

Análise de diferenças entre sinais de EEG de indivíduos distintos

A. Hauer¹, D.P.Campos², E.Krueger³, J.J.A.Mendes Junior¹, H.S.Lopes¹ and A.E.Lazzaretti¹

¹ Graduate Program in Electrical and Computer Engineering, Federal University of Technology - Paraná (UTFPR), Curitiba, PR, Brazil

² Graduate Program in Biomedical Engineering, Federal University of Technology - Paraná (UTFPR), Curitiba, PR, Brazil.

³ Department of Anatomy, State University of Londrina (UEL), Londrina, PR, Brazil.

Abstract— Aplicações envolvendo o reconhecimento de padrões para Eletroencefalografia (EEG) são consideradas tarefas complexas principalmente devido comportamento não estacionário do sinal. Essa característica afeta o desenvolvimento de sistemas de classificação em Interfaces Cérebro-Computador voltados para auxílio em dispositivos de reabilitação, pois o sinal adquirido de uma mesma condição apresenta diferenças tanto entre indivíduos quanto em diferentes aquisições para um mesmo indivíduo. Assim, há duas principais formas de abordagens empregadas para classificá-los: calibrar e testar com os sinais provenientes apenas do usuário final ou buscar uma única solução final, mais generalizada, que possa ser aplicada independente do usuário. Dessa forma, esse trabalho apresenta uma avaliação entre a similaridade nos sinais de EEG para diferentes indivíduos durante a execução de uma mesma tarefa em um sistema de classificação. Os dados utilizados foram adquiridos por uma base de dados de competição e foram avaliados em relação a sua similaridade (utilizando o método *Dynamic Time Warping*) e pela classificação por utilizando *Common Spatial Pattern* e Análise de Discriminantes Lineares e Máquinas de Vetores Suporte (SVM). Os dados foram submetidos a quatro análises diferentes durante a separação dos conjuntos de treinamento e teste para as seis classes relacionadas com movimentação dos dedos, mãos e braços. A análise de similaridade mostrou que a maioria das classes possuem distâncias similares, tanto entre aquisições quanto para indivíduos. Isso foi refletido na etapa de classificação, na qual o classificador baseado em SVM obteve as maiores taxas de acerto. As maiores acurácias foram obtidas com a separação dos dados em treinamento e teste de forma isolada. Entretanto, os resultados obtidos foram estatisticamente similares à separação das instâncias de treinamento com todos os indivíduos (exceto um) e testando com um indivíduo não apresentado na fase de treinamento, permitindo o desenvolvimento de estratégias com maior generalização.

Keywords— Eletroencefalografia, Análise de Similaridade, Reconhecimento de Padrões,

I. INTRODUÇÃO

Interfaces cérebro-computador (BCIs, do inglês *Brain-Computer Interfaces*) baseadas em eletroencefalogramas (EEGs) são uma tecnologia amplamente pesquisada e empregada, principalmente no âmbito de recuperação do movi-

mento de membros em indivíduos que sofreram danos no sistema nervoso [1, 2]. De modo geral, os sistemas propostos para esta aplicação consistem em um conjunto de aquisição de sinais de EEG, que alimenta um processador. Este último é responsável por classificar a intenção do movimento e controlar um atuador que, por sua vez, efetua o movimento requerido pelo usuário [3].

A tarefa de reconhecimento de padrões para EEG é complexa devido aos sinais apresentarem uma baixa relação sinal ruído, alta sensibilidade a artefatos de estímulo e comportamento não estacionário. Ainda, o comportamento não estacionário ocorre entre indivíduos e entre aquisições de um mesmo indivíduo, dificultando ainda mais o reconhecimento destes sinais [4].

Para a classificação de sinais de EEG focando em aplicações de recuperação motora, há duas principais opções. Na primeira, o sistema é calibrado e testado especialmente para o usuário final. Apesar de pesquisas apontarem resultados promissores relacionados à qualidade de classificação atingida com esta abordagem [5, 6], ela não permite o desenvolvimento de soluções comerciais generalizadas. A segunda opção trata-se do desenvolvimento de uma solução geral, com classificadores já treinados [7]. Esta opção reduziria o tempo de processamento inicial e definição das técnicas e métodos de classificação (*setup*) [7, 6], e seria comercializável com maior facilidade. Apesar de a última opção ser motivada por razões de alta relevância, o seu desempenho pode ser insuficiente para aplicação em soluções reais.

Os problemas supracitados estão relacionados, principalmente, à natureza do sinal de EEG. Além disso, como a aquisição destes sinais envolve mais de um canal — apresentando alta dimensionalidade — com baixas amplitudes, técnicas de pré-processamento são necessárias antes das etapas de reconhecimento de padrões. Filtros passa-banda têm demonstrado contribuição no aumento da acurácia de classificação [8, 9], bem como para a redução dos artefatos de movimentos do sinal [10].

Partindo dessa premissa, este trabalho apresenta uma investigação de similaridades nos padrões de EEG de diferentes indivíduos durante a realização de uma mesma tarefa. Para tal, utiliza-se o método *Dynamic Time Warping* (DTW),

além de dois classificadores comumente utilizados na literatura da área [11, 12, 13]. Ademais, escolheu-se utilizar uma base de dados pública, sendo esta gerada por [14] e publicada como competição em [15]. Foram aplicadas técnicas pré-processamento e de extração de características espaciais aos sinais antes da etapa de classificação. Métricas para avaliar a qualidade da classificação foram utilizadas para poder verificar todo o processo de reconhecimento de padrões.

II. MATERIAIS E MÉTODOS

A Figura 1 apresenta os passos seguidos neste trabalho. As demais particularidades são apresentadas em cada uma das seções a seguir.

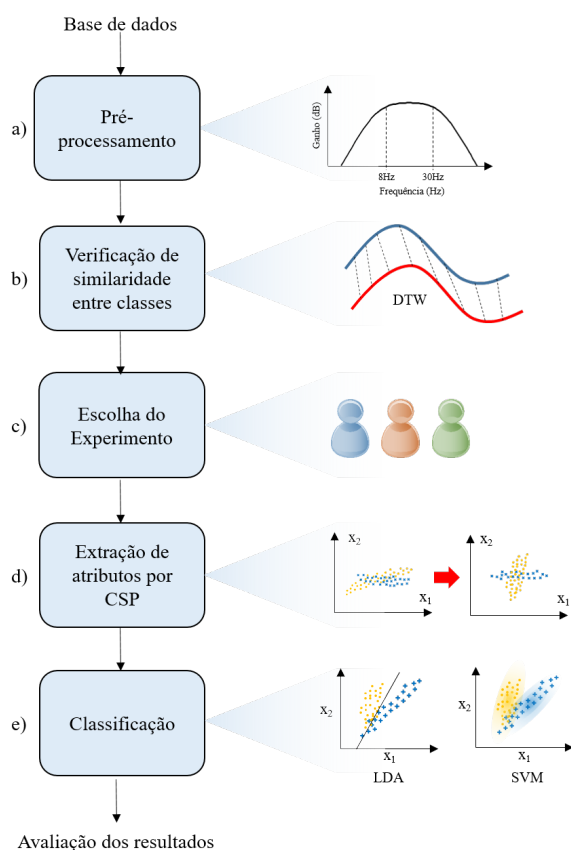


Fig. 1: Etapas de processamento para a avaliação proposta. Após o pré-processamento por meio de um filtro passa-banda (a), foi verificada a similaridade entre classes usando DTW (b). Posteriormente, os conjuntos de treinamento e teste foram separados em 4 experimentos (c). Atributos foram extraídos por meio da técnica de CSP (d), classificados usando LDA e SVM (e) e os resultados obtidos são avaliados.

A. Base de dados e pré-processamento

A base de dados utilizada possui sinais de 32 canais de EEG, adquiridos de 12 voluntários com uma taxa de amostragem de 500 Hz [14]. Cada voluntário desenvolveu 8 séries com aproximadamente 30 repetições do movimento de *Grasp-and-Lift* (GAL), contendo seis classes de movimentação dos dedos, das mãos e dos braços. Durante as aquisições, os indivíduos foram orientados a seguir a seguinte rotina: aproximar a mão de um objeto com textura e peso imprevisito (com início indicado em tempo aleatório), segurar com o polegar e o indicador o objeto, levantá-lo, mantê-lo levantado por dois segundos e colocá-lo na posição inicial para enfim, soltá-lo.

De acordo com a competição [15], os eventos a serem classificados são:

1. Movimento da mão para pegar o objeto;
2. Toque do primeiro dedo no objeto;
3. Aperto do objeto pelos dedos;
4. Objeto levantado;
5. Retorno do objeto à posição inicial;
6. Objeto solto.

Os sinais passaram pelo primeiro estágio do pré-processamento, composto de filtro passa-baixa de 4ª ordem com aproximação de Butterworth, conforme apresentado na Figura 1a. Este filtro, com frequências de corte entre 8 e 30 Hz, foi usado para delimitar a banda de frequência do sinal de EEG [9, 10].

B. Verificação de similaridade entre classes

Como os sinais adquiridos da realização são de natureza fisiológica, foi necessário avaliar o seu comportamento para verificar se seguem um certo padrão de similaridade, tornando possível a sua classificação. Em relação a este tipo de tarefa, dificilmente dois sinais fisiológicos são idênticos; porém, podem conter um grau de similaridade muito grande. Esta similaridade, que pode ou não indicar uma condição específica, auxilia no desenvolvimento de sistemas de classificação mais precisos [16, 17]. A forma mais comum de medição do grau de semelhança entre duas séries temporais é baseada no cálculo de distância, como a distância euclidiana. Entretanto, este tipo de procedimento pode não fornecer resultados corretos para sinais que são dessincronizados ou defasados entre si. Para resolver este problema, podem ser aplicados métodos como *Dynamic Time Warping* (DTW) [18, 19]. Na DTW, os sinais são comprimidos ou esticados ao longo do eixo temporal de modo que seja possível compará-los, produzindo uma medida de similaridade.

dade mais apurada para séries que tenham formatos similares e que não estejam sincronizadas.

O cálculo da distância entre séries temporais baseados na DTW foi empregado conforme proposto por [20] para avaliar a discrepâncias entre as aquisições dos indivíduos (Figura 1b). Além disso, avaliou-se a distância euclidiana entre os centróides, calculada a partir da média de centróide de cada indivíduo para cada classe avaliada.

C. Separação dos dados para classificação

Neste trabalho, foram divididos 4 experimentos de classificação a fim de comparar a variação na qualidade da classificação (Figura 1c). Estes foram:

1. Treinar e testar com indivíduos isoladamente — abordagem mais comum na literatura, *e.g.* [21] —, objetivando uma base de comparação;
2. Treinar com um indivíduo e testar com todos os indivíduos restantes;
3. Treinar com todos os indivíduos (exceto um) e testar com o indivíduo restante — estratégia *leave-one-out* [22] —;
4. Treinar com todos os indivíduos (exceto um) e todas as séries (exceto uma do indivíduo restante) e testar com a série restante do indivíduo restante — similar a estratégia *leave-one-out*, com a ressalva de haver adaptação ao usuário final [23].

D. Extração de Atributos

Posteriormente, a técnica de *Common Spatial Pattern* (CSP) foi utilizada para a extração de atributos com seis filtros espaciais [24, 25, 26], treinados com uma janela de eventos de 1 s (Figura 1d). A duração da janela de eventos foi escolhida por meio de uma série de testes com um classificador LDA sem ajuste de parâmetros. Como métrica de avaliação, foi calculada a Área sobre a Curva (AUC, *Area under the Curve*) obtida pela curva de Característica de Operação do Receptor (ROC, *Receiver Operating Characteristic*). Os resultados destes testes são apresentados na Tabela 1. Pode-se notar que não há uma grande diferença observada entre os todos os comprimentos de janela, porém as janelas com comprimento equivalentes a 1 s apresentam distribuições com médias ligeiramente maiores que as demais.

Posteriormente, aplicou-se um filtro de suavização aos atributos extraídos, definido pela convolução entre uma função vagão de tamanho fixo e o sinal de entrada. A suavização após a extração de atributos é justificada pelo aumento da área da curva de ROC, observável pelos resultados apresentados na Tabela 2. Além disso, a Tabela 2 mostra

Tabela 1: Efeito do comprimento da janela de eventos usado no treinamento do extrator de atributos.

Comprimento da janela (s)	ROC AUC	
	Média	Variância
0,5	0,6674	0,0679
1	0,6761	0,0685
2	0,6746	0,0683
3	0,6648	0,0716
4	0,6593	0,078

Tabela 2: Efeito do comprimento da janela de suavização aplicada após a extração de atributos

Comprimento da janela(s)	ROC AUC	
	Média	Variância
0	0,5940	0,0463
100	0,6659	0,0717
200	0,6768	0,0758
300	0,6775	0,0769
400	0,6691	0,0792

que uma janela com comprimento de 300 amostras para uma função de suavização pode fornecer uma média resultante maior que os demais comprimentos avaliados, estando adequado para esta aplicação.

E. Classificação

Os classificadores *Linear Discriminant Analysis* (LDA) e *Support Vector Machine* (SVM) foram os algoritmos de reconhecimento de padrões escolhidos para essa aplicação, pois são os mais comuns em aplicações de BCI, com baixo custo computacional, tornando-os apropriados para classificação em tempo real. Em todo o processo de treinamento, o método de *k-fold* para validação cruzada foi implementado.

Para o classificador LDA, os parâmetros de variação de encolhimento e o método de solução foram escolhidos por meio de *Grid Search*. A variação do encolhimento foi analisada entre o intervalo de 0 a 1 (com 0.1 de passo) e foram testados os métodos de solução por *Singular Value Decomposition* (SVD), mínimos quadrados e decomposição em autovalores. Essa seleção resultou em uma AUC da ROC de 0,814 para a seguinte combinação: método de solução por mínimos quadrados e fator de encolhimento igual a 0.1.

Para o classificador SVM, utilizou-se a configuração proposta por [27], na qual os autores empregaram uma função de base radial (RBF, do inglês *Radial Basis Function*),

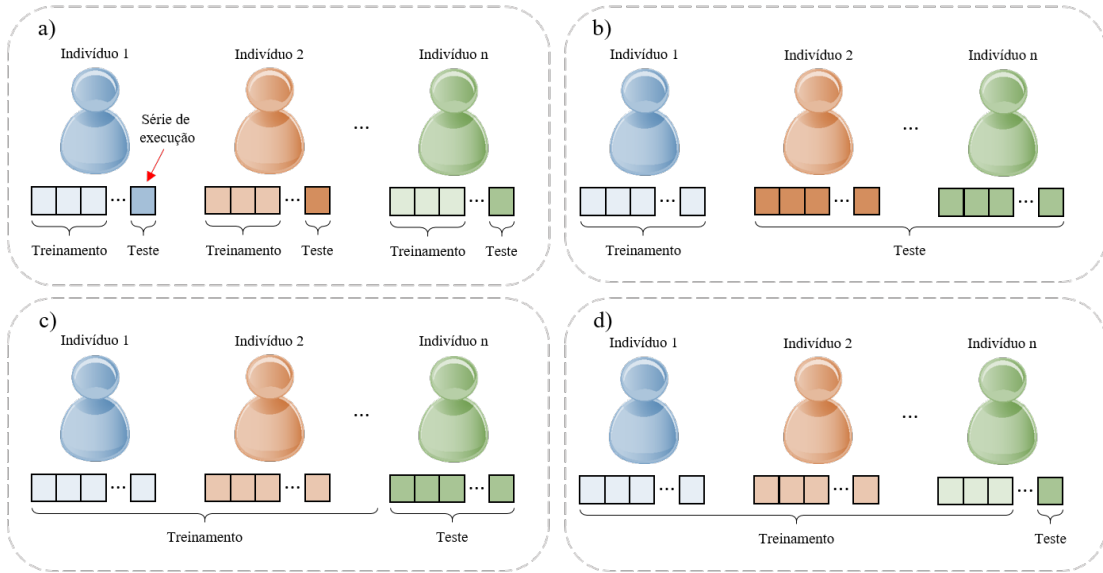


Fig. 2: Separação entre os conjuntos de treinamento e teste para cada um dos 4 experimentos. Em a), treinamento e teste com cada indivíduo separadamente. Em b), treinamento com apenas um indivíduo e teste com os demais. Em c), treinamento com todos os indivíduos, exceto um indivíduo. Em d), treinamento com todos os indivíduos, exceto uma série de um indivíduo restante.

parâmetro de regularização (C) de 1 e

$$\Gamma = \frac{1}{N_f * \sigma_x^2}, \quad (1)$$

onde N_f é o número de atributos do sinal a ser classificado e σ_x^2 representa a variância do sinal.

Em ambos os classificadores, a probabilidade da ocorrência de cada classe como saída foi considerada.

III. RESULTADOS E DISCUSSÃO

Iniciando a análise com a verificação da similaridade dos sinais de EEG, a Tabela 3 apresenta a distância esperada entre classes, calculada a partir dos centróides médios de cada classe. Os valores estão normalizados entre 0 e 1. Por sua vez, a Tabela 4 apresenta a distância média normalizada entre classes estimada por meio de DTW.

Nota-se que, pela Tabela 3, a classe 4 (que se refere ao objeto levantado) possui as maiores distâncias entre em comparação com as demais, sendo as demais classes com médias de centróides similares. Seguindo este raciocínio, pode-se observar que esta classe poderia apresentar uma pequena distância em comparação com seus indivíduos e que as distâncias para as classes respectivas por meio do DTW seriam as menores encontradas, ou seja, os valores mais baixos da tabela pertenceriam a diagonal principal. Porém, isso foi observado em sua totalidade pela Tabela 4. Percebe-se que

todas as classes, exceto a classe 2 (que se refere ao toque no primeiro dedo no objeto), possuem as menores distâncias entre os indivíduos em outras classes. O caso extremo é observado na própria classe 4, na qual a distância entre os valores dessa mesma classe em indivíduos distintos foi o máximo observado em relação às demais. Esse resultado reforça que os sinais de EEG possuem uma natureza não-estacionária, sendo que os sinais obtidos para uma mesma classe para indivíduos distintos podem sofrer grande variação.

Constatada essa dificuldade de classificação de sinais de EEG, as Figuras 3 e 4 apresentam as áreas sobre a curva ROC obtidas por meio dos classificadores LDA e SVM, respectivamente. São apresentados tanto a relação das áreas em relação aos experimentos realizados (a-d) quanto em relação aos indivíduos. Os valores das médias obtidas para todos os

Tabela 3: Distância média normalizada entre centróides de classes de indivíduos distintos.

		Classe					
		1	2	3	4	5	6
Classe	1	0	0,21	0,23	0,78	0,26	0,19
	2	0,21	0	0,3	0,77	0,15	0,27
	3	0,23	0,3	0	1	0,36	0,41
	4	0,78	0,77	1	0	0,73	0,6
	5	0,26	0,15	0,36	0,73	0	0,27
	6	0,19	0,27	0,41	0,6	0,27	0

Tabela 4: Distância média normalizada entre classes de indivíduos distintos obtida com DTW

	Classe						
	1	2	3	4	5	6	
Classe	1	0,31	0,15	0,24	0,79	0,22	0,29
	2	0,15	0	0,06	0,7	0,07	0,14
	3	0,24	0,06	0,14	0,85	0,13	0,24
	4	0,79	0,76	0,85	1	0,73	0,71
	5	0,22	0,07	0,13	0,73	0,15	0,21
	6	0,29	0,14	0,24	0,71	0,21	0,27

indivíduos em cada método são destacas nos itens (I) das Figuras 3 e 4.

Em relação aos valores médios entre os experimentos para os dois classificadores, o classificador SVM obteve um desempenho superior ao LDA. A utilização do SVM aumentou cerca de 15% acurácia que a LDA considerando a média de todos os experimentos. Todos os indivíduos (Figuras 3II e 4II) apresentaram uma melhora no seu desempenho com este classificador. Esse fato pode ser explicado devido às SVMs possuírem um significativo desempenho de generalização para problemas envolvendo classificação [28].

Comparando os experimentos adotados, nota-se que o desempenho obtido para o experimento (a) (com o treinamento e teste dos indivíduos isolados) foi sempre maior do que os demais experimentos. Entre os experimentos (b) e (c), o classificador chegou a obter uma queda de seu desempenho de aproximadamente 8%.

A verificação das similaridades das distribuições das áreas da curva ROC dos classificadores foi feita utilizando o teste estatístico de Friedman com teste post-hoc para comparações múltiplas de Tukey, com intervalo de confiança de 95%. Para o classificador LDA, o experimento (a) indicou distribuições distintas dos demais testes, o qual pode ser percebido pelos altos valores obtidos na Figura 3a). Os demais experimentos obtiveram as mesmas distribuições, não apresentando diferença estatística entre eles. Entretanto, para o classificador SVM (Figura 4), o experimento (a) e o experimento (c) apresentaram distribuições similares. Ou seja, neste classificador com maior capacidade de generalização, a separação do conjunto de dados para cada indivíduo separadamente (a) e o treinamento com a exclusão de um indivíduo para teste (c) são similares. Este ponto reforça que a capacidade de generalização para um sistema que contenha os dados de treinamento de diversos indivíduos e execute as técnicas em um indivíduo não treinado possa ser possível de realizado. Em relação aos experimentos (b) e (d), estes possuem distribuições similares com o experimento (c). Outro ponto

de análise é que a diminuição extrema da quantidade de dados disponíveis para o treinamento (obtido no experimento b) tem pouco efeito estatístico se comparado com os experimentos (c) e (d). Esse é um de suma relevância no desenvolvimento de interfaces do tipo BCI pois diminuem o tempo de treinamento, facilitando o seu uso.

IV. CONSIDERAÇÕES FINAIS

Neste trabalho, as dificuldades enfrentadas na classificação de sinais de EEG foram avaliadas. Como observado, é possível atribuir o baixo desempenho de classificação à característica não-estacionária deste tipo de sinal. Contudo, pode-se perceber um desempenho crescente pelo classificador SVM, proporcional ao número de exemplos e indivíduos utilizados no treinamento.

A partir destas observações, pode-se concluir que algoritmos de classificação com capacidade de generalização superior ao SVM utilizado devem obter desempenho melhor




Fig. 3: Médias das áreas sobre a curva ROC obtidas para o classificador LDA. Em (I), estão destacadas as relações obtidas para cada experimento realizado e em (II), em relação aos indivíduos.




Fig. 4: Médias das áreas sobre a curva ROC obtidas para o classificador SVM. Em (I), estão destacadas as relações obtidas para cada experimento realizado e em (II), em relação aos indivíduos.

realizando classificação entre indivíduos. Além disso, pode-se perceber que para a maioria das classes deve existir uma característica intrínseca que a torna discriminável das outras e é comum a todos os indivíduos. Essa característica é observável para as classes 2, 3 e 5.

Para análises futuras, sugere-se a utilização de mais exemplos de treinamento, com um número maior de indivíduos e a utilização de outros classificadores para comparação. Vale-se também a avaliação de similaridade entre classes por outros métodos além dos aqui apresentados. Ressalta-se que a base de dados utilizada neste trabalho encontra-se disponível em, enquanto que os *softwares* desenvolvidos em Python para o seu processamento pode ser acessado em [29].

CONFLITO DE INTERESSES

Os autores declaram que não há conflito de interesses.

REFERÊNCIAS

1. Várkuti Bálint, Guan Cuntai, Pan Yaozhang, et al. Resting State Changes in Functional Connectivity Correlate With Movement Recovery for BCI and Robot-Assisted Upper-Extremity Training After Stroke *Neurorehabilitation and Neural Repair*. 2013;27:53–62. Publisher: SAGE Publications Inc STM.
2. Mateo Sébastien, Di Rienzo Franck, Bergeron Vance, Guillot Aymeric, Collet Christian, Rode Gilles. Motor imagery reinforces brain compensation of reach-to-grasp movement after cervical spinal cord injury *Frontiers in Behavioral Neuroscience*. 2015;9.
3. Shih Jerry J., Krusienski Dean J., Wolpaw Jonathan R.. Brain-Computer Interfaces in Medicine *Mayo Clinic Proceedings*. 2012;87:268–279.
4. Mikkelsen Kaare B., Tabar Yousef R., Christensen Christian B., Kidmose Preben. EEGs Vary Less Between Lab and Home Locations Than They Do Between People *Frontiers in Computational Neuroscience*. 2021;15:565244.
5. Gao Zhongke, Yuan Tao, Zhou Xinjun, Ma Chao, Ma Kai, Hui Pan. A Deep Learning Method for Improving the Classification Accuracy of SSMVEP-Based BCI *IEEE Transactions on Circuits and Systems II: Express Briefs*. 2020;67:3447–3451. Conference Name: IEEE Transactions on Circuits and Systems II: Express Briefs.
6. Fazli Siamac, Popescu Florin, Danóczy Márton, Blankertz Benjamin, Müller Klaus-Robert, Grozea Cristian. Subject-independent mental state classification in single trials *Neural Networks*. 2009;22:1305–1312.
7. Saha Simanto, Baumert Mathias. Intra- and Inter-subject Variability in EEG-Based Sensorimotor Brain Computer Interface: A Review *Frontiers in Computational Neuroscience*. 2020;13.
8. Perrin Xavier. *Semi-autonomous navigation of an assistive robot using low throughput interfaces*. PhD thesis 2009.
9. Sun Lei, Feng Zu Ren. Classification of imagery motor EEG data with wavelet denoising and features selection in *2016 International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR)*:184–188 2016.
10. Aljalal Majid, Djemal Ridha, AlSharabi Khalil, Ibrahim Sutrisno. Feature Extraction of EEG based Motor Imagery Using CSP based on Logarithmic Band Power, Entropy and Energy in *2018 1st International Conference on Computer Applications & Information Security (ICCAIS)*IEEE 2018.
11. Garrett D., Peterson D.A., Anderson C.W., Thaut M.H.. Comparison of linear, nonlinear, and feature selection methods for EEG signal classification *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2003;11:141–144.
12. Scherer R., Muller G.R., Neuper C., Graimann B., Pfurtscheller G.. An asynchronously controlled EEG-based virtual keyboard: improvement of the spelling rate *IEEE Transactions on Biomedical Engineering*. 2004;51:979–984.
13. Rakotomamonjy A., Guigue V., Mallet G., Alvarado V.. Ensemble of SVMs for Improving Brain Computer Interface P300 Speller Performances in *Artificial Neural Networks: Biological Inspirations – ICANN 2005*:45–50Springer Berlin Heidelberg 2005.
14. Luciw Matthew D, Jarocka Ewa, Edin Benoni B. Multi-channel EEG recordings during 3, 936 grasp and lift trials with varying weight and friction *Scientific Data*. 2014;1.
15. Grasp-and-Lift EEG Detection
16. Jiang Yi, Lan Tuo, Zhang Dongzhan. A New Representation and Similarity Measure of Time Series on Data Mining in *2009 International Conference on Computational Intelligence and Software Engineering*IEEE 2009.
17. Kalpakis K., Gada D., Puttagunta V.. Distance measures for effective clustering of ARIMA time-series in *Proceedings 2001 IEEE International Conference on Data Mining*IEEE Comput. Soc.
18. Dong Xiao, Gu Cheng, Wang Zheng. Research on Shape-Based Time Series Similarity Measure in *2006 International Conference on Machine Learning and Cybernetics*IEEE 2006.
19. Megalooikonomou V., Wang Qiang, Li Guo, Faloutsos C.. A Multiresolution Symbolic Representation of Time Series in *21st International Conference on Data Engineering (ICDE'05)*IEEE.
20. Yamauchi Takashi, Xiao Kunchen, Bowman Casady, Mueen Abdulalah. Dynamic time warping: A single dry electrode EEG study in a self-paced learning task in *2015 International Conference on Affective Computing and Intelligent Interaction (ACII)*IEEE 2015.
21. Schirrmester Robin Tibor, Springenberg Jost Tobias, Fiederer Lukas Dominique Josef, et al. Deep learning with convolutional neural networks for EEG decoding and visualization *Human Brain Mapping*. 2017;38:5391–5420.
22. Kwon O-Yeon, Lee Min-Ho, Guan Cuntai, Lee Seong-Whan. Subject-Independent Brain–Computer Interfaces Based on Deep Convolutional Neural Networks *IEEE Transactions on Neural Networks and Learning Systems*. 2020;31:3839–3852.
23. Zhang Kaishuo, Robinson Neethu, Lee Seong-Whan, Guan Cuntai. Adaptive transfer learning for EEG motor imagery classification with deep Convolutional Neural Network *Neural Networks*. 2021;136:1 – 10.
24. Gaur Pramod, Gupta Harsh, Chowdhury Anirban, McCreadie Karl, Pachori Ram Bilas, Wang Hui. A Sliding Window Common Spatial Pattern for Enhancing Motor Imagery Classification in EEG-BCI *IEEE Transactions on Instrumentation and Measurement*. 2021;70:1–9.
25. Goel Purvi, Joshi Raviraj, Sur Mriganka, Murthy Hema A.. A Common Spatial Pattern Approach for Classification of Mental Counting and Motor Execution EEG in *Intelligent Human Computer Interaction*:26–35Springer International Publishing 2018.
26. Ramoser H., Muller-Gerking J., Pfurtscheller G.. Optimal spatial filtering of single trial EEG during imagined hand movement *IEEE Transactions on Rehabilitation Engineering*. 2000;8:441–446.
27. Riyadi Munawar A, Prakoso Teguh, Whaillan Finade Oza, David Wahono Marcelinus, Hidayatno Achmad. Classification of EEG-based Brain Waves for Motor Imagery using Support Vector Machine in *2019 International Conference on Electrical Engineering and Computer Science (ICECOS)*:422–425 2019.
28. Haykin Simon S.. *Neural networks and learning machines*. Upper Saddle River, NJ: Pearson Educationthird ed. 2009.
29. Hauer Arthur. Conjunto de códigos em python para processamento de GAL trials