

INTERFACE CÉREBRO-COMPUTADOR PARA PRÓTESE DE MEMBRO INFERIOR: ESTADO ATUAL DO MODELO DE CLASSIFICAÇÃO EEG

Rodrigo Oliveira Altoé¹, rodrigo.altoe@edu.ufes.br
Guilherme Gomes Fiorezi¹, guilherme.fiorezi@edu.ufes.br
Rafhael Milanezi de Andrade^{1 2}, rafhael.andrade@edu.ufes.br

¹ Graduate Program in Mechanical Engineering, Federal University of Espírito Santo, Vitória, ES, Brazil

² Graduate Program in Biotechnology, Federal University of Espírito Santo, Vitória, ES, Brazil

Resumo. O presente trabalho apresenta o estado atual de um projeto focado no desenvolvimento de uma interface cérebro-computador (BCI) para o controle de próteses de membro inferior. O estudo explora a eficácia de diferentes estratégias de processamento de sinais de eletroencefalografia (EEG) e modalidades de feedback visual, investigando o potencial do Filtro de Kalman Não-Centrado (UKF) para aprimorar a classificação da imagem motora do pé. Resultados preliminares indicam que o UKF oferece melhorias seletivas, com ganhos de acurácia para janelas de 1s com sobreposição (52-54% vs. 47-50%, $p < 0.01$) e um desempenho notável do SVM com janelas de 2s, atingindo $72.05\% \pm 8.71\%$. As diferenças entre as condições de realidade virtual (VR) e não-VR foram mínimas (1-3%), e a variabilidade individual reforçou a necessidade de calibração personalizada. Atualmente, o projeto foca na coleta de 2000 amostras de movimentos para treinar modelos de Deep Learning (CNN+LSTM). Os próximos passos envolvem a validação prática do sistema em VR e, subsequentemente, na prótese robótica, após calibração de segurança.

Palavras-chave: Imagem motora de membro inferior. Realidade virtual imersiva. Eletroencefalografia. Interface Cérebro-Computador. Filtro de Kalman.

1. INTRODUÇÃO

A tecnologia de BCI representa uma fronteira promissora na restauração da função motora, especialmente para o controle de próteses de membro inferior (MOHAMED et al., 2022). A acurácia da classificação de imagem motora (MI) é, contudo, prejudicada pelo ruído inerente aos sinais de EEG (LEE et al., 2019). Os sinais de EEG exibem características não lineares e não estacionárias, motivando o uso de abordagens de aprendizado profundo (ZHANG et al., 2021; MOHAMED et al., 2022) e técnicas de filtragem avançada, como o UKF, para capturar essas complexidades (BLANCO-DÍAZ et al., 2024; PÉREZ-MARCOS; LEEB, 2020; FERRERO et al., 2023). Outro aspecto crucial é a modalidade de feedback ao usuário.

O debate sobre a eficácia da realidade virtual (VR) versus métodos convencionais (não-VR) é marcado por resultados contraditórios (PÉREZ-MARCOS; LEEB, 2020; FERRERO et al., 2023). Enquanto a VR pode aumentar o engajamento (BLANCO-DÍAZ et al., 2024; ESTEVES, 2025; VOURVOPOULOS et al., 2022), sua complexidade pode não ser justificada se alternativas mais simples alcançarem resultados comparáveis (BATISTA et al., 2022; LEE et al., 2019; AL-SAEH; MOHAMMED, 2022). Este trabalho consolida achados preliminares e apresenta o ponto atual do projeto, que avança para testes práticos com um sistema de classificação robusto. O objetivo é validar o BCI em VR e, em seguida, integrá-lo a uma prótese robótica de perna, visando um controle mais intuitivo e seguro.

O objetivo deste artigo é apresentar o estado atual do projeto, detalhando os resultados obtidos com classificadores tradicionais e o UKF, e introduzir o plano de trabalho futuro, que inclui a expansão do banco de dados, a avaliação de modelos de Deep Learning e a proposta de um sistema adaptativo baseado em Deep Reinforcement Learning (DRL).


2. METODOLOGIA

A metodologia segue um pipeline sistemático para processamento de sinais de EEG, projetado para avaliar o impacto de cada componente na performance da classificação da intenção motora.

2.1. VISÃO GERAL E PROTOCOLO EXPERIMENTAL

O pipeline, ilustrado na Figura 1, compreende: aquisição de sinais, pré-processamento (com ou sem filtro UKF), segmentação, extração de características e classificação. Os dados foram coletados de seis voluntários saudáveis (destros, 20-27 anos) durante tarefas de imagem motora de dorsiflexão e flexão plantar. Os estímulos visuais foram apresentados em um headset Meta Quest 2 nos modos "Não-VR" (setas) e "VR" (avatar em primeira pessoa), com conteúdo informacional equivalente

Figura 1 – Protocolo experimental de aquisição de dados de imaginação motora (IM) do pé



Fonte: Produção do próprio autor.

2.2. AQUISIÇÃO E PROCESSAMENTO DE SINAIS

A atividade cerebral foi registrada com um sistema OpenBCI (16 canais, 125 Hz). Os sinais foram filtrados na banda de 8-30 Hz (mu e beta), com um filtro notch de 60 Hz. A remoção de artefatos e a normalização Z-score foram aplicadas. O protocolo atual foca na coleta de 2000 amostras de movimentos para alimentar modelos de Deep Learning (CNN+LSTM). Os canais de EEG utilizados são Cz, C3, C4, Fz, Pz, P3, P4, F3, F4, Ref, GND, Fp1, Fp2, T3 e T4, visando capturar uma maior amplitude da atividade cerebral. Notou-se que focar nos canais Cz, C3 e C4 como principais, e os demais como auxiliares, melhora a qualidade do sinal. Os sinais foram segmentados em janelas de 0.25s, 0.5s, 1s e 2s (as duas últimas com 50% de sobreposição). Características temporais (RMS, variância, Hjorth) e espectrais (potência e entropia das bandas mu/beta) foram extraídas.

2.3. CLASSIFICAÇÃO E ANÁLISE

Foram avaliados os algoritmos LDA, SVM e KNN, com validação cruzada "leave-one-subject-out" (LOSO). A análise estatística utilizou testes t pareados, Wilcoxon ou ANOVA ($\alpha = 0.05$) conforme a distribuição dos dados.


3. TRABALHOS REALIZADOS E RESULTADOS OBTIDOS

A fase inicial do projeto concentrou-se na avaliação de diferentes estratégias de processamento e classificação de sinais de EEG para imagem motora do pé, comparando o desempenho em ambientes com e sem realidade virtual (VR) e o impacto do pré-processamento com o Filtro de Kalman Não-Centrado (UKF).

3.1. DESEMPENHO DO CLASSIFICADOR E IMPACTO DO FEEDBACK VISUAL

A comparação entre as condições VR e não-VR revelou variações mínimas de acurácia (1-3%), como detalhado na Figura 2. Com o filtro de Kalman (Figura 2A), os resultados foram quase idênticos. Sem o filtro (Figura 2B), o classificador LDA apresentou um desempenho marginalmente superior no ambiente não-VR. A ausência de diferenças estatisticamente significativas ($p > 0.05$) sugere que, para a tarefa específica de imagem motora do pé, interfaces mais simples e de menor custo podem ser tão eficazes quanto sistemas de VR complexos, desde que o conteúdo informacional seja equivalente.

Figura 2 – Comparação de acurácia entre visualização VR e não-VR, onde (A) é com filtro de Kalman e (B) sem filtro de Kalman




Fonte: Produção do próprio autor.

3.2. EFEITO DO FILTRO UKF E OTIMIZAÇÃO DE JANELAS TEMPORAIS

A análise do janelamento temporal (Figura 3) foi crucial para entender a dinâmica da classificação. Janelas curtas (0.25s e 0.5s) forneceram um desempenho estável, com acurácias em torno de 61-62%. Notavelmente, a janela de 1s com 50% de sobreposição de gradou a performance (47-55%), um efeito atribuído à contaminação de características durante a transição entre os estados de imagem motora e repouso. Em contraste, a janela de 2s, especialmente quando combinada com o filtro UKF, demonstrou o resultado mais promissor: o classificador SVM atingiu uma acurácia de $72.05\% \pm 8.71\%$. Este resultado, obtido a partir de um banco de dados com mais de 1000 movimentos (aproximadamente 500 para dorsiflexão e 500 para flexão plantar), valida a eficácia da combinação de um contexto temporal mais longo com a redução de ruído proporcionada pelo UKF. A análise de canais indicou que Cz, C3 e C4 são primordiais para a captura da imagem motora, com os demais canais atuando de forma auxiliar para melhorar a qualidade do sinal.

Figura 3 – Desempenho dos algoritmos por tamanho de janela, onde (A) é com filtro de Kalman e (B) sem. As barras de erro representam o erro padrão




Fonte: Produção do próprio autor.

3.3. VARIABILIDADE INDIVIDUAL E NECESSIDADE DE PERSONALIZAÇÃO


A análise de correlação (Figura 4) e os resultados individuais (Figura 5) destacaram uma alta variabilidade entre os participantes. O desempenho do SVM mostrou uma correlação positiva com o aumento da janela temporal ($r = 0.5412$), enquanto o KNN se mostrou mais independente. Os efeitos da filtragem variaram de um decréscimo de 5.83 a um aumento de 6.67 pontos percentuais na acurácia, dependendo do indivíduo e da tarefa. Essa variabilidade reforça a conclusão de que sistemas BCI devem ser calibrados e otimizados individualmente, em vez de aplicar uma abordagem universal.

Figura 4 – Comparação de acurácia entre visualização VR e não-VR, onde (A) é com filtro de Kalman e (B) sem filtro de Kaman



Fonte: Produção do próprio autor.

Figura 5 – Desempenho individual dos participantes na janela de 2s, evidenciando a variabilidade



Fonte: Produção do próprio autor.


4. PRÓXIMOS PASSOS E TRABALHOS FUTUROS

Com base nos resultados promissores obtidos, o projeto agora se direciona para a validação prática e o aprimoramento do sistema de classificação, com foco em tecnologias de aprendizado profundo e testes em cenários mais realistas.

4.1. EXPANSÃO DO BANCO DE DADOS E IMPLEMENTAÇÃO DE DEEP LEARNING

O próximo passo fundamental é a expansão do banco de dados. Para isso, foi transferido todo o sistema de coleta, pré-processamento, treino e classificação dos modelos de classificação ao Python, onde o modo de coleta do sinal, se manteve com uma apresentação de como funcionaria a coleta dos dados, o tempo de pré-preparo da captura de movimentos em tempo de 17s, seguido com o tempo de 5s de movimentação para 5s de descanso, como demonstrado pela Figura 6.

Figura 6 – Protocolo de coleta



Fonte: Produção do próprio autor.

O novo protocolo de coleta foi atualizado para adquirir 2000 amostras de movimentos (1000 para dorsiflexão e 1000 para flexão plantar), tanto do pé destro quanto do pé canhoto, totalizando 4000 movimentos até o momento. Esse volume de dados é essencial para treinar modelos de Deep Learning de forma mais robusta, especificamente uma arquitetura híbrida CNN+LSTM (Rede Neural Convolutacional com Memória de Longo e Curto Prazo). A CNN é ideal para extrair características espaciais dos sinais de EEG, enquanto a LSTM é eficaz em aprender as dependências temporais da imagem motora. A coleta será realizada utilizando 14 canais de EEG (Cz, C3, C4, Fz, Pz, P3, P4, F3, F4, Fp1, Fp2, T3, T4), além de referência (Ref) e terra (GND), para capturar a atividade cortical com maior amplitude e resolução espacial.

4.2. EXPLORAÇÃO DE DEEP REINFORCEMENT LEARNING (DRL) PARA ADAPTAÇÃO EM TEMPO REAL

O foco principal dos trabalhos futuros será a transição de modelos de classificação estática para um paradigma de controle adaptativo e em tempo real, utilizando o Deep Reinforcement Learning (DRL) (PILARSKI; SUTTON, 2017). O DRL permite que o agente (o algoritmo de classificação) aprenda a tomar decisões (classificar o movimento) em um ambiente dinâmico (o sinal de EEG do usuário), otimizando uma recompensa (a acurácia da classificação ou a performance do feedback) (MNIH et al., 2015).

A metodologia idealizada para isso envolverá, inicialmente, a modelagem do ambiente e da recompensa. Será necessário definir o estado (janela de tempo do sinal de EEG pré-processado), a ação (classificação do movimento: Dorsiflexão, Flexão Plantar ou Repouso) e a função de recompensa (baseada na acurácia da classificação e na latência de resposta). Em seguida, serão exploradas arquiteturas de DRL, como Deep Q-Networks (DQN), Advantage Actor-Critic (A2C) ou Proximal Policy Optimization (PPO), adaptadas para lidar com a natureza sequencial e ruidosa dos dados de EEG. O objetivo é desenvolver um agente que possa se adaptar rapidamente às mudanças nas características do sinal do usuário (non-stationarity), um desafio que o DRL é particularmente adequado para resolver (LI, 2022; KOBER et al., 2013). Finalmente, serão implementadas estratégias de aprendizagem contínua (continual learning) para que o modelo possa se ajustar ao longo do tempo, mantendo a performance mesmo com a variação do sinal ao longo das sessões.

4.3. VALIDAÇÃO EM AMBIENTE VIRTUAL E INTEGRAÇÃO COM A PRÓTESE

Após o treinamento e a validação offline do modelo de Deep Learning, o sistema será testado em um ambiente de realidade virtual em malha fechada. Nessa fase, o usuário controlará um avatar em tempo real, permitindo avaliar a usabilidade, a responsividade e a precisão do classificador em um cenário interativo. A etapa final do projeto consistirá na integração do sistema BCI com a prótese robótica de perna, apresentado pela Figura 7 abaixo. Antes dos testes com usuários, a prótese passará por um rigoroso processo de calibração para garantir a segurança e a precisão dos movimentos do pé robótico. O objetivo é validar a capacidade do sistema de traduzir a intenção motora do usuário em um controle funcional e intuitivo da prótese em um ambiente real.

Figura 7 – Teste de bancada para a aplicação do teste em tempo real com a prótese robótica de pé



Fonte: Produção do próprio autor.

5. CONCLUSÃO

Os trabalhos realizados até o momento validaram a eficácia de estratégias de processamento, como o filtro UKF combinado com janelas temporais de 2s, alcançando acurácias de até $72.05\% \pm 8.71\%$, com classificadores tradicionais. Foi demonstrado que interfaces de baixo custo pode ser tão eficazes quanto sistemas de VR e que a personalização é crucial devido à alta variabilidade interindividual. O projeto agora avança para uma fase de maior complexidade, com a coleta de um banco de dados expandido para treinar modelos de Deep Learning (CNN+LSTM) e a subsequente validação do sistema em realidade virtual e, finalmente, em uma prótese robótica. A inclusão do Deep Reinforcement Learning no plano de trabalho futuro representa um passo estratégico para o desenvolvimento de um sistema BCI adaptativo e personalizado, capaz de manter alta performance em ambientes não-estacionários e de fornecer um controle protético mais natural e intuitivo.

6. REFERÊNCIAS

- AL-SAEIGH, M. S.; MOHAMMED, A. A review on brain-computer interface: fundamentals, challenges, and applications. **Journal of King Saud University - Computer and Information Sciences**, v. 34, n. 8, p. 5767–5784, 2022.
- BATISTA, D. et al. Effect of head-mounted virtual reality and vibrotactile feedback in ERD during motor imagery Brain-computer interface training. **Sensors**, v. 22, n. 19, 2022.
- BLANCO-DÍAZ, C. F. et al. Lower-limb kinematic reconstruction during pedaling tasks from EEG signals using Unscented Kalman filter. **Comput Methods Biomech Biomed Engin**, v. 27, n. 7, p. 867-877, 2024.
- BLANCO-DIAZ, C. F. et al. Deep learning approach for EEG classification in lower-limb movement phases: towards enhanced brain-computer interface control. In: **2024 20th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA)**, 2024. p. 1-7.
- ESTEVES, D. A. C. **Identifying EEG biomarkers of virtual embodiment for restorative brain-computer interfaces**. Tese (Doutorado) – Universidade de Lisboa, Lisboa, 2025.
- FERRERO, L. et al. Brain-computer interface enhanced by virtual reality training for controlling a lower limb exoskeleton. **Isience**, v. 26, n. 5, 2023.
- KOBER, J.; BAGNELL, J. A.; PETERS, J. Reinforcement learning in robotics: A survey. **The International Journal of Robotics Research**, v. 32, n. 11, p. 1238–1274, 2013.
- LEE, M. H. et al. A high-performance spelling system based on EEG-based BCI. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 27, n. 7, p. 1342–1353, 2019.
- LI, Z. A survey of deep reinforcement learning for autonomous driving. **arXiv preprint arXiv:2203.03493**, 2022.
- MNIH, V. et al. Human-level control through deep reinforcement learning. **Nature**, v. 518, n. 7540, p. 529–533, 2015.
- MOHAMED, A. A. A. T. T. & A. A. Deep learning for EEG-based BCI: a review of recent advances and future trends. **Frontiers in Human Neuroscience**, v. 16, 2022.
- PÉREZ-MARCOS, D.; LEEB, R. Brain-computer interfaces and virtual reality for neurorehabilitation. **Handbook of clinical neurology**, v. 168, p. 183–197, 2020.
- PILARSKI, P. M.; SUTTON, R. S. Between a rock and a hard place: a path to robust, useful, and adaptive prosthetic control. In: **International Conference on Rehabilitation Robotics (ICORR)**, 2017.

VOURVOPOULOS, A. et al. Enhancing Motor-Imagery Brain-Computer Interface Training With Embodied Virtual Reality: A Pilot Study With Older Adults. In: **2022 IEEE International Conference on Metrology for Extended Reality, Artificial Intelligence and Neural Engineering (MetroXRINE)**, Rome, Italy, 2022. p. 157-162.

ZHANG, Y. et al. A review of deep learning in EEG-based brain-computer interfaces: recent advances and future trends. **Journal of Neural Engineering**, v. 18, n. 4, p.041001, 2021

7. AGRADECIMENTOS

Este trabalho foi parcialmente financiado por bolsas da FAPES (Fundação de Amparo à Pesquisa do Espírito Santo, Bolsa: 946/2023, nº 2023-F0GWQ, Bolsa: 565/2023, nº 2023-BQK22), MCTI/FINEP (Financiadora de Estudos e Projetos) com recursos do FNDCT (ref. 2784/20 e ref. 2790/20), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (projeto 442445/2023-7 e projeto 402317/2023-8 e projeto 305367/2024-2) e CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Código Financeiro 001). O autor também reconhece o recebimento de uma bolsa de mestrado da FAPES sob o Edital nº 13/2023 – PROCAP MESTRADO 2024 (Processo nº 230/2024; Bolsa nº 2024-RDBHR) e ao LabTecMec-UFES por patrocinar o evento.

8. RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores confirmam, por meio deste documento, que são os únicos responsáveis pela autoria deste trabalho e que todo o material aqui incluído como parte deste artigo é propriedade (e de autoria) dos autores ou possui a permissão dos proprietários para ser incluído neste documento.