

Comparison of performance of scenarios with one and three brain-machine interfaces applied.

Francisco F. de S. Neto¹, Vitor da S. Jorge ², Cleison Daniel da Silva³

Faculdade de Engenharia Elétrica
Universidade Federal do Pará (UFPA) – Tucuruí, Pa – Brazil

francisco.neto@tucurui.ufpa.br, vitor.jorge@tucurui.ufpa.br,
cleison@ufpa.br

Abstract. *Brain-Machine Interfaces based on Motor Imagery (BCI-MI) allow device control independent of the use of peripheral nerves and muscles. This work proposes two scenarios, in order to compare their final performance. Among the differences between them are: the way the signal is windowed; the training of the BCI's and the classification, where a classification method is applied that makes use of a strategy of fusion of classifiers having a neural network as responsible for the final decision.*

Resumo. *Interfaces Cérebro-Máquina baseadas em Imagética Motora (ICM-IM) permitem o controle de dispositivos independente do uso de nervos e músculos periféricos. Este trabalho propõe dois cenários, com o intuito de comparar o desempenho final dos mesmos. Dentre as diferenças entre eles, estão: a forma em que é feito o janelamento do sinal; o treinamento das ICM's e a classificação, onde é aplicado um método de classificação que faz uso de uma estratégia de fusão de classificadores tendo uma rede neural como responsável pela decisão final.*

1. Introdução

Nas últimas duas décadas, o constante avanço em pesquisas nas áreas de neurociências, de instrumentação biomédica e de processamento digital de sinais têm proporcionado uma melhor compreensão do funcionamento do cérebro humano, bem como o aperfeiçoamento de instrumentos de medição de sinais biomédicos [Silva 2017]. Esses avanços são o que proporcionam o desenvolvimento de sistemas artificiais, que convertem as informações da atividade neural de um indivíduo em sinais de comando. As aplicações desse sistema são inúmeras, como por exemplo, a utilização no processo de reabilitação de indivíduos com a capacidade motora comprometida [Siqueira e Barbosa 2013].

Essa é uma das motivações que impulsionam o estudo e o desenvolvimento de Interfaces Cérebro-Máquina (ICM) baseados em Imagética Motora (IM): sistemas formados por cadeias de processamento de sinais associados à atividade elétrica cerebral e que proporcionam ao usuário o controle de dispositivos externos [Tayla et al 2019]. A imagética motora consiste na simulação mental de movimentos de membros do corpo e é caracterizada pela mudança no ritmo da atividade cerebral, denominada de Dessincronização Relacionada a Eventos (ERD). A intenção motora do indivíduo é

então traduzida a partir da variação de energia dos sinais medidos no escalpo do usuário da ICM, por meio de Eletroencefalografia (EEG) segundo [Seul-Kee et al 2019].

O ajuste dos parâmetros que compõem uma ICM-IM pode ser realizado em duas etapas: treinamento e validação. Na primeira etapa, os algoritmos que formam a ICM-IM, são calibrados com amostras de sinais de EEG contendo intenções motoras do usuário. Na etapa seguinte, a ICM-IM calibrada é testada a fim de distinguir e classificar corretamente a imagética motora do usuário, quando presente nos sinais de EEG [Jorge 2022].

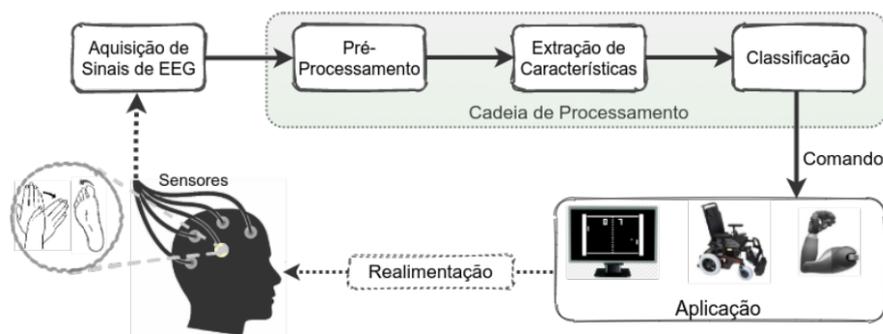


Figura 1. Funcional de um sistema ICM-IM. Nas etapas de aquisição e processamento são empregadas ferramentas que possibilitam o controle de aplicações a partir do reconhecimento de padrões nos sinais de EEG, adaptado de [Vilas Boas 2021].

Normalmente, em estudos de ICM-IM, em função do protocolo experimental adotado [Vilas Boas 2021], é utilizado apenas um trecho do sinal de EEG para que seja realizado o treinamento da ICM-IM, não utilizando os demais trechos do sinal de EEG coletado. Esses trechos são descartados com base no suposto de que por estarem mais distantes do instante de início do experimento na coleta do sinal, o estado de engajamento do indivíduo para realização da tarefa mental definida no protocolo experimental esteja baixo [Jorge 2022].

Porém, de acordo com [Feng et al. 2018], o tempo de latência durante um período de imagética motora varia entre as tentativas para cada participante, ou seja, a fixação do ponto de início da janela utilizada para realizar o ajuste da interface, em um único trecho do sinal para todos os participantes, pode levar à diminuição do desempenho do sistema. Além disso, os trabalhos de [Vilas-Boas et al 2020 ; Yangyang e Jin 2021] comprovam a forte presença de imagética motora nos trechos de sinais que normalmente não são usados para o treinamento e validação das ICM. Portanto, um dos objetivos deste trabalho é utilizar mais trechos do sinal coletado para realizar o ajuste das interfaces e verificar se a utilização de mais janelas para o treinamento da ICM melhora o desempenho final da classificação.

Dessa maneira, este artigo tem o objetivo principal de verificar e comparar o desempenho de dois cenários, que utilizam o mesmo sinal de EEG como base para análise, porém com estruturas de processamento e formas de treinamento distintas. Esses cenários podem ser descritos da seguinte forma: Cenário A é composto por três ICM em paralelo, com estruturas iguais, porém treinadas com três janelas distintas e sobreposição de 50%, com um atraso temporal entre elas. Ademais, este sistema possui um método de classificação que faz uso de uma estratégia de fusão de classificadores. A saída de decisão final, oriunda da rede neural aplicada, é baseada nos resultados de

classificação das três ICM, com o intuito de reduzir o risco de classificação incorreta; o Cenário B é composto por uma única ICM, que é treinada com os dados provenientes das três janelas citadas no cenário A. Tendo a classificação final do sistema sendo feita pelo classificador da interface, sem o uso da rede neural. Ambos os cenários comentados, tem o objetivo de realizar a classificação do sinal apresentado nas duas classes de imagéticas explanadas neste trabalho, imagética da mão esquerda e direita.

2. Procedimentos e metodologia

2.1 Protocolo experimental

A fim de prover um roteiro de coleta controlada, a implementação de um sistema de ICM-IM normalmente requer um protocolo experimental com eventos organizados cronologicamente a fim de permitir a obtenção de sinais de EEG em sincronia com a execução de tarefas cognitivas específicas [Silva 2017].

A sequência completa de instruções tem 8 segundos e é subdividida em 4 eventos. Primeiramente, um sinal sonoro na forma de beep é disparado e indica que a sequência de instruções teve início; concomitante ao sinal sonoro é apresentada no monitor uma imagem em forma de cruz, que fica visível por 2 segundos. Em seguida, destina-se um intervalo de 1 segundo em que o usuário deve aguardar o aparecimento de uma imagem no monitor, a imagem corresponde a uma 'dica'. A dica é exibida durante 1 segundo e é apresentada por meio de imagens de setas, direcionadas para a direita ou para a esquerda, correspondendo a imagética motora que deve ser realizada pelo usuário nos 4 segundos subsequentes [Tayla et al 2019].

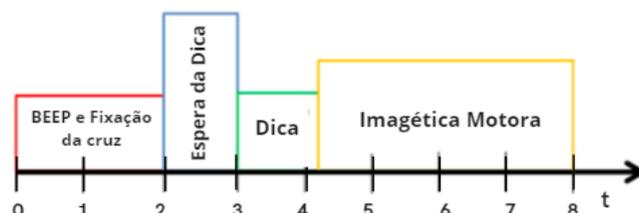


Figura 2. Sequência de instruções para o desenvolvimento do protocolo experimental, o qual tem duração de 8 segundos e é subdividido em 4 partes.

O protocolo descrito é o mesmo aplicado na aquisição de sinais do conjunto de dados da Competição IV de ICM, que foi escolhido para o desenvolvimento deste trabalho. Desse conjunto, que contém 9 sujeitos, são selecionadas as informações de duas classes de IM: mão esquerda (ME) e mão direita (MD). Cada sujeito fornece 144 tentativas de realizar a imagética motora para cada classe, sendo que 72 tentativas formam o conjunto utilizado para treinamento e a segunda parte é utilizada para a validação. Cada imagética motora tem 4 segundos de duração amostrados a 250 Hz [Vilas Boas 2021].

2.2 Janelamento do sinal de EEG

Tendo em vista a sequência do protocolo experimental, Figura 2, é esperado que o sujeito esteja com um grau de engajamento mais elevado em realizar a imagética motora logo após o aparecimento da 'dica', por conta disso a janela adotada normalmente nos

estudos de ICM tem a largura de 2 segundos, começando 0,5 segundo após o aparecimento da 'dica', desprezando o sinal gerado posteriormente.

Com o objetivo de melhor aproveitar o sinal gerado no protocolo experimental e verificar como isso afeta o desempenho final do sistema, no estudo presente é adotado 3 janelas após o aparecimento da 'dica' (três segundos após o início do protocolo). Com largura de dois segundos, a primeira janela começa logo após o aparecimento da 'dica', a janela subsequente tem início um segundo depois do marco inicial da primeira, com a mesma organização a terceira janela possui a mesma distância temporal da segunda. Ou seja, é dado origem a 3 janelas com larguras iguais, porém em sessões de tempo distintas.

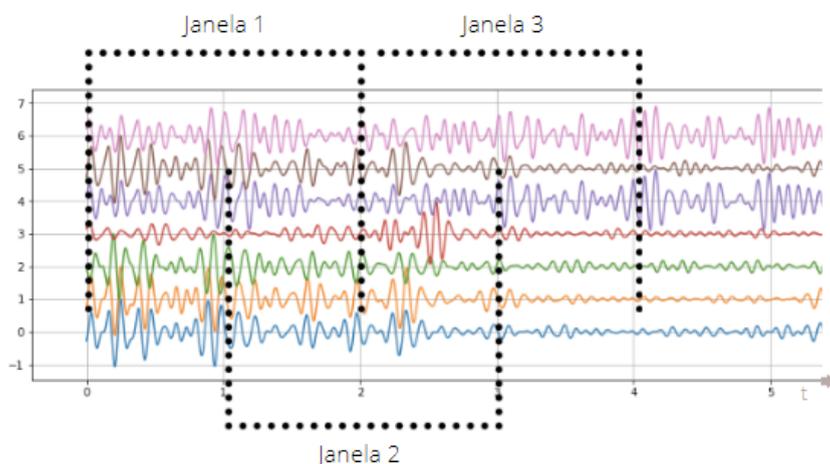


Figura 3. Esquema de janelamento do sinal de EEG. São três janelas com duração de 2 segundos e com sobreposição de 50% obtidas a partir do instante 0 segundo, referente ao desaparecimento da dica.

Cada janela adotada é responsável pelo treinamento de uma ICM, fazendo com que se obtenha 3 ICM especialistas no intervalo de tempo em que a janela utilizada no seu treinamento foi destacada.

2.3 Filtragem temporal dos sinais de EEG

Os sinais de EEG possuem baixa relação sinal ruído, portanto, são suscetíveis a diversos tipos de ruídos e artefatos [Teplan 2002]. Além dos biopotenciais cerebrais, ruídos associados a outras partes do corpo são capturados, como os provenientes de: Atividade cardíaca; contrações musculares; movimento ocular brusco etc. Por ser de fácil caracterização espectral e por ter origem técnica, este tipo de ruído frequentemente intitulado ruído de circuito elétrico ou simplesmente ruído de rede, é comumente removido pela maioria dos amplificadores profissionais por meio de filtros do tipo Notch ou rejeita faixa [Teplan 2002].

Dessa forma, um filtro digital passa-faixa de Resposta Impulsiva Infinita (IIR) de 5° ordem é adotada neste trabalho, para se obter a versão filtrada do espectro dos sinais na faixa de frequência entre 8 e 30Hz a qual foi dividida em 10 sub-bandas com largura de 4 Hz cada: 8-12Hz, 10-14Hz, 12-16Hz, 14-18Hz, 16-20Hz, 18-22Hz,

20-24Hz, 22-26Hz, 24-28Hz, 26-30Hz. A escolha pela implementação deste conjunto de sub-bandas provém de estudos que afirmam que há sub-bandas dentro do intervalo de frequência de 8-30Hz que apresentam maior relevância na classificação de imagética motora [Nicolas-Alonso 2012].

Importante destacar que que na faixa de frequência entre 8Hz e 30Hz encontram-se as bandas (ritmos cerebrais) mu e beta, respectivamente. É nesses ritmos que o fenômeno da imagética motora está presente de forma mais evidente. São os fenômenos de sincronização e dessincronização relacionados ao evento.

2.4 Filtragem espacial dos sinais de EEG

Devido ao efeito *smearing* do crânio (também conhecido como efeito de condução de volume), a atividade elétrica cerebral se espalha por regiões subjacentes à origem, o que provoca a captação redundante dos sinais nos múltiplos canais de EEG no escalpo, o que gera uma imagem bastante turva da atividade cerebral [Lotte 2010]. Com isso, é comum a aplicação de filtros espaciais nos sinais de EEG. Para tal, o algoritmo denominado Padrões Espaciais Comuns (Common Spatial Pattern - CSP) é bastante utilizado, uma vez que a distância da dispersão média entre duas classes de IM é reduzida o quanto possível a fim de ressaltar suas características e facilitar a classificação [Wang 2018].

No presente trabalho, são utilizados 4 pares de CSP, os quais são responsáveis por favorecer o desempenho de classificação satisfatórios dos sinais. O método parte do princípio de que, durante a realização de uma tarefa motora específica, os sinais registrados por canais em um dos hemisférios do cérebro apresentam uma variância de energia significativamente diferente em relação à energia dos sinais registrados por canais no hemisfério oposto (contralateralidade) [Tayla et al 2019].

2.5 Classificação dos sinais de EEG

Com o agrupamento dos padrões que descrevem a intenção motora do indivíduo nos vetores de características, uma etapa fundamental no processamento dos sinais de EEG em sistemas de ICM-IM consiste na classificação desses vetores de modo a associá-los à rótulos de classes de IM [Nam et al 2018].

Para o estudo em questão foram adotados dois classificadores, o de Análise de Discriminantes Lineares (LDA) e o de Máquina de Vetores de Suporte (SVM). O algoritmo LDA realiza um mapeamento linear dos vetores de característica para o espaço de decisão. Esse mapeamento determina um hiperplano de separação entre os vetores de características de classes diferentes. Uma vez que, múltiplas soluções poderiam ser encontradas em diferentes dimensões do espaço de decisão de forma a estabelecer a separação entre duas classes, a ideia central do SVM, para além de encontrar os parâmetros do modelo de separação entre duas classes, é encontrá-los para um hiperplano em particular cuja margem para os padrões de treinamento mais próximos é a máxima possível [Lal 2002].

A classificação é dada de forma distinta nos dois cenários apurados. No cenário A, as classificações das três ICM são usadas como referência de decisão para a rede neural aplicada no sistema, com o intuito de utilizar o máximo de informação presente no período da imagética motora. Em contrapartida, a classificação do cenário B é dada por um único SVM, ajustado com uma única janela de EEG. Porém, em ambos os cenários, a classificação do sinal está vinculada à intenção motora de realizar o movimento da mão esquerda e direita.

3. Estrutura do sistema ICM

3.1 Sistema Interface Cérebro-Máquina - ICM

Em ambos os sistemas destacados para comparação de desempenho, a estrutura da ICM presente neles é idêntica. O que difere uma ICM da outra é a janela escolhida para o ajuste dos algoritmos.

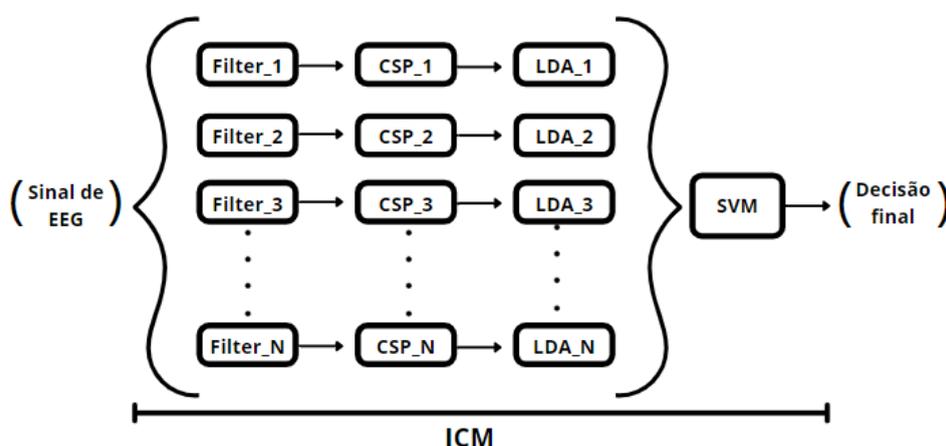


Figura 4. Esquema representativo dos componentes que juntos formam a ICM usada neste estudo.

Como pode ser visto na Figura 4, a ICM adotada no estudo possui um filtro digital passa-faixa de Resposta Impulsiva Infinita (IIR) de 5° ordem, com 10 sub-bandas de 8 a 30 Hz e com sobreposição de 50%. Conectado a cada sub-banda, 4 pares de CSP fazem a filtragem espacial do sinal.

O LDA atua como um meta-classificador de sub-banda a fim de pontuar as características em cada uma das 10 sub-bandas e obter uma saída única. Após a obtenção das 10 pontuações LDA, cada uma representando uma característica de sub-banda, essas são agrupadas de modo a compor um vetor único de meta-classificações para enfim serem enviadas para classificação final [Vilas Boas 2021]. Sendo este classificador final o SVM, como pode ser visto na Figura 4.

3.2 Rede neural Multilayer perceptron (MLP)

Os trabalhos em redes neurais artificiais, usualmente denominadas “redes neurais”, têm sido motivados desde o começo pelo reconhecimento de que o cérebro humano processa

informações de uma forma inteiramente diferente do computador digital convencional. O cérebro é um computador altamente complexo, não-linear e paralelo. O sinal de entrada se propaga para frente através da rede, camada por camada. Estas redes neurais são normalmente chamadas de perceptrons de múltiplas camadas (*multilayer perceptron*, MLP). Os MLP têm sido aplicados com sucesso para resolver diversos problemas difíceis, através do seu treinamento de forma supervisionada com um algoritmo muito popular conhecido como algoritmo de retropropagação de erro (*error backpropagation*), este algoritmo é baseado na regra de aprendizagem por correção de erro [Haykin 2001].

A configuração com duas camadas ocultas é adotada para a estrutura da MLP, o número de neurônios nestas camadas sofre algumas variações. Primeiramente foram fixados 5 neurônios na primeira camada e o número de neurônios na segunda varia com o passo de 5, no intervalo de 5 a 30 neurônios. Em um segundo momento, segue a mesma ideia, porém com a variação do número de neurônios na primeira camada oculta. Dando origem a configuração A e B na sequência citada anteriormente.

Há diferentes formulações possíveis para a função de ativação, sendo duas funções sigmóides as mais comumente adotadas para classificação, tais quais: logística e tangente hiperbólica [Vilas Boas 2021]. No presente trabalho a função de ativação usada foi a logística.

3.3 Cenários de comparação

Tendo em vista as estruturas e características dos componentes citados previamente, a configuração do cenário A pode ser visualizada na Figura 5-a, onde é possível observar a presença de 3 ICM que possuem etapas como: filtragem temporal, filtragem espacial e classificação idênticos. No entanto, o sinal entregue na etapa de treinamento para cada ICM é diferente, fazendo com que cada ICM seja especialista no intervalo de tempo do sinal entregue ao mesmo no momento do seu treinamento, dando origem a três sistemas especialistas em janelas de tempo diferente. A rede neural recebe um vetor contendo a classificação dos três sistemas, a partir disso a MLP retorna à classificação final do sistema, informando qual a intenção motora do indivíduo, ou seja, a classificação varia entre imagética da mão esquerda e imagética da mão direita. Tendo valores de acurácia diferente para cada variação de parâmetros de sua estrutura, como pode ser visto na seção 3.2.

A representação do cenário B é mostrada na Figura 5-b. Este sistema, diferente do anterior, possui apenas um ICM global que é treinado com os dados referentes às 3 janelas que são destacadas anteriormente. É esperado que o sistema com essa configuração não apresente resultados de desempenho melhores que as ICM que são treinados com estas janelas individualmente. Pois, ao entregar todos os dados do sinal para um único sistema, também é entregue o ruído presente no mesmo, o que afeta diretamente o desempenho do sistema como um todo.

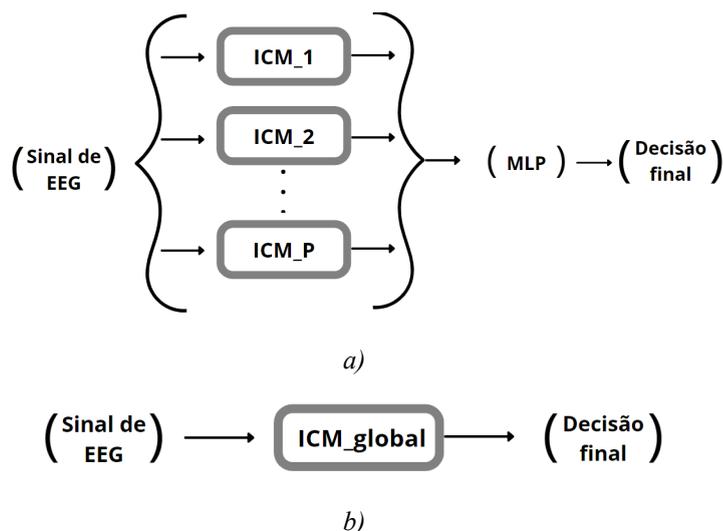


Figura 5. Esquema representativo do sistema de classificação dos sinais de EEG; a) Cenário A, composto por três ICM e uma rede neural; b) Cenário B com a ICM global, treinada com os dados provenientes das três janelas destacadas.

4. Resultados e Discussão

A métrica escolhida para avaliar o desempenho dos sistemas descritos na secção 3.3 é a acurácia. A acurácia é uma medida efetiva da taxa de acerto na classificação ao relacionar o número de exemplos corretamente classificados com o número total de exemplos realizados durante um experimento [Silva 2017]. Com isso, o desempenho do cenário B, sistema composto pela ICM global, é medido e destacado na Tabela 1. Ademais, a média de desempenho das três ICM do cenário A é destacado a Tabela 2 e o da rede neural é medido e destacado na Tabela 3, vale ressaltar que os parâmetros da MLP são modificados 5 vezes, citados previamente na secção 3.2.

Tabela 1. Acurácia ICM global, referente ao cenário B

Acurácia ICM global (%)								
1	2	3	4	5	6	7	8	9
85,42	53,01	89,58	54,17	59,26	64,81	80,09	91,44	84,49

Tabela 2. Acurácia das três ICM treinadas com suas respectivas janelas, referente ao cenário A

Acurácias (%)										
Sujeitos		1	2	3	4	5	6	7	8	9
Média de acurácias das ICM especialistas (%)	ICM_1	84,26	53,01	92,13	56,94	56,94	68,06	72,92	87,73	79,40
	ICM_2	82,41	53,93	87,73	50,47	61,57	60,42	81,48	90,97	85,18
	ICM_3	82,18	50,93	82,18	51,62	50,23	63,20	75,46	91,21	60,42
Desvio Padrão		0,931	1,254	4,071	2,818	4,655	3,157	3,589	1,586	10,57

Tabela 3. Acurácia da rede neural, seguindo os parâmetros destacados na seção 3.2, configuração a) e configuração b)

Sujeito	Acurácias (%)									
	MLP_1		MLP_2		MLP_3		MLP_4		MLP_5	
	Confg. a)	Confg. b)	Confg. a)	Confg. b)	Confg. a)	Confg. b)	Confg. a)	Confg. b)	Confg. a)	Confg. b)
1	85,64	86,34	85,64	85,87	85,87	86,11	87,26	86,11	85,41	85,87
2	54,16	54,16	54,39	54,39	54,39	54,62	54,16	53,93	53,93	54,16
3	88,42	85,18	88,42	87,96	86,80	88,65	87,50	86,57	87,03	88,88
4	55,78	55,32	55,55	55,09	55,78	55,09	56,48	55,55	56,25	55,32
5	64,12	63,88	64,12	63,65	64,12	62,96	63,65	63,42	63,19	64,12
6	65,97	65,74	65,74	65,82	65,74	65,74	65,74	65,97	65,74	65,74
7	70,13	71,99	70,13	72,22	73,14	72,22	73,37	73,14	72,91	71,75
8	92,12	92,36	92,36	92,36	92,36	92,36	92,12	92,12	92,36	92,59
9	78,93	78,93	80,78	81,01	80,32	86,11	78,47	80,55	79,39	79,62

Ao realizar uma comparação experimental com os resultados obtidos, é possível evidenciar que, a acurácia de saída da rede neural, que é baseada nos resultados de classificação das ICM especialistas, dependendo da configuração no número de neurónios, é superior a decisão tomada pela ICM global na maioria dos casos, não acontecendo isso apenas para os participantes de número 3, 7 e 9, onde a acurácia do cenário A se manteve igual ou inferior a acurácia da ICM global, independente da configuração usada. Destaca-se que, quando utilizado a MLP_4 na configuração a), o sujeito 1 apresentou uma acurácia de 87,26% e o sujeito 5 utilizando a MLP_3 na configuração a), apresentou uma acurácia de 64,12%, enquanto isso, o sistema com a ICM global apresentou, respectivamente, acurácias de 85,42% e 59,26%. Sendo esses, os sujeitos que tiveram a melhora mais relevante no experimento.

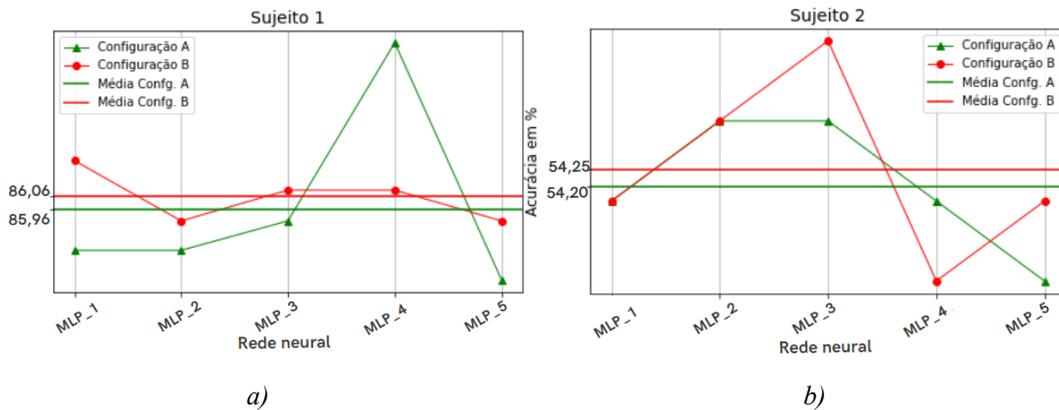


Figura 6. Desvio das acurácias para a média de cada configuração, para: a) sujeito 1; b) sujeito 2.

Somado a isso, uma segunda análise a ser feita além de comparar a decisão final da rede neural com o sistema que possui uma única ICM, é a comparação da média das acurácias das ICM especialistas (Tabela 2) com as acurácias da ICM global (Tabela 1). Ao realizar essa análise, é possível verificar que os sujeitos de número 2, 3, 4, 5, 6, 7 e 9 apresentam melhor acurácia no sistema que possuem as ICM especialistas, evidenciando essa melhora em pelo menos uma das três interfaces do sistema.

Para complementar os resultados, na Figura 7 é destacado duas matrizes de confusão, referente aos sujeitos que obtiveram o maior e menor valor de acurácia. O melhor desempenho é referente ao sujeito 8 quando aplicado a MLP com 5 neurônios na primeira camada e 30 na seguinte, em contrapartida, o pior desempenho é resultado do sujeito 2 com a MLP que possui 30 neurônios na primeira camada oculta e 5 na segunda.

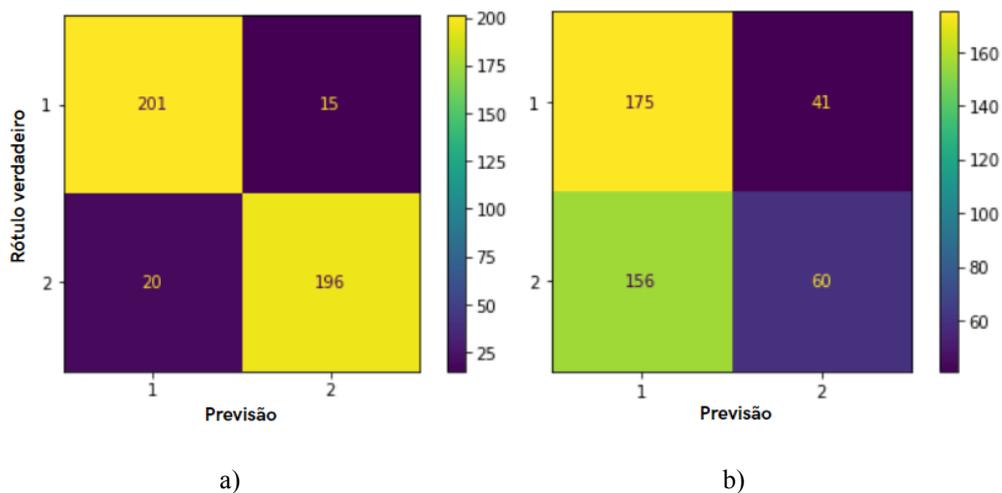


Figura 7. Matriz de confusão para o sujeito que obteve melhor e pior desempenho consecutivamente: a) sujeito 8 na MLP 5_B; b) sujeito 2 MLP 5_A.

5. Conclusão

Conclui-se que, a utilização da rede neural, que tem o objetivo de reduzir o risco de classificação incorreta, usando as classificações das ICM especialistas como referência foi eficaz. Visto que, a acurácia da rede foi superior à acurácia da ICM global para apenas 6 sujeitos, sendo mais da metade do número de sujeitos que completam o banco de dados. A adição desta rede na configuração e parâmetros vistas nesse artigo, se mostra perspicaz, pois a sua adição aumenta a acurácia do sistema como um todo mesmo que de forma suave em alguns casos.

Outrossim, ao comparar o desempenho da ICM global com as ICM especialistas do cenário A, a configuração com a rede neural se mostra novamente mais eficaz, com acurácia superior à do ICM global para sete dos nove sujeitos que compõem o banco de dados. Um dos pontos que influenciaram neste resultado, está vinculado a forma em que a ICM em questão é treinada, ao entregar os dados referentes às três janelas do sinal de EEG a uma única ICM, também é entregue todo o ruído contido nesses dados, o que atrapalha e influencia negativamente a acurácia final.

Uma análise a ser feita com os resultados expostos, é que a acurácia das interfaces treinadas com as primeiras janelas do sinal de EEG, logo após a dica do protocolo experimental, se mostram superiores às acurácias das demais ICM e da rede neural para a maioria dos sujeitos. Evidenciando que, o sujeito ao realizar o protocolo experimental, está mais engajado em realizar a imagética motora logo após o aparecimento da dica, fazendo com que, a ICM que esteja sendo treinado com a janela que contemple esse intervalo de tempo, obtenha um desempenho melhor que os demais que são treinados com outras janelas.

Referências

- Feng J, Yin E, Jin J, Saab R, Daly I, Wang X, Hu D, Cichocki A (2018). “Towards correlation-based time window selection method for motor imagery BCIs”. *Neural Netw.* Jun;102:87-95. doi: 10.1016/j.neunet.2018.02.011. Epub 2018 Mar 2. PMID: 29558654.
- G. Pfurtscheller, C. Neuper (2001). “Motor imagery and direct brain-computer communication,” *Proc. IEEE*, vol. 89, no. 7, pp. 1123–1134.
- Haykin, Simon. (2001) “Redes neurais: princípios e práticas”. Trad. Paulo Martins Engel. – 2.ed. – Porto Alegre: Bookman.
- J. Jin, Y. Miao, I. Daly, C. Zuo, D. Hu, and A. Cichocki (2020) “Correlation-based channel selection and regularized feature optimization for MI-based BCI,” *Neural Netw.*, vol. 118, pp. 262–270.
- Jorge, V. S. (2022) “Análise da utilização de interfaces-cérebro máquina em paralelo para a classificação da imagética motora”. Trabalho de Conclusão de Curso, Orientador: Prof. Dr. Cleison Daniel Silva — Universidade Federal do Pará (UFPA), Tucuruí.

- Lal, T. N. et al. (2004) “Support vector channel selection in BCI”. IEEE transactions on biomedical engineering, IEEE, v. 51, n. 6, p. 1003–1010.
- Lotte, F.; Guan, C. (2010) “Spatially regularized common spatial patterns for EEG classification”. IEEE, 20th International Conference on Pattern Recognition. p. 3712–3715.
- Nicolas-Alonso, L. F. and Gomez-Gil, J. (2012) “Brain computer interfaces” a review Sensors (Basel, Switzerland), v. 12, n. 2, p. 1211–79. ISSN 1424-8220.
- Seul-Kee Kim, Da-Hye Kim, Laehyun. (2019) “Optimization method of error-related potentials to improve MI-BCI performance”. IEEE, 7th International Winter Conference on Brain-Computer Interface (BCI).
- Silva, C. D. (2017) “Processamento de sinais de EEG para classificação de tarefas motoras em sistemas de interface cérebro-máquina”. Orientador: Alexandre Trofino Neto. 189 p. Tese (Doutorado em Engenharia de Automação e Sistemas) — Universidade Federal de Santa Catarina (UFSC), Florianópolis.
- Silverthorn, D. U. (2017) “Fisiologia Humana: uma abordagem integrada”. 7. ed. [S.l.]: Porto Alegre: Artmed editora. ISBN 978-8-5388-0532-8.
- Siqueira, A. O; Barbosa, R. F (2013). “Terapia por Contensão Induzida e Treino Mental na Função de Membro Superior Pós-AVC”. Rev Neurocienc. 21(2):193-201.
- Tayla de J. Lopes, William Machado, Jhoanyn V. F. Calvino , Vitor M. Vilas-Boas, Cleison D. Silva. (2019). “Interface Cérebro-Máquina baseada em Imagética Motora: Estudo comparativo da quantidade de canais de EEG”. Anais do 14 Congresso Brasileiro de Inteligência Computacional.
- Teplan, M. (2002) “Fundamentals of EEG measurement”. Measurement science review, , v. 2, n. 2, p. 1–11. ISSN 1335-8871.
- V. M. Vilas-Boas, V. da S. Jorge, C. D. Silva (2020). “Towards ideal time window for classifying motor imagery in brain-computer interfaces”. Symposium on Knowledge Discovery, Mining and Learning, KDMILE 2020.
- Vilas Boas, Vitor Mendes (2021). “AutoBCI : interface cérebro-máquina com configuração hiperparamétrica automatizada”. Orientador(a): Prof. Dr. Cleison Daniel Silva. Núcleo de Desenvolvimento Amazônico em Engenharia, Programa de Pós-Graduação em Computação Aplicada, UFPA, Tucuruí.
- Wang, M. (2018) “A wearable SSVEP-based BCI system for quadcopter control using head-mounted device”. IEEE Access, , v. 6, p. 26789–26798. ISSN 2169-3536.
- Nam, C. S.; Nijholt, A.; Lotte, F. (2018) “Brain-computer interfaces handbook: technological and theoretical advances”.
- Yangyang Miao, Jing Jin, Ian Daly, Cili Zuo, Xingyu Wang (2021). “Learning Common Time-Frequency-Spatial Patterns for Motor Imagery Classification”. IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 29.