

16º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2025

Processamento de Sinais de EEG para Aplicação em uma Cadeira de Rodas Movida por Pensamento

LUCCA F. ANDRÉ, EDUARDO MOSSIN, MÁRCIO M. BENDER

Graduando em Engenharia Elétrica, Bolsistas PIBIFSP, IFSP, Campus Sertãozinho, Lucca.andre@aluno.ifsp.edu.br

Área de conhecimento (Tabela CNPq): **1.03.03.04-9 Sistemas de Informação**

RESUMO: Este trabalho apresenta o desenvolvimento, implementação e avaliação de um software pipeline para classificação de padrões em sinais de eletroencefalograma (EEG) com aplicação em interfaces cérebro-computador (ICC). O pipeline converte segmentos de EEG em espectrogramas (STFT) e emprega uma arquitetura de rede neural convolucional (CNN) treinada com augmentação de imagens. Foram utilizados dois conjuntos de dados públicos com características distintas: um voltado à imaginação motora (BBCI Competition) e outro voltado a crises epiléticas (CHB-MIT). Descrevem-se as etapas de pré-processamento (filtragem 1 a 40 Hz, remoção de artefatos por ICA e normalização), geração de espectrogramas, arquitetura da CNN e estratégias de treinamento (ImageDataGenerator, Adam, early stopping). A análise indicou limitações da abordagem para reconhecimento de comandos por imaginação motora e viabilidade promissora para detecção de padrões patológicos em EEG.

PALAVRAS-CHAVE: EEG; espectrograma; rede neural convolucional; interface cérebro-computador; detecção de epilepsia.

Processing of EEG Signals for Application in a Thought-Controlled Wheelchair

ABSTRACT: This work presents the development, implementation and evaluation of a pipeline for classification of electroencephalogram (EEG) patterns, applicable to brain-computer interfaces (BCI) and clinical event detection. The pipeline converts EEG segments into spectrograms (STFT) and uses a convolutional neural network (CNN) trained with image augmentation. Two public datasets were used: a motor imagery dataset (BBCI Competition) and an epilepsy dataset (CHB-MIT). Preprocessing steps (1 to 40 Hz bandpass, ICA artifact removal, normalization), spectrogram generation, CNN architecture and training strategies (ImageDataGenerator, Adam, early stopping) are described. Qualitative comparison indicates limitations for motor imagery command recognition and promising viability for pathological EEG pattern detection.


KEYWORDS: EEG; spectrogram; convolutional neural network; brain-computer interface; epilepsy detection.

INTRODUÇÃO

A comunicação entre o cérebro e dispositivos externos por meio de interfaces cérebro-computador (ICC) tem se mostrado uma alternativa promissora para aumentar a autonomia de pessoas com deficiência motora. Neste contexto, sinais de eletroencefalograma (EEG) são frequentemente utilizados por serem não invasivos e de fácil aquisição. No entanto, a baixa relação sinal-ruído e a grande variabilidade intersujeito tornam desafiador o reconhecimento robusto de intenções motoras a partir de EEG. Por outro lado, eventos patológicos como crises epiléticas costumam apresentar assinaturas temporo-espectrais mais marcantes, o que facilita sua detecção automática. Este trabalho propõe e avalia um pipeline que transforma segmentos de EEG em espectrogramas e aplica redes neurais convolucionais (CNN) para classificar padrões em duas aplicações distintas: controle por imaginação motora (uso assistivo) e detecção de crises epiléticas (aplicação clínica). A justificativa

é investigar até que ponto um mesmo conjunto de técnicas pode generalizar entre esses cenários e apontar melhorias necessárias para uso prático. Mandhouj (2021), por exemplo, demonstra a aplicação de espectrogramas com CNNs para classificação de sinais EEG. Estudos nacionais, como Nunes e Nascimento (2013) e Santos et al. (2018), também reforçam a importância do processamento de sinais de EEG em interfaces cérebro- máquina. Na Figura 1 apresenta-se a arquitetura CNN de Mandhouj (2021) utilizada como referência.

FIGURA 1. Classificação de espectrogramas de EEG



MATERIAL E MÉTODOS

Nesta seção descrevem-se os conjuntos de dados utilizados, os procedimentos de pré-processamento e geração de espectrogramas, a arquitetura da rede convolucional implementada, parâmetros de treinamento e métricas empregadas. Foram utilizados dois repositórios públicos com características distintas: (i) BBCI Competition, dataset voltado à imaginação motora com registros multicanais; (ii) CHB-MIT Scalp EEG Database, dataset pediátricos com registros de crises epilépticas.


Conjuntos de dados e aquisição: os arquivos brutos foram padronizados e organizados em conjuntos de treinamento, validação e teste. Para cada dataset, segmentos de 1s com 50% de sobreposição foram extraídos.

Pré-processamento: aplicou-se filtragem passa-banda (1–40 Hz), remoção de artefatos por ICA (conforme Jung et al., 2000) e normalização z-score por canal. A literatura de análise tempo-frequência, assim como revisões sobre classificação para BCI (Lotte et al., 2007; Nunes; Nascimento, 2013; Santos et al., 2018), suportam a escolha das etapas de pré-processamento e geração de representações espectrais.

Geração de espectrogramas: cada segmento foi transformado por STFT (janela Hamming) e convertido em imagens redimensionadas para 64×64 pixels, seguindo práticas comuns em trabalhos que aplicam CNNs a espectrogramas (ver, por exemplo, Mandhouj, 2021; Millán et al., 2010).

A figura 2 mostra o sinal bruto do EEG e, após todo o tratamento, o espectrograma gerado para treinamento da IA.

FIGURA 2. Sinal bruto de EEG para espectrograma gerado



Arquitetura e treinamento: a CNN implementada consta de três blocos convolucionais, camada flatten, camadas densas e saída sigmoid. O treinamento utilizou otimizador Adam (Kingma & Ba, 2014), batch size = 32, augmentação via ImageDataGenerator e early stopping. Para avaliação empregaram-se acurácia, precisão, recall, F1-score, matriz de confusão e tempo de inferência. Observa-se que, embora o uso de GPU reduza latência, a literatura aponta que requisitos de latência para aplicações assistivas são mais exigentes e demandam validação específica (Rebsamen et al., 2010).

Observação metodológica: o sucesso em detecção de eventos epiléticos não garante automaticamente adequação para ICMs voltadas à mobilidade assistiva, pois as exigências de latência, taxa de falsos positivos/negativos e robustez frente a artefatos são distintas — essa distinção é tratada na seção de discussão e fundamentada em trabalhos que combinam BCIs e tecnologias assistivas (Millán et al., 2010; Rebsamen et al., 2010).

RESULTADOS E DISCUSSÃO

A aplicação do pipeline (pré-processamento → espectrogramas → CNN) apresentou resultados distintos nos dois conjuntos de dados analisados.

No BBCI (imaginação motora, primeiro banco de dados), a taxa de acurácia obtida foi de 55%. Esse desempenho, ainda que limitado, reflete a dificuldade inerente em distinguir padrões relacionados à imaginação motora em espectrogramas, especialmente em cenários de múltiplos canais e elevada variabilidade intersujeitos. Embora a acurácia não seja suficiente para garantir controle seguro e confiável em aplicações críticas, como o direcionamento de cadeiras de rodas, os resultados confirmam a viabilidade da metodologia como ponto de partida para ajustes e aprimoramentos. A literatura indica que a combinação com métodos de extração de características espaciais (ex.: CSP), estratégias de adaptação online, calibração personalizada ou a integração de sinais complementares (EOG/EMG) pode elevar substancialmente a separabilidade entre classes. Além disso, a integração de sinais complementares (por exemplo EOG para detecção de piscadas voluntárias) e técnicas de extração espacial (ex.: CSP) poderiam melhorar a separabilidade entre classes e reduzir a necessidade de calibração extensa para uso assistivo.

No CHB-MIT (detecção de crises epiléticas, segundo banco de dados), o modelo alcançou 85% de acurácia, evidenciando que o pipeline foi capaz de capturar assinaturas espectrais e temporais relevantes. Esse resultado demonstra aplicabilidade em um domínio clínico específico e confirma que a metodologia proposta apresenta boa capacidade de generalização para diferentes tarefas de EEG. Ressalta-se, contudo, que o sucesso em detecção de eventos epiléticos não garante automaticamente adequação para ICMs voltadas à mobilidade assistiva, uma vez que as exigências de latência, taxa de falsos positivos/negativos e robustez frente a artefatos são distintas.

Quanto à viabilidade prática, o tempo de inferência acelerado por GPU mostrou-se compatível com aplicações em tempo real. Ainda assim, a transposição para cenários de uso assistivo requer validação com usuários reais, análise de segurança e estudos de usabilidade para garantir desempenho satisfatório em condições de operação cotidiana.


Em síntese, os achados reforçam que uma mesma estratégia não apresenta desempenho uniforme para todas as tarefas em EEG. O pipeline mostrou-se promissor para detecção clínica (85%),

mas demanda ajustes significativos e, possivelmente, a exploração de sinais alternativos mais discriminativos para alcançar confiabilidade adequada no paradigma de imaginação motora (55%).

CONCLUSÕES DISCUSSÃO

O pipeline proposto comprovou sua capacidade de treinar modelos de inteligência artificial para o reconhecimento de padrões em sinais de EEG, validando a utilização de CNNs aplicadas a espectrogramas como abordagem metodológica. Na detecção de crises epiléticas (base CHB-MIT), o desempenho obtido (85% de acurácia) evidencia potencial de aplicação clínica, desde que acompanhado por validação externa e protocolos adequados de avaliação. A figura 3 abaixo ilustra a comparação da acurácia entre os três modelos em cada banco de dados. Observa-se que a CNN apresentou desempenho superior nos dois casos, sobretudo no CHB MIT, reforçando sua aplicabilidade em cenários clínicos.

FIGURA 3. Comparação da acurácia dos modelos nos bancos de dados BBCI e CHB-MIT.



No caso da imaginação motora (base BBCI), o desempenho de 55% revela que a metodologia, em sua forma atual, ainda não é suficiente para controle confiável de interfaces assistivas complexas, como cadeiras de rodas. No entanto, o resultado destaca a necessidade de estratégias complementares, como extração de características espaciais, adaptação dinâmica e integração de sinais adicionais (ex.: EOG para piscadas voluntárias), que podem tornar o pipeline mais eficaz em cenários de mobilidade assistida.

Conclui-se, portanto, que embora o método tenha se mostrado adequado para validação inicial do reconhecimento de padrões em EEG, sua aplicação prática em dispositivos de auxílio à locomoção exige aperfeiçoamentos técnicos e validações experimentais com usuários reais, garantindo segurança, robustez e confiabilidade na operação.

CONTRIBUIÇÕES DOS AUTORES

Lucca Fernando André foi responsável pela concepção, implementação do pipeline de processamento de sinais, treinamento da rede neural convolucional (CNN), análise dos resultados obtidos e redação do relatório técnico. Eduardo Mossin, como coorientador do projeto, contribuiu significativamente com o desenvolvimento da parte de programação e de inteligência artificial, auxiliando no treinamento da CNN, na estruturação dos códigos e na otimização dos algoritmos utilizados. Márcio Machado Bender, como orientador do projeto, contribuiu com a supervisão técnica e científica, oferecendo suporte na definição da metodologia, validação dos resultados e revisão crítica do conteúdo.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento (CNPq) pelo apoio financeiro, essencial para a realização deste projeto.

REFERÊNCIAS

BCI Competitions. Disponível em: <<https://www.bbc.de/competition/>>. Acesso em: 4 set. 2025.

CHB-MIT Scalp EEG Database. Disponível em: <physionet.org>. Acesso em: 4 set. 2025.

JUNG, T. P. *et al.* Removing electroencephalographic artifacts by blind source separation. **Psychophysiology**, v. 37, n. 2, p. 163–178, 2000.

KINGMA, Diederik P.; BA, Jimmy. **Adam: A method for stochastic optimization.** 2014. Disponível em: <<http://arxiv.org/abs/1412.6980>>.

LOTTE, F. *et al.* A review of classification algorithms for EEG-based BCIs. **Journal of Neural Engineering**, n. 2, p. R1–R13, 2007.

MANDHOUI, Badreddine; CHERNI, Mohamed Ali; SAYADI, Mounir. An automated classification of EEG signals based on spectrogram and CNN for epilepsy diagnosis. **Analog integrated circuits and signal processing**, v. 108, n. 1, p. 101–110, 2021.

MANDHOUSH, O.; WU, J. Y.; WANG, M. Epileptic seizure detection using spectrogram-based convolutional neural network. **Biomedical Signal Processing and Control**, v. 65, 2021.

MILLÁN, J. *et al.* Combining BCIs and assistive technologies. **Frontiers in Neuroscience**, 2010.

NUNES, I. L.; NASCIMENTO, F. A. Processamento de sinais de EEG para aplicações em interfaces cérebro-máquina: revisão sistemática. **Revista Brasileira de Engenharia Biomédica**, v. 29, n. 2, p. 180–195, 2013.

REBSAMEN, Brice *et al.* A brain controlled wheelchair to navigate in familiar environments. **IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society**, v. 18, n. 6, p. 590–598, 2010.

REIRE, L. L.; COUTO, J. S.; FALCÃO, A. Análise de sinais de EEG com redes neurais convolucionais para aplicações em BCI. **Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)**, 2020.

SANTOS, V. M.; OLIVEIRA, R. J.; COSTA, P. Métodos de classificação de sinais de EEG aplicados a BCI: um estudo comparativo. **Congresso Brasileiro de Inteligência Computacional (CBIC)**, 2018.