

Multi-Classificação de Sinais de Eletroencefalograma, para Imaginação Motora, usando Processamentos Estatísticos de Sinais e *Deep Learning*

Multi-Classification of Electroencephalogram Signals, for Motor Imagination, using Statistical Signal Processing and Deep Learning

Clasificación Múltiple de Señales da Electroencefalograma, para Imaginación Motora, Utilizando Procesamiento Estadístico de Señales y Aprendizaje Profundo

William Henrique Pereira Costa¹, Luiz Eduardo Borges da Silva²


¹ Mestrando em Engenharia Elétrica, Instituto de Engenharia de Sistemas e Tecnologias da Informação, Universidade Federal de Itajubá – Itajubá, MG, Brasil.

² Doutor em Engenharia Elétrica, Instituto de Engenharia de Sistemas e Tecnologias da Informação, Universidade Federal de Itajubá – Itajubá, MG, Brasil.

Autor correspondente: William Henrique Pereira Costa
E-mail: willam_henrique@unifei.edu.br

Resumo

Objetivos: A classificação dos sinais de eletroencefalograma (EEG) é a base para a construção de sistemas com interface cérebro-computador. Seu desenvolvimento depara-se com a complexidade dos sinais de EEG, que se diferem de sujeito para sujeito, tornando sua classificação complexa. Diante disso, esse trabalho visa comparar o desempenho de uma rede neural artificial utilizando diferentes técnicas de processamento de sinal, na classificação de um estado de repouso e dois estados de imaginação de movimento (IM). Métodos: Para esse trabalho, utilizou-se de três técnicas estatísticas de processamento de sinais e uma Rede Neural Convolucional. O banco de dados utilizado para a classificação consiste no registro de EEG de 109 voluntários, disponibilizado pela Physionet. Resultado e Conclusão: Observou-se que a Análise de Componentes Principais reduziu o custo computacional sem perda de desempenho na acurácia. Entretanto, a Análise de Componentes Independentes e a Análise Espectral Singular não obtiveram resultados promissores.



Descritores: Processamento de Sinais Digitais; Aprendizado Profundo; Imaginação


Abstract

Objectives: The classification of electroencephalogram (EEG) signals is the basis for building systems with a brain-computer interface. Its development is faced with the complexity of EEG signals, which differ from subject to subject, making their classification complex. Therefore, this work aims to compare the performance of an artificial neural network using different signal processing techniques, in the classification of a resting state and two states of motor imagination (MI). **Methods:** For this work, we used three statistical techniques of signal processing and a Convolutional Neural Network. The database used for the classification consists of the EEG recording of 109 volunteers, made available by Physionet. **Result and Conclusion:** It was observed that Principal Component Analysis reduced the computational cost without loss of performance in accuracy. However, Independent Component Analysis and Singular Spectral Analysis did not obtain promising results.

Keywords: Signal Processing; Deep Learning; Imagination

Resumen

Objetivos: La clasificación de las señales del electroencefalograma (EEG) es la base para la construcción de sistemas con una interfaz cerebro-computadora. Su desarrollo se enfrenta a la complejidad de las señales EEG, que difieren de un sujeto a otro, haciendo compleja su clasificación. Por lo tanto, este trabajo tiene como objetivo comparar el desempeño de una red neuronal artificial utilizando diferentes técnicas de procesamiento de señales, en la clasificación de un estado de reposo y dos estados de imaginación en movimiento (MI). **Métodos:** Para este trabajo se utilizaron tres técnicas estadísticas de procesamiento de señales y una Red Neuronal Convolutiva. La base de datos utilizada para la clasificación consiste en el registro de EEG de 109 voluntarios, puesto a disposición por Physionet. **Resultado y Conclusión:** Se observó que el Análisis de Componentes Principales redujo el costo computacional sin pérdida de rendimiento en precisión. Sin embargo, el Análisis de Componentes Independientes y el Análisis Espectral Singular no obtuvieron resultados prometedores.



Descritores: Procesamiento de Señales Asistido por Computador; Aprendizaje Profundo; Imaginación


Introdução

Interface Cérebro-Computador (BCI, de *Brain-Computer Interface*) é um sistema que usa sinais cerebrais para controlar dispositivos externos, permitindo interação com o ambiente sem o uso das vias convencionais do Sistema Nervoso Central (SNC), que são musculares ou hormonais. A atividade cerebral consiste em fenômenos eletrofisiológicos, neuroquímicos e metabólicos, e pode ser quantificada por diversas técnicas de monitoramento. Um sistema BCI mensura os sinais cerebrais produzidos por um usuário que pode ser através de eletroencefalograma (EEG), extrai deles características específicas e as traduz em comandos para uma aplicação. Esses comandos são convertidos em ações, como o movimento de uma prótese, cadeira de rodas, robô ou cursor⁽¹⁾, ou o estímulo elétrico direto sobre músculos, ou sobre o próprio cérebro⁽²⁾. Dentro desse contexto, as BCIs podem atuar como tecnologias assistivas e de reabilitação em pacientes com severas deficiências motoras, como as resultantes de esclerose lateral amiotrófica (ELA), acidente vascular cerebral (AVC) ou lesões medulares.

A classificação das características de EEG é a parte principal dos sistemas BCI. A classificação da atividade como a imaginação motora (IM) é uma tarefa desafiadora devido à baixa relação sinal-ruído (SNR) e a sua natureza não estacionária para o mesmo sujeito e entre os sujeitos, ao número limitado de dados de treinamento, e a baixa confiabilidade dos sistemas BCI atuais. Portanto, os algoritmos de classificação visam principalmente superar um ou mais dos desafios mencionados.

Uma revisão da literatura feita por Craik e Contreras⁽³⁾ sobre o estado da arte para classificação de sinais de EEG com base em *deep learning*, verificou que para IM, 22% dos artigos estudados não utilizaram métodos para remoção de artefatos, ruídos ou redução de dimensão⁽³⁾. Ainda não há um consenso sobre o uso de técnicas de processamento de sinal, o que deixa o campo aberto para estudos.

A Análise Independente de Componentes (ICA, de *Independent Component Analysis*), é uma técnica usada para decompor os sinais em componentes



independentes. No EEG, a ICA é utilizada para identificar e remover sinais de outras fontes externas ao cérebro ⁽³⁾. Esses sinais, podem ser da eletro-oculografia (EOG), da eletrocardiografia (ECG), ruído dos sensores, entre outros.

A Análise de Componentes Principais (PCA, de *Principal Component Analysis*), é um método bem estabelecido e utilizado em diversos campos (e.g., eletromiografia) para extração de características e redução de dimensionalidade. Em outros campos da biomedicina, a PCA é utilizada para aumentar a relação SNR em sinais neuro-magnéticas ⁽⁴⁾. Na classificação de IM, a PCA pode minimizar o tempo de treinamento de uma rede neural sem perdas relevantes nas informações contidas no sinal.


A Análise Espectral Singular (SSA, de *Singular Spectrum Analysis*), decompõe uma série temporal em componentes que podem ser interpretadas como tendência, periodicidade e ruído. A SSA enfatiza a separação das componentes subjacentes e pode separar as periodicidades que ocorrem em diferentes escalas de tempo, mesmo em dados de séries temporais com muito ruído. ⁽⁵⁾

Agarwal e Zubair ⁽⁵⁾ utilizaram a SSA como parte de um algoritmo de *machine learning* para classificação de EEG binária entre pessoas alcoolizadas e não alcoolizadas, essa aplicação torna a SSA um método promissor para classificação de IM.

Com bases nos argumentos citados acima, esse estudo tem por objetivo avaliar o desempenho e o custo computacional de uma Rede Neural Convolutacional (CNN, de *Convolutional Neural Network*) para a classificações dos estados de repouso, da IM do punho esquerdo e da IM do punho direito utilizando-se de técnicas descritivas para o processamento de sinais como a ICA, PCA e SSA.

Métodos

A metodologia aplicada neste estudo foi dividida em três partes: pré-processamento, processamento e *deep learning*. Para uma maior compreensão, elaborou-se um diagrama da Figura 1. Todas as técnicas de processamento e a CNN foram executadas em um computador com um processador AMD Ryzen 7 3600x, 16 GB de RAM e uma placa de vídeo Nvidia GTX 1060 com o sistema operacional Microsoft Windows 10 21H2.



Pré-Processamento

Nesse trabalho, utilizou-se o banco de dados da Physionet⁽⁷⁾, esse banco de dados é gratuito e com uma boa base de dados. Ele consiste em registros de EEG de 109 voluntários, extraídos no sistema BCI2000. Para extração dos sinais de EEG, utilizou-se 64 eletrodos com frequência de amostragem de 160 Hz, os eletrodos foram colocados conforme o sistema internacional 10-10.

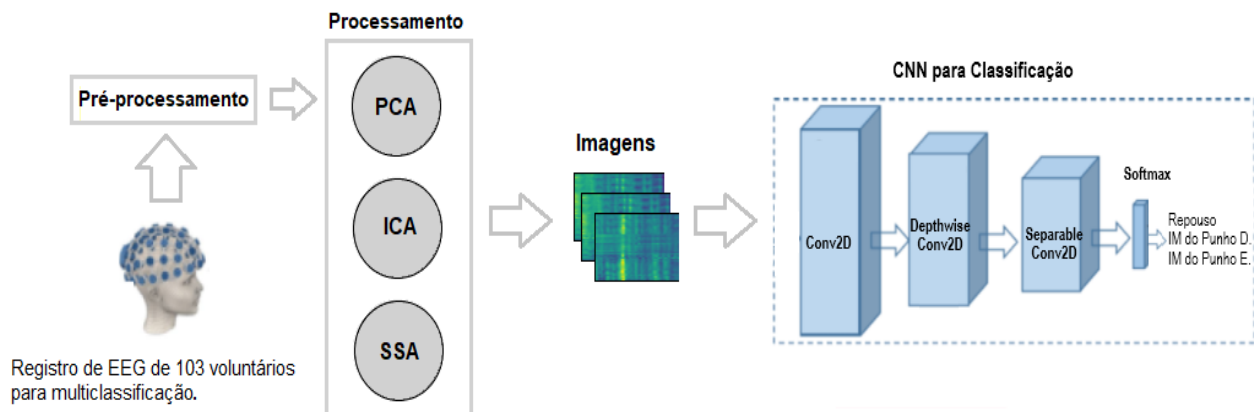



Figura 1 – Diagrama com resumo dos métodos.

Para cada voluntário gravou-se 14 registros de EEG, sendo eles divididos em: duas de *baseline* (uma com olhos fechados e uma com olhos abertos) e outras quatro diferentes tarefas, a qual foram repetidas três vezes cada.

As tarefas consistiram-se em:

- Tarefa 1 - O voluntário realizava o movimento de abrir e fechar do punho esquerdo ou direito.
- Tarefa 2 - O voluntário imaginava o movimento do abrir e fechar do punho direito ou do esquerdo.
- Tarefa 3 - O voluntário realizava o movimento de abrir e fechar de ambos punhos.
- Tarefa 4 - O voluntário imaginava o movimento de abrir e fechar de ambos os punhos ou de movimento dos ambos os pés.

Para esse estudo, utilizou-se a Tarefa 2, composta por eventos que foram ações solicitadas aos voluntários, tais como, a IM de abrir e fechar punho esquerdo ou direito, cada ação foi intercalada por um período que o voluntário ficou em repouso. Cada evento



teve duração de 4,1 s e a tarefa inteira teve 124 s, ao todo obtiveram-se 15 eventos de repouso, sete de IM do punho esquerdo e oito de IM do punho direito. No total foram 30 eventos entre a IM e repouso.





Figura 2 – Corte de 42 s contendo alguns sensores de EEG da Tarefa 2 do voluntário 004, cada cor simboliza o intervalo de um evento.

O pré-processamento consistiu-se em avaliar a qualidade dos registros de modo a verificar possíveis erros nos registros ou arquivos corrompidos, nessa parte, verificaram-se os arquivos de cada voluntário. Para visualização dos arquivos, utilizou-se a biblioteca *MEG + EEG Analysis & Visualization* (MNE)⁽⁸⁾ da linguagem Python. Observou-se que os registros dos voluntários 043, 088, 089, 092, 100 e 104 estavam corrompidos, portanto, utilizaram-se os registros de 103 voluntários.⁽⁹⁾

A IM tem suas informações mais relevantes abaixo da frequência de 30 Hz, então, utilizou-se um filtro passa-faixa de resposta ao impulso finita (FIR, de *Finite Impulse Response*) de segunda ordem para a faixa de 0,5 a 30 Hz. Dentro dessa faixa de frequência, contém-se as frequências δ (0,5–4 Hz), α (8–13 Hz) e β (13–30 Hz), essa são as faixas mais efetivas para IM encontradas na literatura.⁽¹⁰⁾



Por fim, extraíram-se os blocos de IM e repouso de cada voluntário, para isso segmentaram-se os registros em 2 s antes do evento e 3 s segundos após o evento (Figura 3). No total, gerou-se 8961 blocos.




Figura 3 – Gráfico agrupado de três blocos (repouso, IM do punho direito e IM do punho esquerdo). Nesse gráfico, observou-se um pico na amplitude da tensão referente ao IM do punho direito a cerca de -1,5 s. Observou-se também um comportamento semelhante do IM no punho esquerdo a cerca de 1,3 s.


Processamento

Análise de Componentes Principais

Para a PCA, efetuou-se a redução da dimensão alterando a variância em 90%, 95% e 99%, da quais obteve-se uma redução na dimensão de 64 componentes para sete componentes principais (CPs) para variância em 90%, de 64 para 18 CPs com a variância em 95% e de 64 para 47 CPs para a variância em 99%. Para as diferentes variâncias cronometrou-se o tempo de execução.

Análise de Componentes Independentes

A ICA visa a remoção de artefatos e ruídos que contaminam os registros de EEG. Os artefatos são relacionados a atividades cerebrais, tais como, o piscar de um dos olhos, movimento muscular do pescoço, entre outros. Na biblioteca MNE há um módulo específico para aplicar a ICA em dados de EEG.



O módulo da ICA tem como padrão a utilização da PCA como método de branqueamento, para isso, ajustou-se a variância em 99% da PCA no algoritmo da ICA. Com o ajuste, obtiveram-se as componentes independentes (CIs). No entanto, foi necessária a inspeção visual para identificar e rejeitar as componentes independentes que continham artefatos (Figura 4).




Figura 4 – Topografia do escalpo das cinco primeiras CIs. As componentes ICA001, ICA002 e ICA003 demonstram atividades de polarização ou despolarização nos eletrodos próximos aos olhos, portanto essas componentes são artefatos de EOG ^(11,12). Todavia, as componentes ICA004 e ICA005 contém sinais originados do cérebro ⁽¹³⁾.

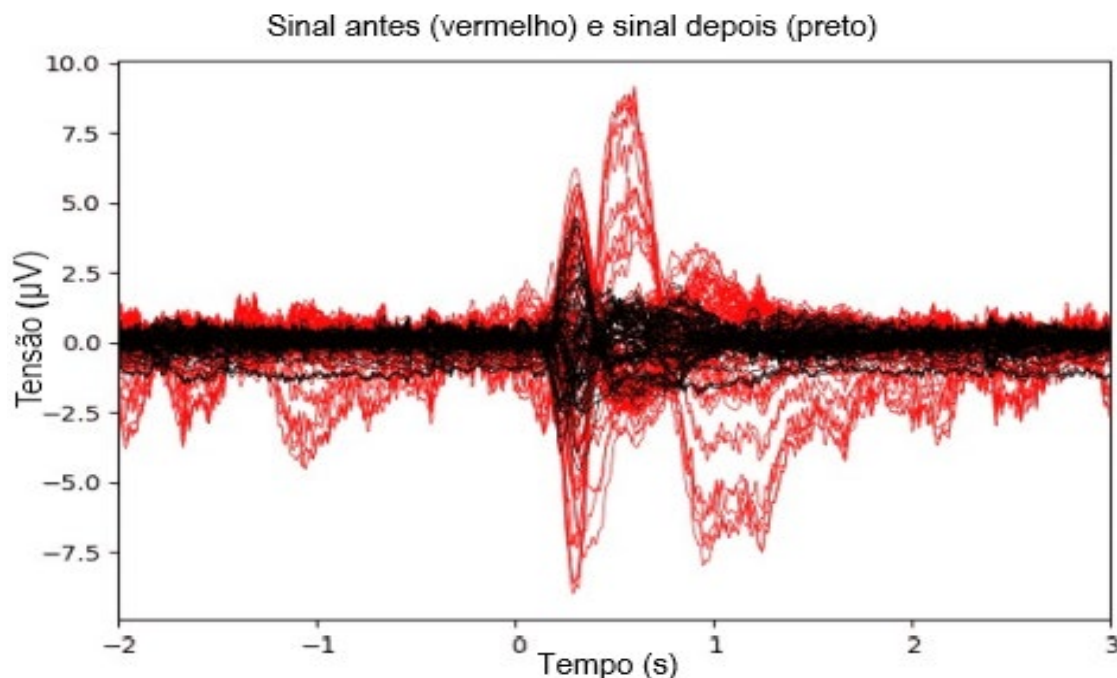



Figura 5 – Gráfico do sinal antes e após aplicação da ICA.

Após a visualização e identificação das componentes com artefato, excluíram-se



as componentes que continham artefatos e efetuou-se a reconstrução do sinal, na Figura 5 pode-se observar o antes e depois da utilização da ICA.

Análise Espectral Singular

A análise espectral singular decompõe cada componente dos 64 sensores em um conjunto de componentes independentes, esses conjuntos foram interpretados como tendências, periodicidade e ruído. De maneira a eliminar o ruído, selecionaram-se as componentes que em sua soma represente 99%, 95 e 90% da variância da série original, para todos os conjuntos mantiveram-se os tamanhos das janelas fixo em cinco. Na Figura 6, observa-se o comparativo do sinal original e do sinal acumulado com 99% de sua variância. Para os diferentes modelos cronometraram-se os tempos de execução.

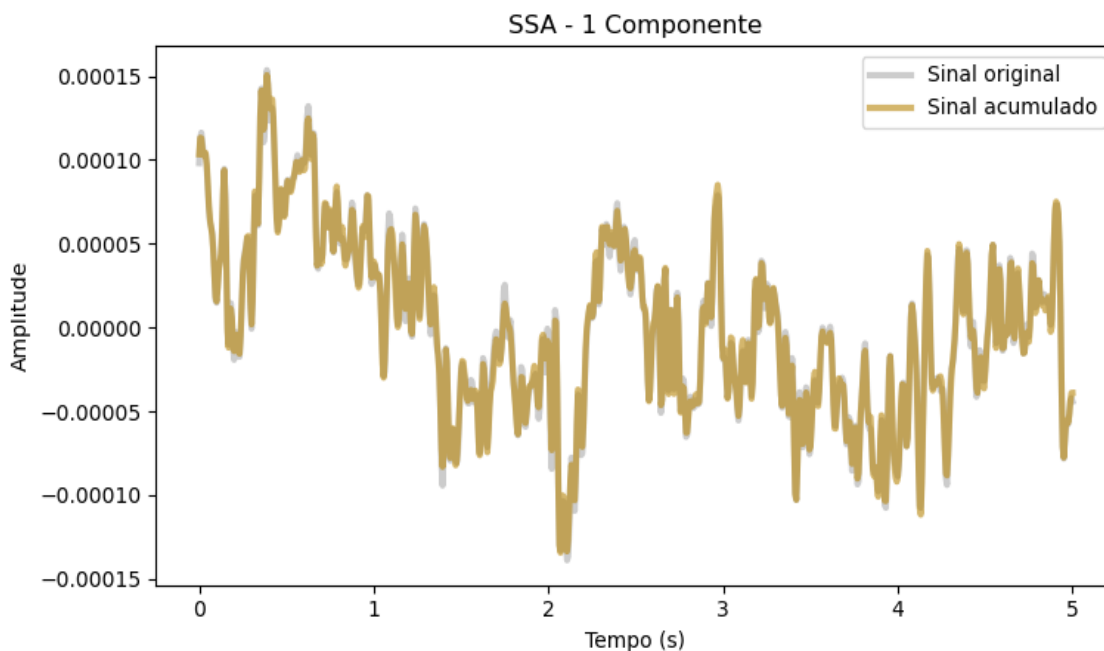



Figura 6 – Gráfico do sinal de um dos sensores de EEG normalizado, observa-se a suavização no sinal acumulado.

Deep Learning

Nesse estudo, utilizou-se o uma CNN para o *deep learning*. A sua arquitetura foi fundamentada em uma rede neural compactada desenvolvida por Lawhern et. al.,⁽¹⁷⁾, sendo seu *framework* baseado em Keras da linguagem Python. Para o treinamento, empregou-se o otimizador ADAM e como critério para avaliar o desempenho da CNN



utilizou-se a entropia cruzada categórica (como função de perda). Para os hiperparâmetros, utilizaram-se as seguintes configurações: taxa de aprendizagem (otimizador Adam) em 10^{-4} , número de *epochs* para o treinamento em 50, tamanho do *batch* fixado em 16, *Dropout* em 0,5, filtro em 64 e a função de ativação Gelu. ⁽⁶⁾

A CNN tem como entrada uma imagem, então transformou-se os sinais de cada um dos blocos em imagens na escala cinza do tamanho 64x801 para a SSA e ICA. Para a PCA, devido a variação da quantidade de CPs, obteve-se diferentes tamanho de imagens, sendo elas: 47x801 para PCA 99%, 18x801 para PCA 95% e de 7x801 para PCA 90%. No total, produziu-se 8961 imagens divididas em três classes, repouso com 4326 imagens, a IM do punho direito com 2298 imagens e a IM do punho esquerdo com 2337 imagens. A divisão do treinamento e do teste foi de 80% e 20% respectivamente.


Para as métricas de avaliação da CNN, empregou-se a métrica da acurácia, F1-Score ⁽¹⁴⁾ e o Coeficiente Kappa (Kappa). Às duas primeiras são comumente utilizadas em classificadores, elas medem os acertos do modelo e a qualidade do modelo respectivamente. A métrica Kappa é conservadora e mede a proporção da concordância observada P_o e a concordância devida ao acaso P_a entre dois conjuntos de dados, na Equação 1 demonstra-se seu cálculo:

$$k = \frac{P_o - P_a}{1 - P_a} \quad (1)$$

Na métrica Kappa, o valor é unitário e indica se a classificação foi totalmente correta ou valor nulo para classificação meramente ao acaso. De maneira a comparar-se os resultados, utilizou-se o mesmo banco de dados sem processamento estatístico, criando-se um controle para os resultados. Para cada método, executou-se o treinamento da CNN por 20 vezes, dessa maneira pode-se utilizar a estatística para comparar as médias, devido à ampla utilização na literatura, utilizou-se a Análise de Variância (ANOVA). ⁽¹⁶⁾

Resultados e Discussão

Com os dados da Tabela 1, avaliaram-se primeiramente as técnicas da PCA com a CNN, observa-se que o modelo com variância de 99% obteve a melhor média nas



métricas avaliadas e seu tempo total foi aproximadamente 50 minutos a menos do que o controle. A PCA 95% obteve médias similares a PCA 99% nas métricas analisadas, entretanto, com um tempo total menor, cerca de 48,7% do tempo da PCA 99% e 41,9% do controle.


Tabela 1 – Média e desvio padrão (entre parenteses) dos resultados das diferentes técnicas em ordem de desempenho pela acurácia. Os tempos de execução são relativos a uma execução.

Método	Acurácia (n=20)	Kappa (n=20)	F1-Score (n=20)	Tempo de execução do método	Tempo de execução da CNN	Tempo total
PCA 99%	0,783 (0,007)	0,654 (0,009)	0,768 (0,008)	00:02 h	05:08 h	05:10 h
Controle	0,781 (0,006)	0,651 (0,008)	0,764 (0,005)	-	06:01 h	06:01 h
PCA 95%	0,781 (0,007)	0,649 (0,008)	0,764 (0,006)	00:01 h	02:30 h	02:33 h
SSA 99%	0,747 (0,008)	0,599 (0,012)	0,730 (0,008)	02:08 h	06:10 h	08:18 h
PCA 90%	0,744 (0,006)	0,595 (0,007)	0,729 (0,006)	00:01 h	01:43 h	01:44 h
ICA	0,735 (0,006)	0,576 (0,009)	0,707 (0,007)	00:19 h	05:57 h	06:17 h
SSA 95%	0,702 (0,007)	0,526 (0,009)	0,680 (0,006)	00:48 h	06:00 h	06:48 h
SSA 90%	0,688 (0,008)	0,504 (0,008)	0,665 (0,007)	00:35 h	06:00 h	06:35 h

Observou-se um menor tempo de execução da CNN nos métodos que se utilizaram da PCA. Isso se deve à redução na quantidade de componentes em relação aos outros métodos, então, logo as imagens são menores e a CNN tende a ser mais rápida. Ademais, com um menor tempo de treinamento, leva-se uma diminuição no custo computacional.

O método com a ICA não obteve bons resultados, seu desempenho foi inferior em 6% e levou cerca de 15 minutos a mais em sua execução se comparado com o controle. Uma hipótese para perda de desempenho foi devido à remoção dos artefatos. Pois, devido à baixa relação SNR, informações de IM acabaram sendo retiradas junto com os artefatos.

A SSA obteve os menores desempenhos nas métricas e com alto custo computacional, principalmente os modelos com 90 e 95% de variância. A hipótese levantada para o baixo desempenho da SSA-CNN deve-se que no processo de remoção do ruído, houve perda de informações relevantes que diminuíram o desempenho da CNN, assim como no caso da ICA.



Em relação aos melhores resultados e de modo a comparar-se as médias estatisticamente, efetuou-se o teste de hipótese ANOVA. Comparou-se a acurácia dos dois primeiros modelos da PCA com o controle, para isso, admitiu-se as seguintes hipóteses:

- $H_0 : \mu_{controle} = \mu_{PCA\ 99\%} = \mu_{PCA\ 95\%}$
- $H_1 : \mu_{controle} \neq \mu_{PCA\ 99\%} \neq \mu_{PCA\ 95\%}$


Com o nível de significância de 0,05 e valor-P igual a 0,155, não há evidências para se rejeita H_0 , logo não há diferença estatística significativa entre as médias. Com esse resultado evidencia-se a eficiência da PCA em preservar as informações no sinal após o redimensionamento.

Conclusão

A classificação de IM em sinais de EEG com eficiência é um grande desafio devido à baixa relação sinal-ruído e a variabilidade entre indivíduos. O desenvolvimento de novas técnicas e aperfeiçoamento das já existentes é importante, principalmente no tocante de proporcionar melhorias nas BCIs assistivas atuais, que podem contribuir para uma melhor qualidade de vida de pessoas com severas deficiências motoras.

Nesse estudo, demonstra-se que o emprego da PCA-CNN é proveitoso para classificação de IM, dispendo como principal benefício a diminuição do tempo de treinamento em 58,1% no caso da PCA 95%, acarretando em uma diminuição do custo computacional. Além disso, sem perda de desempenho estatisticamente da CNN em comparação o controle. Um bom balanceamento entre desempenho e custo computacional deve ser considerado, principalmente quando se planeja executar o modelo por várias vezes ou em tempo real, ou mesmo em alguma BCI assistiva que necessite de velocidade no processamento.

Para um trabalho futuro, em relação a ICA, uma mudança no método de escolha das suas componentes pode levar a remoção de artefatos sem perda de informações de IM. Em relação ao método SSA e seus modelos, uma mudança na forma de selecionar



suas componentes pode melhorar separação do sinal do ruído. Para ambas técnicas, o aperfeiçoamento pode refletir em uma melhora em suas métricas na CNN.


Por fim, conclui-se que esse estudo pode ser útil em relação à escolha de um método de processamento para ser usado em conjunto com uma rede neural, principalmente se seu uso for em tempo real ou em sistemas que fazem o uso de bateria.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Universidade Federal de Itajubá (UNIFEI).

Referências

1. Pfurtscheller G, Da Silva FL. Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical neurophysiology*. 1999 Nov 1;110(11):1842-57.
2. Pfurtscheller G, Müller GR, Pfurtscheller J, Gerner HJ, Rupp R. ‘Thought’–control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia. *Neuroscience letters*. 2003 Nov 6;351(1):33-6.
3. Craik A, He Y, Contreras-Vidal JL. Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of neural engineering*. 2019 Apr 9;16(3):031001.
4. Kobayashi, T., Kuriki, S., Principal component elimination method for the improvement of S/N in evoked neuromagnetic field measurements. *IEEE Transactions on Biomedical Engineering* 46, 951-958.
5. Agarwal S, Zubair M. Classification of Alcoholic and Non-Alcoholic EEG Signals Based on Sliding-SSA and Independent Component Analysis. *IEEE Sensors Journal*. 2021 Oct 15;21(23):26198-206.
6. Hendrycks D, Gimpel K. Gaussian error linear units (gelus). *arXiv preprint arXiv:1606.08415*. 2016 Jun 27.
7. Congedo M, Barachant A, Bhatia R. Riemannian geometry for EEG-based brain-computer interfaces; a primer and a review. *Brain-Computer Interfaces*. 2017 Jul 3;4(3):155-74.



8. Goldberger AL, Amaral LA, Glass L, Hausdorff JM, Ivanov PC, Mark RG, Mietus JE, Moody GB, Peng CK, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *circulation*. 2000 Jun 13;101(23):e215-20.
9. Gramfort A, Luessi M, Larson E, Engemann DA, Strohmeier D, Brodbeck C, Goj R, Jas M, Brooks T, Parkkonen L, Hämäläinen M. MEG and EEG data analysis with MNE-Python. *Frontiers in neuroscience*. 2013:267.
10. Loboda A, Margineanu A, Rotariu G, Lazar AM. Discrimination of EEG-based motor imagery tasks by means of a simple phase information method. *International Journal of Advanced Research in Artificial Intelligence*. 2014 Oct;3(10)..
11. Tangermann M, Müller KR, Aertsen A, Birbaumer N, Braun C, Brunner C, Leeb R, Mehring C, Miller KJ, Mueller-Putz G, Nolte G. Review of the BCI competition IV. *Frontiers in neuroscience*. 2012:55.
12. Pion-Tonachini L, Kreutz-Delgado K, Makeig S. The ICLabel dataset of electroencephalographic (EEG) independent component (IC) features. *Data in brief*. 2019 Aug 1;25:104101.
13. Pion-Tonachini L, Makeig S, Kreutz-Delgado K. Crowd labeling latent Dirichlet allocation. *Knowledge and information systems*. 2017 Dec;53(3):749-65.
14. SCCN. (n.d.). SCCN: Independent Component Labeling. Retrieved September 10, 2022, from <https://labeling.ucsd.edu/tutorial/labels>
15. Kai Ming Ting. 2011. *Encyclopedia of machine learning*. Springer. ISBN 978-0-387-30164-8.
16. Kim TK. Understanding one-way ANOVA using conceptual figures. *Korean journal of anesthesiology*. 2017 Feb 1;70(1):22-6.
17. Lawhern VJ, Solon AJ, Waytowich NR, Gordon SM, Hung CP, Lance BJ. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of neural engineering*. 2018 Jul 27;15(5):056013.