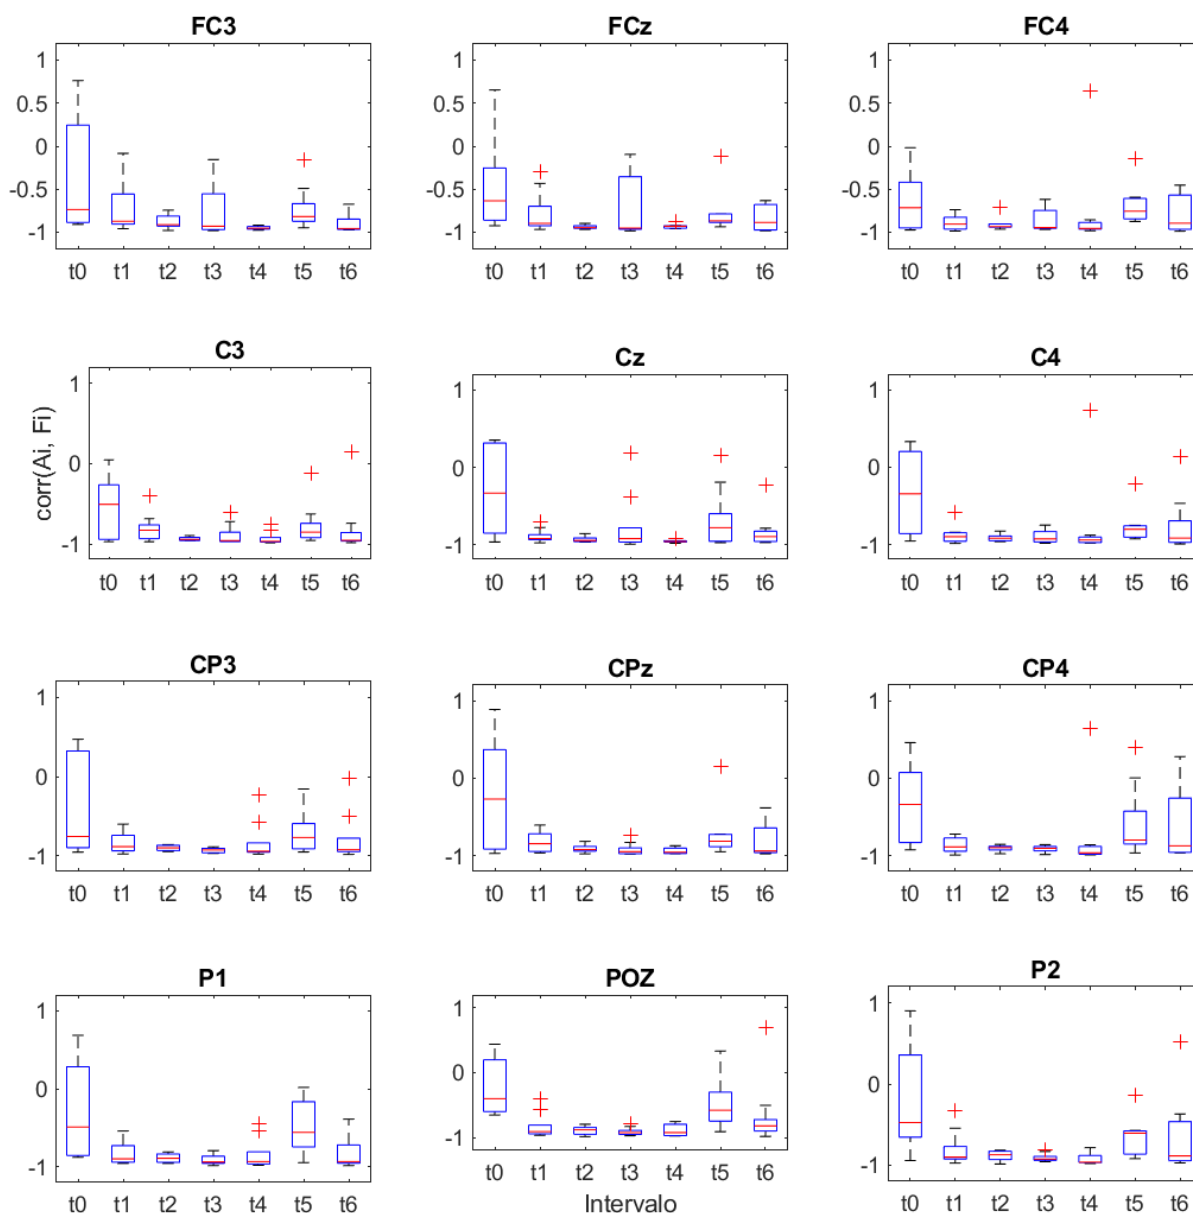


Figura 4.17 - *Boxplots* das correlações entre  $A_i$  e  $F_i$  nos intervalos para IM dos pés.

#### 4.3.2 Diferenças entre os intervalos – $sA_{ef}$ , $sF_{ce}$ e $\text{corr}(A_{ef}, F_{ce})$

Nesta seção são descritos os resultados da análise da diferença entre os intervalos para os PEDs obtidos da TFTC, assim como a correlação entre  $A_{ef}$  e  $F_{ce}$ . Ao realizar os testes de Friedman para as várias combinações de derivação de EEG e classe IM todas as comparações foram estatisticamente significativas, tanto para  $sA_{ef}$  quanto para  $sF_{ce}$ . Diferente da correlação entre  $A_i$  e  $F_i$ , a correlação entre  $A_{ef}$  e  $F_{ce}$  não apresentou nenhum caso não significativo.

A Tabela 4.16 contém os valores de W de Kendall de cada variável (integrais dos PEDs e correlação) para cada par de IM-derivação, além da mediana e o intervalo interquartil (IIQ) calculados ao longo das derivações para cada classe de IM. Assim como para as integrais dos PEDs obtidos a partir da TDH, os tamanhos de efeito para  $sA_{ef}$  e  $sF_{ce}$  também apresentam valores elevados (medianas entre 0,65 e 0,85) e com baixa variância (IIQs  $\leq 0,12$ ) para todas as imaginações de movimentos. Para a correlação, os tamanhos de efeito também apresentam baixa variabilidade (IIQs  $\leq 0,09$ ), porém com valores médios para as medianas (entre 0,45 e 0,57), indicando que há mais variabilidade ao longo do tempo para  $\text{corr}(A_{ef}, F_{ce})$  do que para  $\text{corr}(A_i, F_i)$ .

Na Figura 4.18, são apresentados os *boxplots* ao longo dos intervalos das integrais dos PEDs para IM dos pés. Observando a metade esquerda da Figura 4.18, o padrão de  $sA_{ef}$  é de um vale em torno de  $2,5 \mu V \cdot s$  em t1 (pré IM), um aumento até formar um platô de  $4,0 \mu V \cdot s$  em t2 e t3, um decréscimo até chegar em um vale de cerca de  $1,0 \mu V \cdot s$  em t5, voltando a aumentar em t6. Observando a metade direita da Figura 4.18, o padrão de  $sF_{ce}$  é oposto ao de  $sA_{ef}$ , com um pico em torno de  $6,0 Hz \cdot s$  em t1, que decresce até cerca de  $2,5 Hz \cdot s$  em t3, voltando a aumentar até um pico em torno de  $9,0 Hz \cdot s$  em t5, voltando a cair em t6.

Observando a Figura 4.19, que apresenta os *boxplots* das correlações entre  $A_{ef}$  e  $F_{ce}$ , nota-se que, para todas as derivações, com exceção dos fronto-centrais, a correlação é fortemente negativa e com baixa variabilidade nos intervalos t2, t4 e t5. Diferente da correlação entre  $A_i$  e  $F_i$ , a correlação entre  $A_{ef}$  e  $F_{ce}$  em t3 apresenta maior variabilidade, podendo até mesmo não haver correlação entre essas variáveis ( $\text{corr}(A_{ef}, F_{ce})=0$ ).

A Tabela 4.17 mostra lado a lado os valores aproximados para as medianas das integrais dos PEDs calculados a partir da TDH e da TFTC, indicando grande similaridade entre  $sA_i$  e  $sA_{ef}$  e também entre  $sF_i$  e  $sF_{ce}$ .

Tabela 4.16 - Tamanho de efeito, W de Kendall, da comparação entre intervalos para  $sA_{ef}$ ,  $sF_{ce}$  e  $\text{corr}(A_{ef}, F_{ce})$ . Valores em cinza indicam valor  $p < 0,05$ . A mediana e o intervalo interquartil foram calculados para cada classe de IM.

W de Kendall - Entre intervalos - sAef																								
Classe	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ	Mediana	IIQ
ME	0,77	0,77	0,79	0,82	0,84	0,80	0,82	0,85	0,91	0,85	0,84	0,83	0,81	0,87	0,90	0,87	0,88	0,83	0,83	0,82	0,81	0,82	0,83	0,04
MD	0,69	0,75	0,79	0,80	0,79	0,76	0,76	0,80	0,81	0,83	0,81	0,82	0,85	0,80	0,80	0,81	0,85	0,87	0,81	0,84	0,84	0,88	0,81	0,05
Pés	0,63	0,86	0,85	0,82	0,82	0,77	0,82	0,85	0,85	0,89	0,87	0,84	0,82	0,86	0,87	0,87	0,87	0,83	0,85	0,86	0,86	0,84	0,85	0,04
Língua	0,79	0,77	0,81	0,85	0,80	0,77	0,76	0,77	0,76	0,78	0,66	0,61	0,64	0,82	0,76	0,66	0,65	0,66	0,82	0,76	0,72	0,81	0,76	0,12
W de Kendall - Entre intervalos - sFce																								
Classe	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ	Mediana	IIQ
ME	0,65	0,58	0,64	0,66	0,64	0,57	0,64	0,68	0,72	0,69	0,62	0,64	0,63	0,70	0,77	0,70	0,68	0,61	0,83	0,76	0,74	0,82	0,67	0,08
MD	0,53	0,59	0,58	0,57	0,61	0,64	0,71	0,69	0,66	0,65	0,63	0,68	0,70	0,71	0,73	0,67	0,65	0,72	0,76	0,76	0,76	0,79	0,68	0,09
Pés	0,53	0,74	0,68	0,68	0,66	0,66	0,72	0,77	0,72	0,75	0,76	0,78	0,66	0,81	0,78	0,79	0,81	0,85	0,84	0,85	0,82	0,87	0,77	0,11
Língua	0,56	0,60	0,62	0,63	0,62	0,65	0,55	0,62	0,64	0,65	0,65	0,67	0,65	0,73	0,72	0,73	0,67	0,73	0,74	0,77	0,80	0,81	0,65	0,11
W de Kendall - Entre intervalos - corr(Aef, Fce)																								
Classe	Fz	FC3	FC1	FCz	FC2	FC4	C5	C3	C1	Cz	C2	C4	C6	CP3	CP1	CPz	CP2	CP4	P1	Pz	P2	POZ	Mediana	IIQ
ME	0,37	0,47	0,46	0,48	0,52	0,35	0,40	0,48	0,48	0,52	0,35	0,36	0,40	0,46	0,52	0,50	0,50	0,41	0,53	0,49	0,47	0,45	0,47	0,09
MD	0,48	0,38	0,41	0,42	0,33	0,27	0,48	0,56	0,54	0,48	0,50	0,44	0,48	0,45	0,57	0,53	0,43	0,51	0,53	0,56	0,51	0,47	0,48	0,09
Pés	0,57	0,51	0,61	0,64	0,56	0,44	0,51	0,55	0,52	0,58	0,59	0,47	0,52	0,50	0,59	0,57	0,59	0,46	0,59	0,61	0,58	0,60	0,57	0,08
Língua	0,46	0,40	0,40	0,36	0,40	0,52	0,43	0,50	0,44	0,40	0,39	0,51	0,42	0,63	0,48	0,46	0,45	0,45	0,54	0,53	0,43	0,42	0,45	0,09

Tabela 4.17 - Valores aproximados por inspeção visual das medianas dos PEDs em t1, t3 e t5.

Intervalo	$sA_i (\mu V \cdot s \cdot V)$	$sA_{ef} (\mu V \cdot s)$	$sF_i (Hz \cdot s)$	$sF_{ce} (Hz \cdot s)$
t1	2,5	2,5	6,0	6,0
t3	5,0	4,0	3,0	2,5
t5	1,0	1,0	9,0	9,0

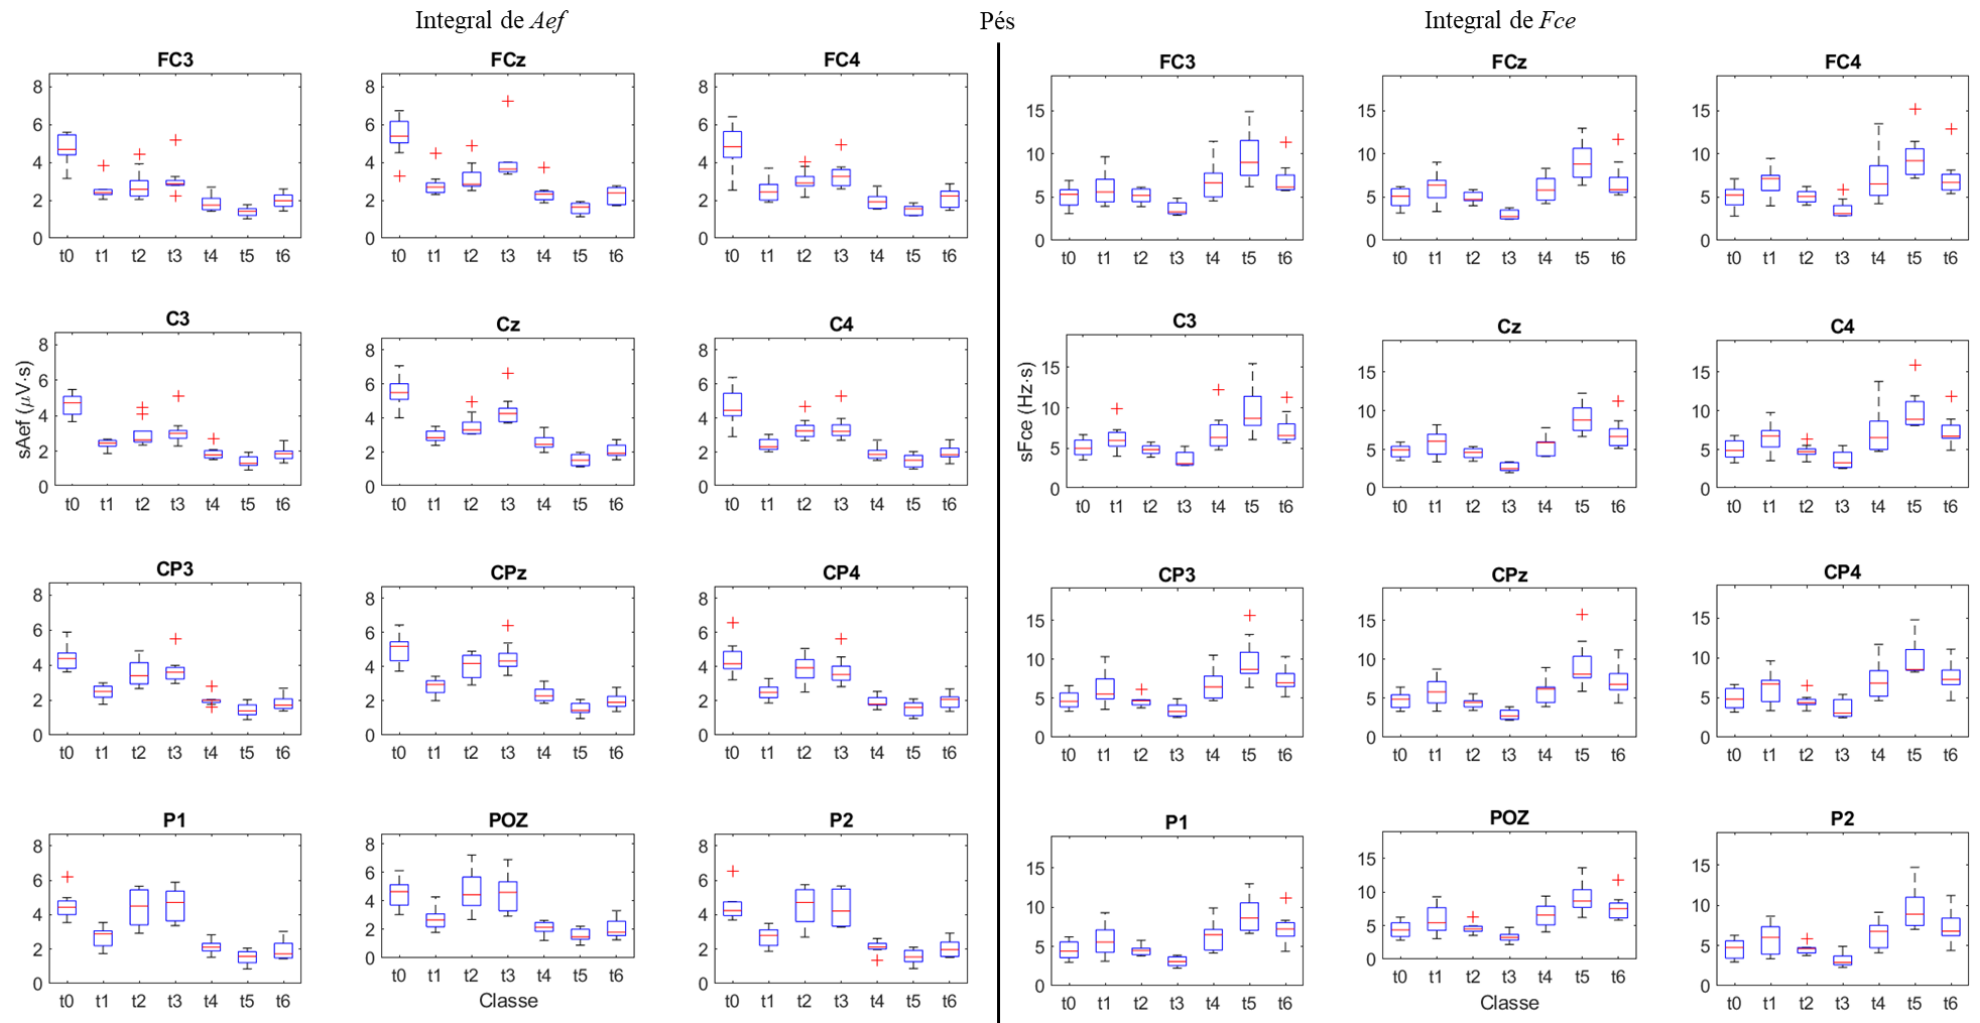


Figura 4.18 - *Boxplots* das integrais de  $A_{ef}$  (esquerda) e  $F_{ce}$  (direita) ao longo dos intervalos para IM dos pés.

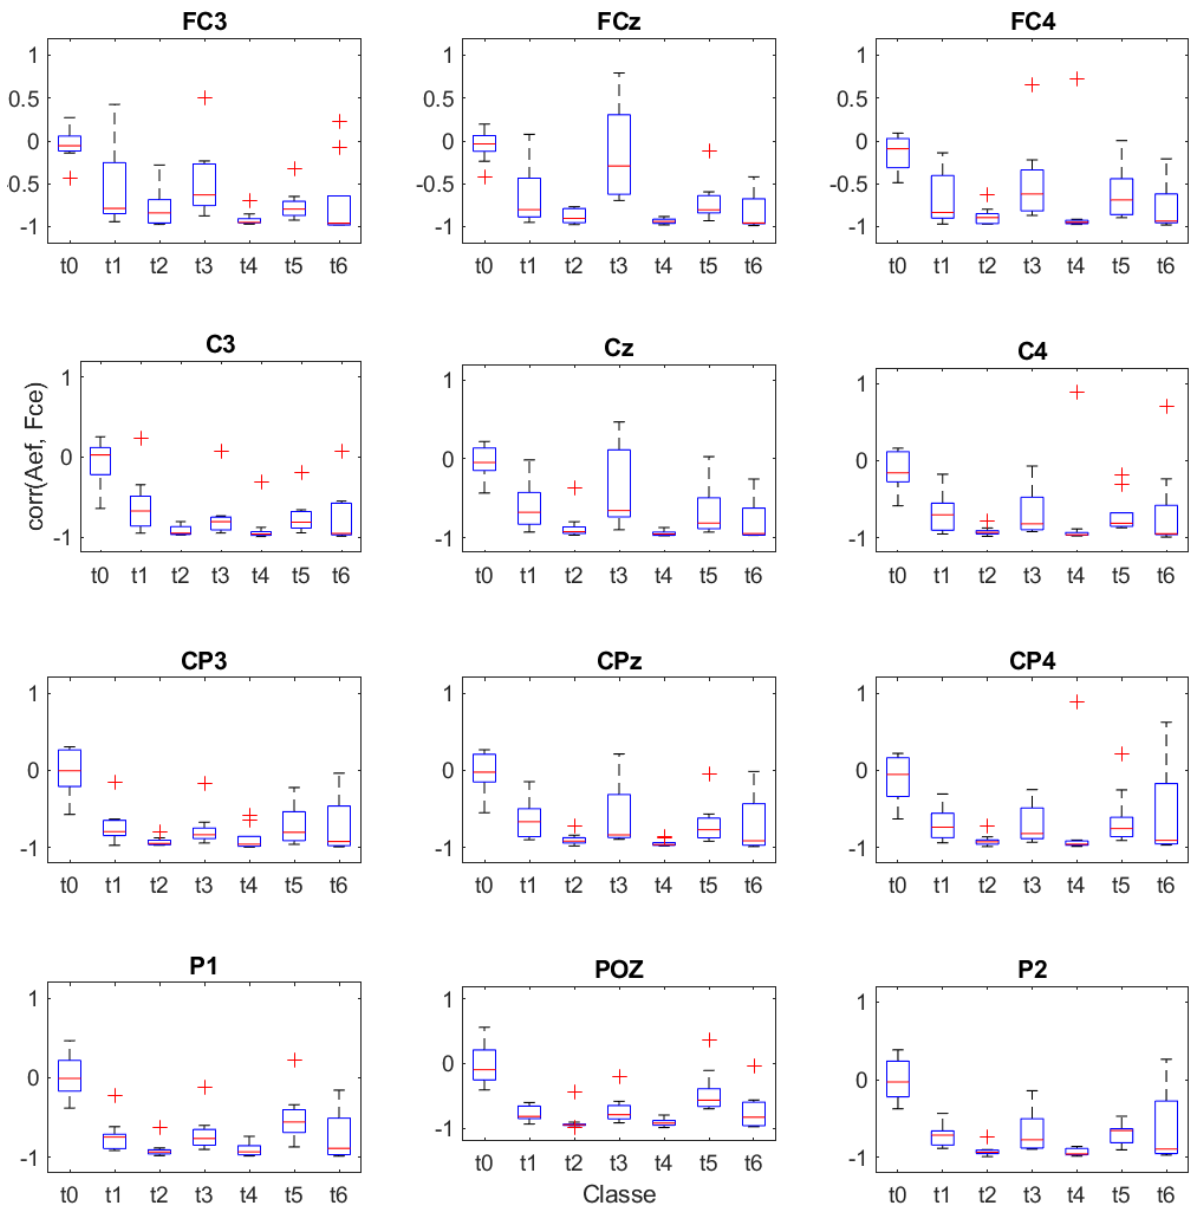


Figura 4.19 - Boxplots das correlações entre *Aef* e *Fce* nos intervalos para IM dos pés.

## Capítulo 5: Discussão

### 5.1 Comparação de traçados dos PEDs

Em linhas gerais, pela inspeção visual dos traçados dos PEDs (Figura 4.4 a Figura 4.7), foi possível identificar intervalos de Dessincronização Relacionada a Evento (DRE) e Sincronização Relacionada a Evento (SRE). Nos traçados, em t3 foi observado um aumento dos PEDs relacionados a amplitude e diminuição dos PEDs relacionados a frequência. Notou-se também uma diminuição dos parâmetros de amplitude e aumento dos parâmetros de frequência no intervalo de imaginação do movimento (4,0 s – 6,0 s), o que é indicativo de presença de DRE. Ainda, é possível ver o contrário ocorrendo ao final da IM (após 6,0 s), com os parâmetros de amplitude se elevando e os parâmetros de frequência diminuindo, o que é um indicativo de SRE. Tais resultados estão de acordo com os reportados por Pfurtscheller; Lopes Da Silva (1999), Jeon et al. (2011), Shahlaei et al. (2019) e Batistić; Lerga; Stanković (2023), com especial atenção para o trabalho de Shahlaei et al. (2019), em que também foi utilizada análise com base na TDH para identificar a DRE. É interessante notar que no artigo de Jeon et al. (2011) a DRE já aparece antes da sinalização de início da IM, possivelmente devido à preparação para realização desta em função da diferença no protocolo experimental, que exige que os participantes imaginem o movimento do dedo de forma rítmica, produzindo uma preparação para o movimento cíclica.

Por último, a similaridade entre os PEDs obtidos da TDH e da TFTC também foi encontrada por Knösche e Bastiaansen (2002), que aplicaram estas técnicas para análise da DRE com base no procedimento definido por Pfurtscheller e Lopes da Silva (1999).

### 5.2 Interpretação dos testes estatísticos: PEDs da TDH versus PEDs da TFTC

Na comparação entre as classes de IM foram encontrados tamanho de efeito médios (média do W de Kendall entre 0,33 a 0,50) para as métricas  $sA_i$ ,  $sF_i$ ,  $sA_{ef}$ , e  $sF_{ce}$  nos intervalos t3 e t4 na maioria das derivações. Foi possível diferenciar a IM dos pés da MD e da língua, sendo os PEDs de amplitude para IM dos pés superior. Nos PEDs de frequência, os valores foram inferiores para IM dos pés em relação a MD e língua. Retomando a Tabela 4.13 e a Tabela 4.14, a comparação MD vs. língua foi a que apresentou diferenças estatisticamente significativas (DES) para menor número de derivações (FC4 e C5 para  $sA_i$  em t4). Quanto às três comparações restantes, ME vs. MD, ME vs. pés e ME vs. língua, as principais identificações de DES foram para  $sA_{ef}$  em t3 nas derivações centro-parietais para ME vs. pés e nas derivações

fronto-centrais para ME vs. língua; e para  $sA_{ef}$  e  $sF_{ce}$  em t4 envolvendo 8 de 22 derivações espalhadas por todas as regiões do escalpo.

Em t3, houve mais DES usando os PEDs de frequência para as comparações pés vs. MD e pés vs. Língua. Porém, em t4, as DES predominaram nos PEDs de amplitude entre pés e MD, enquanto os PEDs de frequência identificaram mais DES entre pés e língua. Esta constatação indica a necessidade de emprego de PEDs de frequência e de amplitude, ao invés de se utilizar somente um dos dois.

Além das integrais dos PEDs, também foram investigadas as correlações  $corr(A_i, F_i)$  e  $corr(A_{ef}, F_{ce})$ . Observando os *boxplots* de  $corr(A_i, F_i)$  ao longo do tempo (Figura 4.17) percebe-se que os valores de correlações são negativos e com baixa variabilidade nos intervalos t1 a t5 (incluindo tanto o período de imaginação de movimento, quanto o intervalo que a precede), se aproximam de zero em t0 e apresentam maior variância em t6. Observações similares podem ser feitas para os *boxplots* de  $corr(A_{ef}, F_{ce})$  (Figura 4.19), havendo, porém, há um aumento da variância no intervalo t3 para a maioria das derivações analisadas.

Assim, de um modo geral, pôde-se concluir que as técnicas tempo-frequência, TDH e TFTC, apresentaram resultados próximos para a diferenciação entre as IMs.

### 5.3 Comparação com a literatura

No presente trabalho, optou-se por analisar a evolução temporal das PEDs ao longo dos diferentes intervalos do protocolo de IM, ao invés de focar diretamente na classificação das IMs, como a maioria dos trabalhos da literatura. Portanto, não é possível realizar uma comparação direta dos resultados, uma vez que estes artigos focam na comparação entre acurácias de classificação. Ainda assim, a Tabela 5.1 apresenta uma compilação com as principais características de trabalhos de desenvolvimento de Interface Cérebro-Máquina, nos últimos 10 anos, com protocolos experimentais similares aos do presente trabalho. Os valores apresentados correspondem à maior acurácia média relatada em cada artigo, no caso de exploração e comparação de múltiplas técnicas.

Dos trabalhos citados na Tabela 5.1, Shahlaei et al. (2019), Sadiq et al. (2019) e Batistić; Lerga; Stanković, (2023) utilizaram técnicas tempo-frequência. Shahlaei et al. 2019 usaram a amplitude instantânea da TDH para cálculo de DRE e SRE, seguida por classificação com SVM. Já Sadiq et al. (2019) usaram um método baseado principalmente na transformada *wavelet* multivariada empírica, sendo que o método proposto por eles aplica a TDH nas subbandas de

*wavelet*, o que resulta em sinais chamados de amplitude instantânea conjunta e frequência instantânea conjunta. Os autores também testaram diversas métricas derivadas destes parâmetros para detectar a IM, assim como realizaram seleção de características. A melhor das combinações foi obtida com um classificador SVM de mínimos quadrados, empatado com o classificador *multilayer perceptron*, usando seleção automática de derivações de EEG, que selecionou derivações da área central e centroparietal principalmente. Por último, Batistić; Lerga; Stanković (2023) exploraram quatro representações tempo-frequência (espectrograma, Gabor, pseudo Wigner-Ville e pseudo Wigner-Ville suavizada) aplicadas ao sinal pré-processado via análise de componentes independentes e filtrados na banda de 0,2 – 5 Hz. A melhor combinação de técnicas foi o uso da representação de Gabor com métrica de entropia calculada a partir da representação tempo-frequência, usando o classificador análise de discriminante linear regularizada. Apesar da aparente baixa acurácia obtida neste trabalho, é importante ressaltar que as classes a serem diferenciadas foram de movimentos (flexão e extensão de cotovelo) que recrutam grupos musculares de uma mesma parte do corpo (braço e antebraço), o que eleva substancialmente a dificuldade de classificação. Além disto, ao fazerem a classificação de IM vs. repouso, os autores atingiram acurácias de até 95 %.

Além da técnica de extração de características, outro ponto de discussão relevante é quanto à escolha dos classificadores. Por exemplo, o trabalho de Steyrl et al. (2014), encontrou diferença significativa a favor do uso de floresta aleatória (*random forest*) quando comparada à análise discriminante linear regularizada, tendo usado como característica a potência em bandas do sinal filtrado com filtros CSP. Já no trabalho de Sadiq et al. (2019), foram testados vários classificadores lineares (regressão logística, árvore de modelos logísticos) e não-lineares (*multilayer perceptron*, *naïve Bayes*, SVM por mínimos quadrados), com melhor desempenho (97% de acurácia) obtido usando tanto SVM e *multilayer perceptron*, não lineares, quanto árvore de modelos logísticos, linear, todos usando características extraídas de 3 derivações de EEG.

Tabela 5.1 – Trabalhos de desenvolvimento de ICM nos últimos 10 Anos

Estudo	Base de Dados	Nº Participantes	Classes de IM	Derivações de EEG Utilizadas	Acurácia (%) (M +/- DP)
Steryl et al. 2014	Própria	10	MD, pés	C3, Cz, C4, derivações laplacianas	79,3 ± 12,6
Ge et al. 2014	CICMB III conjunto de dados 3A	3	ME, MD, pés, língua	C4	76,9 ± 9,7
Shahlaei et al. 2018 <sup>1</sup>	CICMB II conjunto de dados 3	1	ME, MD	C3, Cz, C4, derivações bipolares	92,4
Shahlaei et al. 2019	CICMB IV conjunto de dados 2B	9	ME, MD	C3, Cz, C4, derivações bipolares	82,2 ± 8,5
Sadiq et al. 2019 <sup>2</sup>	CICMB III conjunto de dados 4A	5	MD, pé direito	F1, F2, F3, F4	97,0 ± 2,7
Sharma et al. 2023 <sup>3</sup>	CICMB IV conjunto de dados 2A	9	ME, MD, pés, língua	22 derivações, um subconjunto do sistema 10-10	83,2 ± 5,9
Batistic et al. 2023 <sup>4</sup>	Base de dados de Ofner et al. (2017)	15	Flexão e extensão de cotovelo	31 derivações de acordo com o sistema 10-10	53,7

<sup>1</sup> Não há desvio-padrão pois há dados de apenas um indivíduo.

<sup>2</sup> O estudo também trabalhou com os conjuntos de dados 4B e 4C, mas escolhi reportar apenas o 4A por ser mais parecido com o usado nesta dissertação. Ainda, para cada indivíduo foi usado um subconjunto diferente de derivações das listadas, sendo que a seleção de derivações partiu de um total de 118 derivações disponíveis inicialmente.

<sup>3</sup> Também trabalharam com o conjunto de dados 4A da CICMB III (resultados não mostrados).

<sup>4</sup> O estudo contém um outro conjunto de dados, mas com paradigma experimental bem diferente do utilizado na dissertação. Ainda, ao classificar entre IM versus EEG em repouso, os autores atingiram acurácias médias de 94,8 % (extensão de cotovelo versus repouso) e 95,3 % (flexão de cotovelo versus repouso). Por último, não foi possível encontrar ou calcular o desvio-padrão a partir do artigo original.

#### 5.4 Aplicações e desempenho de ICMs baseadas em IM

Apesar do presente trabalho se concentrar no fenômeno de IM, é importante ter em mente a existência de diferentes PREs, pois o uso de uma combinação deles pode permitir o desenvolvimento de ICMs mais robustas e flexíveis. Por exemplo, no trabalho de Duan et al. (2019), os autores combinaram o potencial evocado visual em regime permanente (PEVRP) para controlar a altitude de um quadricóptero e a IM usada para definir entre as direções direita ou esquerda, sendo o piscar de olhos o comando para trocar entre a detecção de IM ou do PEVRP. Apesar de apenas 5 dos 9 voluntários terem tido desempenho suficiente na calibração da ICM para seguir para a etapa de controle do quadricóptero, este estudo ilustra bem o problema da ineficiência na ICM. É possível perceber como este problema não é simples, uma vez que uma pessoa pode ter bons resultados em uma modalidade de PRE, mas não em outra, como o voluntário 2 que teve acurácia de 62 % com o PEVRP visual e 75 % com a IM, ou o voluntário 3 que teve acurácia de 99 % com o PEVRP, mas apenas 52 % com a IM.

Outro aspecto a se considerar em estudos de IM é a finalidade do uso. As aplicações mais comuns são o desenvolvimento de tecnologias assistivas, como as ICMs, e a reabilitação motora. Entretanto, é possível que um melhor desempenho com ICMs não esteja correlacionado com melhora de aspectos neurofisiológicos ligados à reabilitação, como mostra o trabalho de Vasilyev et al., 2017. Neste trabalho, os autores recrutaram 19 participantes saudáveis e mediram o aumento da excitabilidade córtico-espinal (usado como indicador de melhora em reabilitação), a magnitude da DRE $\alpha$  no escalpo todo e a acurácia no uso da ICM baseada em IM. Além disso, colheram entrevistas por escrito dos voluntários e aplicaram dois questionários para avaliar a qualidade da IM: o Questionário de Imagética Cinestésica e Visual (KVIQ-20, MALOUIN et al., 2007) e o Questionário de Vivacidade da Imagética Motora (VMIQ-2, ROBERTS et al., 2008). Os resultados mostraram que os efeitos neurofisiológicos associados à reabilitação (aumento da excitabilidade córtico-espinal) não se relacionam com os efeitos neurofisiológicos associados à melhora na proficiência com a ICM (magnitude da DRE). Apesar deste achado, cabe a ressalva de que uma avaliação funcional seria mais apropriada para analisar o sucesso do processo de reabilitação do que apenas o aumento da excitabilidade córtico-espinal.

Por último, o trabalho de Rimbart e Fleck (2023), elucida questões sobre o efeito da prática de longo prazo com ICM baseada em IM sobre a fadiga, a motivação para o uso do dispositivo, as características dos PREs e o desempenho da ICM. O estudo acompanhou

1 voluntário durante 214 dias (com pausas) tendo sido realizadas 26 sessões de IM no período. Verificou-se que a amplitude da DRE aumenta com o passar do tempo, e que a DRE fica mais espacialmente concentrada. Também se verificou que há uma correlação positiva entre a amplitude da DRE e o desempenho na ICM, assim como visto em Vasilyev et al. (2017). Porém não há correlação entre a amplitude da SRE e o desempenho na ICM. Apesar da realização da IM com foco em aspectos cinestésicos aumentar a fadiga durante a sessão de coleta, essa fadiga não se acumulou com o passar do tempo e, ainda, a melhora no desempenho com a ICM com o passar do tempo aumentou a motivação do voluntário para as sessões subsequentes.

## Capítulo 6: Conclusão, Limitações e Sugestões de Trabalhos Futuros

A presente pesquisa teve por objetivo investigar as propriedades dos parâmetros espectrais dinâmicos obtidos a partir da TDH e da TFTC em registros de EEG durante IM, visando ao desenvolvimento de ICMs. Em relação à evolução temporal dos PEDs  $A_i$ ,  $F_i$ ,  $A_{ef}$ ,  $F_{ce}$ , os parâmetros de amplitude apresentaram aumento em t3 (1,0 s após indicação de início da IM) e os parâmetros de frequência apresentaram diminuição do valor e da variabilidade neste período. Quanto à identificação de diferenças estatisticamente significativas entre as IMs, os períodos t3 e t4 foram os que apresentaram diferenças em mais derivações (de acordo com os testes de Friedman) para praticamente todos os PEDs, tendo sido mais evidente as diferenças entre a IM dos pés quando comparada as IMs da língua ou da mão direita. Entretanto, essa diferenciação não apresentou distribuição topográfica restrita às derivações fronto-centrais, centrais e centro-parietais, apresentando-se de forma difusa por todo o escalpo. Sobre a correlação entre os PEDs obtidos a partir da TDH, foram observados valores negativos com baixa variabilidade nos intervalos t2 a t5, durante a IM, assim como no intervalo t1, que precede a IM. O mesmo foi observado para a correlação entre os PEDs obtidos pela TFTC, porém com aumento da variância e valores menos negativos em t3.

### 6.1 Limitações do presente trabalho

Dentre as limitações do presente trabalho, pode-se citar:

- Base de dados relativamente pequena (9 voluntários);
- Ausência de uma classe neutra (execução de uma atividade mental distinta de IM ou repouso) como referência;
- Discussão restrita a trabalhos que utilizaram protocolos similares e/ou a mesma base de dados;

### 6.2 Trabalhos futuros

Com base nas limitações identificadas, sugere-se como continuidade:

- a validação da metodologia baseada na evolução temporal de PEDs com bases de dados maiores e que incluam, possivelmente, uma classe neutra; alternativamente ou adicionalmente, pode-se planejar a coleta de uma nova base de sinais;
- a análise do comportamento dos PEDs para a média coerente com menor número de épocas

até atingir a situação de *single-trial*;

- o emprego dos PEDs como parâmetros a serem avaliados com diferentes classificadores como os encontrados na literatura (e.g.: SVM, análise discriminante de Fisher, regressão logística etc.);
- a comparação do comportamento dos PEDs durante IM e durante execução do movimento.

## Referências

ALONSO-VALERDI, L. M.; SALIDO-RUIZ, R. A.; RAMIREZ-MENDOZA, R. A. Motor imagery based brain-computer interfaces: An emerging technology to rehabilitate motor deficits. *Neuropsychologia*, v. 79, p. 354–363, 1 dez. 2015. Acesso em: 11 fev. 2021.

ANG, K. K.; CHIN, Z. Y.; WANG, C.; GUAN, C.; ZHANG, H. Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b. *Frontiers in Neuroscience*, v. 6, n. MAR, p. 39, 29 mar. 2012. Disponível em: <<http://journal.frontiersin.org/article/10.3389/fnins.2012.00039/abstract>>. Acesso em: 28 jan. 2021.

BAGH, N.; REDDY, M. R. Hilbert transform-based event-related patterns for motor imagery brain computer interface. *Biomedical Signal Processing and Control*, v. 62, p. 102020, 1 set. 2020. Acesso em: 28 jan. 2021.

BATISTIĆ, L.; LERGA, J.; STANKOVIĆ, I. Detection of motor imagery based on short-term entropy of time–frequency representations. *BioMedical Engineering Online*, v. 22, n. 1, p. 1–23, 1 dez. 2023. Disponível em: <<https://biomedical-engineering-online.biomedcentral.com/articles/10.1186/s12938-023-01102-1>>. Acesso em: 10 jan. 2024.

BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. *Neurociências: desvendando o sistema nervoso*. 3. ed. Porto Alegre: ARTMED EDITORA S.A., 2008.

BEDROSIAN, E. A product theorem for Hilbert transforms. *Proceedings of the IEEE*, v. 51, n. 5, p. 868–869, 1963. Disponível em: <[https://ieeexplore.ieee.org/abstract/document/1444238/?casa\\_token=daFTfwpC9AEAAAAA:zmCzoqxwYi59O1wJHV21eCEpsXwtXUCdmGci-Ltj6GosBFH5HK8FRzaFxAf5C6cC4Heui5n\\_PkQ](https://ieeexplore.ieee.org/abstract/document/1444238/?casa_token=daFTfwpC9AEAAAAA:zmCzoqxwYi59O1wJHV21eCEpsXwtXUCdmGci-Ltj6GosBFH5HK8FRzaFxAf5C6cC4Heui5n_PkQ)>. Acesso em: 21 maio 2025.

BENDAT, J. S.; PIERSOL, A. G. *Random Data: Analysis and Measurement Procedures*. Hoboken: John Wiley & Sons, 2011.

BIRBAUMER, N.; ELBERT, T.; CANAVAN, A. G. M.; ROCKSTROH, B. *Slow potentials of the cerebral cortex and behavior*. *Physiological Reviews*. [S.l: s.n.]. Disponível em: <<https://journals.physiology.org/doi/abs/10.1152/physrev.1990.70.1.1>>. Acesso em: 11 fev. 2021. , 1990

BLANKERTZ, B.; MÜLLER, K. R.; KRUSIENSKI, D. J.; SCHALK, G.; WOLPAW,

J. R.; SCHLÖGL, A.; PFURTSCHELLER, G.; MILLÁN, J. D. R.; SCHRÖDER, M.; BIRBAUMER, N. The BCI competition III: Validating alternative approaches to actual BCI problems. jun. 2006, [S.l.]: IEEE Trans Neural Syst Rehabil Eng, jun. 2006. p. 153–159. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/16792282/>>. Acesso em: 28 jan. 2021.

BRUNNER, C.; BIRBAUMER, N.; BLANKERTZ, B.; GUGER, C.; KÜBLER, A.; MATTIA, D.; MILLÁN, J. DEL R.; MIRALLES, F.; NIJHOLT, A.; OPISSO, E.; RAMSEY, N.; SALOMON, P.; MÜLLER-PUTZ, G. R. BNCI Horizon 2020: towards a roadmap for the BCI community. <http://dx.doi.org/10.1080/2326263X.2015.1008956>, v. 2, n. 1, p. 1–10, 2 jan. 2015. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/2326263X.2015.1008956>>. Acesso em: 28 dez. 2021.

BRUNS, A. Fourier-, Hilbert- and wavelet-based signal analysis: Are they really different approaches? *Journal of Neuroscience Methods*, v. 137, n. 2, p. 321–332, 30 ago. 2004. Acesso em: 12 jan. 2022.

DUAN, X.; XIE, S.; XIE, X.; MENG, Y.; XU, Z. Quadcopter Flight Control Using a Non-invasive Multi-Modal Brain Computer Interface. *Frontiers in Neurorobotics*, v. 13, p. 23, 31 maio 2019. Disponível em: <<https://www.frontiersin.org/article/10.3389/fnbot.2019.00023/full>>. Acesso em: 27 jan. 2021.

GABOR, D. Theory of communication. Part 1: The analysis of information. *Journal of the Institution of Electrical Engineers*, p. 429–441, 1946. Disponível em: <<http://www.granularsynthesis.com/pdf/gabor.pdf>>.

GE, S.; WANG, R.; YU, D. Classification of four-class motor imagery employing single-channel electroencephalography. *PLoS ONE*, v. 9, n. 6, p. 1–7, 2014.

GHAEMI, A.; RASHEDI, E.; POURRAHIMI, A. M.; KAMANDAR, M.; RAHDARI, F. Automatic channel selection in EEG signals for classification of left or right hand movement in Brain Computer Interfaces using improved binary gravitation search algorithm. *Biomedical Signal Processing and Control*, v. 33, p. 109–118, 1 mar. 2017. Acesso em: 11 fev. 2021.

GRAY H, C.; GRAY, H.; CLEMENTE, CD. *Anatomy of the Human Body*. [S.l.: s.n.], 1985.

HALL, J. E. *Tratado de Fisiologia Médica*. 12a. ed. Rio de Janeiro: [s.n.], 2011.

HANAKAWA, T. Organizing motor imageries. *Neuroscience Research*, v. 104, p. 56–63, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.neures.2015.11.003>>.

HARRIS, F. J. On the Use of Windows for Harmonic Analysis with the Discrete Fourier Transform. *Proceedings of the IEEE*, v. 66, n. 1, p. 51–83, 1978. Acesso em: 21 maio 2025.

HEINZEL, G.; RÜDIGER, A.; SCHILLING, R. Spectrum and spectral density estimation by the Discrete Fourier transform (DFT), including a comprehensive list of window functions and some new at-top windows. 2002. Acesso em: 17 jan. 2022.

HONG, J.; QIN, X.; LI, J.; NIU, J.; WANG, W. Signal processing algorithms for motor imagery brain-computer interface: State of the art. *Journal of Intelligent and Fuzzy Systems*, v. 35, n. 6, p. 6405–6419, 1 jan. 2018. Acesso em: 28 jan. 2021.

HORTAL, E.; PLANELLES, D.; COSTA, A.; IÁÑEZ, E.; ÚBEDA, A.; AZORÍN, J. M.; FERNÁNDEZ, E. SVM-based Brain-Machine Interface for controlling a robot arm through four mental tasks. *Neurocomputing*, v. 151, n. P1, p. 116–121, 3 mar. 2015. Acesso em: 11 fev. 2021.

HUANG, N. E.; SHEN, Z.; LONG, S. R.; WU, M. C.; SNIN, H. H.; ZHENG, Q.; YEN, N. C.; TUNG, C. C.; LIU, H. H. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, v. 454, n. 1971, p. 903–995, 1998. Disponível em: <[https://www.researchgate.net/publication/215754718\\_The\\_empirical\\_mode\\_decomposition\\_and\\_the\\_Hilbert\\_spectrum\\_for\\_nonlinear\\_and\\_non-stationary\\_time\\_series\\_analysis](https://www.researchgate.net/publication/215754718_The_empirical_mode_decomposition_and_the_Hilbert_spectrum_for_nonlinear_and_non-stationary_time_series_analysis)>. Acesso em: 21 maio 2025.

HUANG, N. E.; WU, Z.; LONG, S. R.; ARNOLD, K. C.; CHEN, X.; BLANK, K. ON INSTANTANEOUS FREQUENCY. <https://doi.org/10.1142/S1793536909000096>, v. 1, n. 2, p. 177–229, 20 nov. 2011. Acesso em: 12 jan. 2022.

JEANNEROD, M. The representing brain: Neural correlates of motor intention and imagery. *Behavioral and Brain Sciences*, v. 17, n. 2, p. 187–202, 1994. Disponível em: <<https://www.cambridge.org/core/journals/behavioral-and-brain-sciences/article/abs/representing-brain-neural-correlates-of-motor-intention-and-imagery/DBF7AB09145C9F02793378601B9A7155>>. Acesso em: 11 fev. 2021.

JEON, Y.; NAM, C. S.; KIM, Y.-J.; WHANG, M. C. Event-related (De)synchronization (ERD/ERS) during motor imagery tasks: Implications for brain-computer interfaces. *International Journal of Industrial Ergonomics*, v. 41, n. 5, p. 428–436, set. 2011. Disponível

em:

<[https://www.engineeringvillage.com/share/document.url?mid=cpx\\_6e3d60131f7d19c64M77122061377553&database=cpx](https://www.engineeringvillage.com/share/document.url?mid=cpx_6e3d60131f7d19c64M77122061377553&database=cpx)>.

KAYA, M.; BINLI, M. K.; OZBAY, E.; YANAR, H.; MISHCHENKO, Y. Data descriptor: A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces. *Scientific Data*, v. 5, 2018. Acesso em: 1 jun. 2021.

KIM, K. T.; CARLSON, T.; LEE, S. W. Design of a robotic wheelchair with a motor imagery based brain-computer interface. *2013 International Winter Workshop on Brain-Computer Interface, BCI 2013*, p. 46–48, 2013.

KNÖSCHE, T. R.; BASTIAANSEN, M. C. M. On the time resolution of event-related desynchronization: A simulation study. *Clinical Neurophysiology*, v. 113, n. 5, p. 754–763, 1 maio 2002. Acesso em: 11 fev. 2021.

KRISHNA, D. H.; PASHA, I. A.; SAVITHRI, T. S. Classification of EEG Motor Imagery Multi Class Signals Based on Cross Correlation. 1 jan. 2016, [S.l.]: Elsevier B.V., 1 jan. 2016. p. 490–495. . Acesso em: 11 fev. 2021.

LATHI, B. P. *Sinais e Sistemas Lineares*. 2ª ed. Porto Alegre: Bookman, 2007.

MALLAT, S. A wavelet tour of signal processing. 1999. Disponível em: <<https://books.google.com.br/books?hl=pt-BR&lr=&id=hbVofWQNtB8C&oi=fnd&pg=PP1&dq=A+wavelet+tour+of+signal+processing&ots=qupUjpm142&sig=DlmMPAykraQu-A5kc-0wQf4ty8>>. Acesso em: 12 jan. 2022.

MALOUIN, F.; RICHARDS, C. L.; JACKSON, P. L.; LAFLEUR, M. F.; DURAND, A.; DOYON, J. The kinesthetic and visual imagery questionnaire (KVIQ) for assessing motor imagery in persons with physical disabilities: A reliability and construct validity study. *Journal of Neurologic Physical Therapy*, v. 31, n. 1, p. 20–29, 1 jan. 2007. Acesso em: 2 ago. 2024.

MARTINEZ-LEON, J. A.; CANO-IZQUIERDO, J. M.; IBARROLA, J. Are low cost Brain Computer Interface headsets ready for motor imagery applications? *Expert Systems with Applications*, v. 49, p. 136–144, 1 maio 2016. Acesso em: 28 jan. 2021.

MASHAT, M. E. M.; LIN, C. T.; ZHANG, DI. Effects of Task Complexity on Motor Imagery-Based Brain-Computer Interface. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 27, n. 10, p. 2178–2185, 1 out. 2019. Acesso em: 28 jan. 2021.

NIEDERMEYER, E.; ROBBINS, S. L.; KUMAR, V.; ASTER, J. C.; ABBAS, A. K. *Electroencephalography Basic Principles, Clinical Applications, and Related Fields*. [S.l.: s.n.], 2016.

OPPENHEIM, A. V.; SCHAFER, R. W. *Discrete-Time Signal Processing*. 3rd. ed. Harlow: Pearson Education, 2014.

PFURTSCHELLER, G.; LOPES DA SILVA, F. H. *Event-related EEG/MEG synchronization and desynchronization: Basic principles. Clinical Neurophysiology*. [S.l.]: Elsevier. . Acesso em: 11 fev. 2021. , 1 nov. 1999

PFURTSCHELLER, G.; SOLIS-ESCALANTE, T. Could the beta rebound in the EEG be suitable to realize a “brain switch”? *Clinical Neurophysiology*, v. 120, n. 1, p. 24–29, 1 jan. 2009. Acesso em: 27 jan. 2021.

PHINYOMARK, A.; THONGPANJA, S.; HU, H.; PHUKPATTARANONT, P.; LIMSAKUL, C.; PHINYOMARK, A.; THONGPANJA, S.; HU, H.; PHUKPATTARANONT, P.; LIMSAKUL, C. The Usefulness of Mean and Median Frequencies in Electromyography Analysis. *Computational Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges*, 17 out. 2012. Disponível em: <<https://www.intechopen.com/state.item.id>>. Acesso em: 23 jan. 2023.

RIMBERT, S.; FLECK, S. Long-term kinesthetic motor imagery practice with a BCI: Impacts on user experience, motor cortex oscillations and BCI performances. *Computers in Human Behavior*, v. 146, p. 107789, 1 set. 2023. Acesso em: 10 jan. 2024.

RIQUELME-ROS, J.-V.; RODRÍGUEZ-BERMÚDEZ, G.; RODRÍGUEZ-RODRÍGUEZ, I.; RODRÍGUEZ, J.-V.; MOLINA-GARCÍA-PARDO, J.-M. On the Better Performance of Pianists with Motor Imagery-Based Brain-Computer Interface Systems. *Sensors*, v. 20, n. 16, p. 4452, 10 ago. 2020. Disponível em: <<https://www.mdpi.com/1424-8220/20/16/4452>>. Acesso em: 28 jan. 2021.

ROBERTS, R.; CALLOW, N.; HARDY, L.; MARKLAND, D.; BRINGER, J. Movement Imagery Ability: Development and Assessment of a Revised Version of the Vividness of Movement Imagery Questionnaire. *Journal of Sport and Exercise Psychology*, v. 30, n. 2, p. 200–221, 1 abr. 2008. Disponível em: <<https://journals.humankinetics.com/view/journals/jsep/30/2/article-p200.xml>>. Acesso em: 2 ago. 2024.

ROMANO SMITH, S.; WOOD, G.; COYLES, G.; ROBERTS, J. W.; WAKEFIELD, C. J. The effect of action observation and motor imagery combinations on upper limb kinematics and EMG during dart-throwing. *Scandinavian Journal of Medicine and Science in Sports*, v. 29, n. 12, p. 1917–1929, 2019.

SADIQ, M. T.; YU, X.; YUAN, Z.; FAN, Z.; REHMAN, A. U.; LI, G.; XIAO, G. Motor imagery EEG signals classification based on mode amplitude and frequency components using empirical wavelet transform. *IEEE Access*, v. 7, p. 127678–127692, 2019. Disponível em: <[https://www.engineeringvillage.com/share/document.url?mid=cpx\\_M14dab07e16fe75efcb1M5b9210178163146&database=cpx](https://www.engineeringvillage.com/share/document.url?mid=cpx_M14dab07e16fe75efcb1M5b9210178163146&database=cpx)>.

SAHA, S.; AHMED, K. I. U.; MOSTAFA, R.; HADJILEONTIADIS, L.; KHANDOKER, A. Evidence of Variabilities in EEG Dynamics during Motor Imagery-Based Multiclass Brain-Computer Interface. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 26, n. 2, p. 371–382, fev. 2018. Disponível em: <[https://www.engineeringvillage.com/share/document.url?mid=cpx\\_f5bd268161d306aa15M768d1017816339&database=cpx](https://www.engineeringvillage.com/share/document.url?mid=cpx_f5bd268161d306aa15M768d1017816339&database=cpx)>.

SHAHLAEI, F.; BAGH, N.; ZAMBARE, M. S.; MACHIREDDY, R.; SHALIGRAM, A. D. Detection of Event Related Patterns using Hilbert Transform in Brain Computer Interface. *2019 IEEE Canadian Conference of Electrical and Computer Engineering, CCECE 2019*, maio 2019. Disponível em: <[https://www.engineeringvillage.com/share/document.url?mid=cpx\\_2e3b486816e36d2d1cfM78c910178163211&database=cpx](https://www.engineeringvillage.com/share/document.url?mid=cpx_2e3b486816e36d2d1cfM78c910178163211&database=cpx)>.

SMITH, J. S. The local mean decomposition and its application to EEG perception data. *Journal of The Royal Society Interface*, v. 2, n. 5, p. 443–454, 2005. Disponível em: <[doi/pdf/10.1098/rsif.2005.0058](https://doi.org/10.1098/rsif.2005.0058)>. Acesso em: 21 maio 2025.

STEYRL, D.; SCHERER, R.; OSWIN, F.; GERNOT, R. M. Motor Imagery Brain-Computer Interfaces: Random Forests vs Regularized LDA - Non-linear Beats Linear. *Proceedings of the 6th International Brain-Computer Interface Conference*, n. 1, p. 8–11, 2014. Acesso em: 14 fev. 2021.

STIEGER, J. R.; ENGEL, S. A.; HE, B. Continuous sensorimotor rhythm based brain computer interface learning in a large population. *Scientific Data*, v. 8, n. 1, 1 dez. 2021. Acesso em: 12 maio 2021.

STIEGER, J. R.; ENGEL, S.; JIANG, H.; CLINE, C. C.; KREITZER, M. J.; HE, B. Mindfulness Improves Brain-Computer Interface Performance by Increasing Control over Neural Activity in the Alpha Band. *Cerebral Cortex*, v. 31, n. 1, p. 426–438, 1 jan. 2021. Disponível em: <<https://academic.oup.com/cercor/article/31/1/426/5910197>>. Acesso em: 2 jun. 2021.

TANGERMANN, M.; MÜLLER, K. R.; AERTSEN, A.; BIRBAUMER, N.; BRAUN, C.; BRUNNER, C.; LEEB, R.; MEHRING, C.; MILLER, K. J.; MÜLLER-PUTZ, G. R.; NOLTE, G.; PFURTSCHELLER, G.; PREISSEL, H.; SCHALK, G.; SCHLÖGL, A.; VIDAURRE, C.; WALDERT, S.; BLANKERTZ, B. *Review of the BCI competition IV. Frontiers in Neuroscience*. [S.l.]: Frontiers. Disponível em: <[www.frontiersin.org](http://www.frontiersin.org)>. Acesso em: 28 jan. 2021. , 13 jul. 2012

VASILYEV, A.; LIBURKINA, S.; YAKOVLEV, L.; PEREPELKINA, O.; KAPLAN, A. Assessing motor imagery in brain-computer interface training: Psychological and neurophysiological correlates. *Neuropsychologia*, v. 97, p. 56–65, 1 mar. 2017. Acesso em: 11 fev. 2021.

VILLE, J. Theorie et applications de la notion de signal analytique. *Câbles et Transmissions*, p. 61–74, 1948. Disponível em: <<https://archive.org/details/VilleSigAnalytiqueCablesEtTrans1948Fr>>.

WANG, G.; MARTIN, M.; HUNG, P.; MACDONALD, S. Towards Classifying Motor Imagery Using a Consumer-Grade Brain-Computer Interface. *2019 IEEE International Conference on Cognitive Computing (ICCC)*, n. Iccc, p. 67–69, 2019.

WIGNER, E. On the Quantum Correction For Thermodynamic Equilibrium. *Physical Review*, v. 40, n. 5, p. 749, 1 jun. 1932. Disponível em: <<https://journals.aps.org/pr/abstract/10.1103/PhysRev.40.749>>. Acesso em: 21 maio 2025.

ZAR, J. H. *Biostatistical Analysis*. 5th. ed. New York: Prentice Hall, 2010.