

Classificação de sinais EEG para controle de cadeira de rodas

Giovanna Gouvea Spuri de Miranda*, Nélcio Lemos Freire Junior[†], Wilian Soares Lacerda[‡]

^{*†}Programa de Pós Graduação em Engenharia de Sistemas e Automação (PPGESISA)

[‡]Departamento de Automática (DAT)

Universidade Federal de Lavras (UFLA), Lavras, Brasil

*giovanna.miranda2@estudante.ufla.br, [†]nelio.junior1@estudante.ufla.br, [‡]lacerda@ufla.br

Resumo—Este trabalho apresenta uma análise comparativa entre três técnicas de aprendizado de máquina—Multilayer Perceptron (MLP), Random Forest (RF) e Support Vector Machine (SVM)—para classificar sinais de eletroencefalograma (EEG). Utilizando dados públicos do projeto Milo da McGill NeuroTech, os algoritmos foram avaliados em tarefas de classificação de imaginação motora, com registros de movimentos para direita e esquerda, além de estados de repouso. Os resultados demonstraram que o algoritmo Random Forest apresentou o melhor desempenho, alcançando 83,83% de acurácia e 83,00% de F1-Score, seguido pelo MLP com 77,90% de acurácia e 76,33% de F1-Score, e SVM com 69,97% de acurácia e 68,11% de F1-Score.

Palavras-Chave—Algoritmos Inteligentes, Interface-Cérebro-Computador (BCI), Rede Neural Artificial (RNA), Máquina de Vetor de Suporte (SVM), Floresta Aleatória (RF)

Abstract—This work presents a comparative analysis of three machine learning techniques—Multilayer Perceptron (MLP), Random Forest (RF), and Support Vector Machine (SVM)—for classifying electroencephalogram (EEG) signals. Using public data from the McGill NeuroTech's Milo project, the algorithms were evaluated in motor imagery classification tasks, with records of movements to the right and left, as well as rest states. The results demonstrated that the Random Forest algorithm showed the best performance, achieving 83.83% accuracy and 83.00% F1-Score, followed by MLP with 77.90% accuracy and 76.33% F1-Score, and SVM with 69.97% accuracy and 68.11% F1-Score.

Keywords—Intelligent Algorithms, Brain-Computer Interface (BCI), Artificial Neural Network (ANN), Support Vector Machine (SVM), Random Forest (RF)

I. INTRODUÇÃO

Segundo dados da Organização Mundial da Saúde, mais de 1 bilhão de pessoas vivem com algum tipo de deficiência, representando aproximadamente 15% da população mundial [1]. No Brasil, de acordo com o Censo de 2022, cerca de 18,6 milhões de pessoas possuem alguma deficiência que afeta severamente sua vida diária, sendo que aproximadamente 3,5 milhões necessitam de cadeiras de rodas [2].

Entre as pessoas com deficiência motora severa, muitas preservam suas funções cognitivas intactas, o que torna as Interfaces Cérebro-Computador (ICC, BCI em inglês) particularmente relevantes como meio para restabelecer algum grau de independência [3]. As BCIs baseadas em eletroencefalograma (EEG) têm ganhado particular atenção devido à sua natureza não invasiva, portabilidade, custo relativamente acessível e boa resolução temporal [4].

No campo do processamento de sinais EEG, técnicas baseadas em componentes independentes têm demonstrado resultados promissores para análise durante estimulação fônica [5]. Adicionalmente, abordagens que utilizam estatísticas de ordem superior têm sido aplicadas com sucesso na classificação de sons pulmonares [6], representando uma possível direção para a classificação de sinais cerebrais em interfaces BCI.

Nesse contexto, este trabalho propõe-se a investigar a seguinte questão de pesquisa: “Quais algoritmos de aprendizado de máquina e quais configurações de hiperparâmetros oferecem melhor

desempenho na classificação de sinais de EEG para controle de cadeiras de rodas, considerando métricas como acurácia, precisão, *recall* e *F1-score*?”

Para responder a essa questão, foram analisados e comparados três métodos diferentes: *Multilayer Perceptron* (MLP), *Random Forest* (RF) e *Support Vector Machine* (SVM). A escolha destes algoritmos baseou-se em suas características complementares: o MLP representa abordagens de redes neurais com capacidade de capturar relações não-lineares complexas [4]; o RF oferece robustez a ruídos e interpretabilidade através de ensemble de árvores [7]; e o SVM demonstra eficácia em problemas de alta dimensionalidade e pequenos conjuntos de dados, características comuns em sinais EEG [8]. Estes algoritmos têm sido amplamente validados na literatura BCI, proporcionando uma base sólida para comparação metodológica. Esses algoritmos foram avaliados utilizando um banco de dados público de sinais de EEG relacionados a imaginação motora e piscadas de olhos, disponibilizado pela equipe do projeto Milo [9].

II. FUNDAMENTOS TEÓRICOS DOS ALGORITMOS

A. Multi Layer Perceptron (MLP)

O Perceptron Multicamadas é uma rede neural artificial *feedforward* baseada no Teorema da Aproximação Universal [10], que afirma que uma rede neural com uma única camada oculta contendo um número finito de neurônios pode aproximar qualquer função contínua, sob certas condições de regularidade.

Para um neurônio j na camada l , a saída é calculada pela Eq. 1.

$$a_j^l = \sigma \left(\sum_k w_{jk}^l a_k^{l-1} + b_j^l \right) \quad (1)$$

onde σ é a função de ativação, w_{jk}^l são os pesos, a_k^{l-1} são as ativações da camada anterior e b_j^l é o viés. O treinamento ocorre através do algoritmo de retropropagação do erro, que ajusta os pesos para minimizar o erro entre a saída prevista e a real [11].

B. Floresta Aleatória

Random Forest é um método de *ensemble* que combina múltiplas árvores de decisão para melhorar a generalização [7]. Seus princípios teóricos incluem:

- **Bagging**: Cada árvore é treinada em uma amostra *bootstrap* dos dados originais.
- **Seleção Aleatória de Features**: Em cada nó, apenas um subconjunto aleatório de *features* é considerado para *split*.

Para classificação, a predição final é feita por votação majoritária conforme a Eq. 2.

$$\hat{y} = \operatorname{argmax}_c \sum_{t=1}^T \mathbb{I}(h_t(x) = c) \quad (2)$$

onde h_t é a t -ésima árvore e $\mathbb{I}$ é a função indicadora.

C. Máquina de Vetor de Suporte

O SVM busca encontrar o hiperplano que maximiza a margem de separação entre classes [12]. Para dados não linearmente separáveis, o SVM emprega o “*kernel trick*”, mapeando implicitamente os dados para um espaço de alta dimensão onde se tornam linearmente separáveis.

A função de decisão do SVM é obtida pela Eq. 3

$$f(x) = \operatorname{sign} \left(\sum_{i=1}^n \alpha_i y_i K(x_i, x) + b \right) \quad (3)$$

onde α_i são os multiplicadores de Lagrange, y_i são as classes, K é a função kernel e b é o termo de viés.

III. MÉTRICAS DE AVALIAÇÃO

A matriz de confusão é uma ferramenta fundamental para a avaliação de modelos de classificação, fornecendo uma visualização tabular do desempenho do classificador ao comparar as classes previstas com as classes reais. A Fig. 1 ilustra a estrutura de uma matriz de confusão para classificação binária, ela é composta por quatro elementos:

- **Verdadeiro Positivo (VP)**: Instâncias da classe positiva corretamente classificadas como positivas.

- **Verdadeiro Negativo (VN):** Instâncias da classe negativa corretamente classificadas como negativas.
- **Falso Positivo (FP):** Instâncias da classe negativa incorretamente classificadas como positivas (Erro Tipo I).
- **Falso Negativo (FN):** Instâncias da classe positiva incorretamente classificadas como negativas (Erro Tipo II).




Figura 1. Representação de uma matriz de confusão para classificação binária.

Em problemas multiclasse, como frequentemente encontrados na classificação de sinais EEG para interfaces cérebro-computador, a matriz de confusão se expande para incluir todas as combinações possíveis de classes reais e preditas, permitindo uma análise detalhada dos padrões de erro específicos de cada classe. A partir da matriz de confusão, derivam-se diversas métricas quantitativas que capturam diferentes aspectos do desempenho do classificador, conforme detalhado nas subseções seguintes.

A. Acurácia e Precisão

Conforma a Eq. 4 a acurácia mede a proporção de classificações corretas em relação ao total de amostras.

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

A precisão quantifica a proporção de predições positivas corretas (Eq. 5).

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (5)$$

B. Sensibilidade e F1-Score

A sensibilidade (recall) mede a proporção de positivos verdadeiros corretamente identificados. É calculada pela Eq. 6.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (6)$$

O F1-Score representa a média harmônica entre precisão e sensibilidade, ela é calculada conforme a Eq. 7.

$$\text{F1-Score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (7)$$

Para comparar holisticamente os modelos, utilizou-se uma métrica de Pontuação Geral (PG) calculada pela Eq. 8

$$\text{PG} = w_a \times A + w_p \times P + w_r \times R + w_f \times \text{F1} - w_t \times T_{\text{norm}} \quad (8)$$

onde $w_a = 1.0$, $w_p = 0.7$, $w_r = 0.7$, $w_f = 0.9$ e $w_t = 0.5$ são os pesos atribuídos a cada componente. Estes valores foram determinados com base em estudos de sistemas BCI em tempo real [3], onde a acurácia global ($w_a = 1.0$) tem importância primária, seguida pelo F1-Score ($w_f = 0.9$) que equilibra precisão e recall para sistemas de classificação multiclasse [4]. Precisão e recall recebem pesos moderados ($w_p = w_r = 0.7$) conforme recomendado por Blankertz et al. [8], enquanto o tempo computacional ($w_t = 0.5$) possui peso menor, mas significativo para aplicações em tempo real. Esta pontuação varia aproximadamente de 0 a 3, com valores maiores indicando melhor desempenho global.

IV. AQUISIÇÃO E PROCESSAMENTO DOS DADOS

Os dados utilizados neste estudo foram disponibilizados pela McGill NeuroTech¹ e foram obtidos durante o projeto Milo [9], que desenvolveu um

¹Website oficial: <https://neurotechx.com/>;
LinkedIn: <https://www.linkedin.com/company/mcgill-neurotech/>

protótipo de cadeira de rodas controlada por sinais de EEG. As coletas foram realizadas com múltiplos participantes, registrando sinais durante tarefas de imaginação motora, movimentos reais das mãos, piscadas e contrações mandibulares.

As aquisições ocorreram por meio da placa *OpenBCI Cyton Biosensing*, equipada com oito canais e eletrodos posicionados sobre o córtex sensório-motor, conforme o Sistema Internacional 10-20 [13]. Essa configuração permite a detecção de ritmos mu (7–13 Hz), relacionados à imaginação motora, bem como artefatos musculares e oculares utilizáveis como sinais de controle. A Fig. 2 ilustra a interface de usuário do OpenBCI utilizada durante a aquisição e análise dos sinais EEG, destacando as visualizações em tempo real que auxiliam no monitoramento da qualidade do sinal e na identificação dos padrões neurais associados à imaginação motora.




Figura 2. Interface de visualização do OpenBCI mostrando o processamento de sinais EEG em tempo real. À esquerda, visualizações de séries temporais e análise espectral. À direita, configurações de *streaming* e visualização da transformada rápida de Fourier (FFT), permitindo monitoramento das bandas de frequência relevantes para detecção de ritmos mu (8–12 Hz) e beta (13–36 Hz). Fonte: [9]

Os eletrodos principais incluíram C1, C2, C3 e C4, com eletrodos adicionais (CP1–CP4) em algumas sessões. A1 e A2 (lobos auriculares) foram utilizados como referência. A aquisição dos sinais ocorreu com taxa de amostragem de 250 Hz e janelas de análise de dois segundos.

Foram definidos quatro paradigmas experimentais:

- **Imaginação Motora (MI):** Alternância en-

tre repouso e imaginação de movimentos das mãos (esquerda/direita).

- **Movimento Real:** Contrações físicas das mãos, intercaladas com períodos de repouso.
- **Artefatos:** Geração proposital de piscadas e contrações mandibulares.
- **Frequência Cardíaca:** Coletas em repouso e sob estímulo.

O conjunto de dados final incluiu registros de 8 canais para três classes: esquerda (51.466 amostras), direita (16.529 amostras) e repouso (30.511 amostras), totalizando 98.506 amostras. Este desbalanceamento motivou a aplicação de técnicas de balanceamento [14].

O pré-processamento incluiu filtro notch para remoção de interferências de 60 Hz e 120 Hz, filtro passa-banda Butterworth de segunda ordem (1–40 Hz), remoção de artefatos e, em alguns casos, Análise de Componentes Independentes (ICA).

As características extraídas focaram no domínio da frequência, incluindo Densidade Espectral de Potência (PSD), potência média nas bandas mu (7–13 Hz) e beta (13–36 Hz), e características espaciais como diferença de potência entre eletrodos simétricos.

V. PROTOCOLO EXPERIMENTAL

O protocolo experimental consistiu na avaliação sistemática dos três classificadores: MLP, RF e SVM. Para cada algoritmo, foram efetuadas 20 execuções com diferentes configurações paramétricas, totalizando 60 configurações distintas.

As configurações para cada algoritmo foram selecionadas com base em recomendações da literatura. As Tabelas I, II e III apresentam algumas das configurações para os classificadores MLP, RF e SVM, respectivamente.

Para avaliar o impacto de diferentes estratégias de pré-processamento, foram implementadas três abordagens para o tratamento do conjunto de dados:

- 1) **Conjunto Original:** Utilização dos dados sem balanceamento.
- 2) **Undersampling:** Remoção aleatória estratificada de amostras das classes majoritárias.
- 3) **SMOTE:** Geração de instâncias sintéticas para as classes minoritárias através de

Tabela I
CONFIGURAÇÕES SELECIONADAS PARA O CLASSIFICADOR MLP

Config	Hidden Layers	Activation	LR	Alpha	Solver	Momentum	Batch Size
1	(300)	relu	0,001	0,0001	adam	-	256
2	(150, 300)	relu	0,0005	0,0001	adam	-	256
3	(100, 200, 300)	relu	0,0005	0,0001	adam	-	256
4	(50, 100, 200, 300)	relu	0,0005	0,0001	adam	-	256
5	(300)	tanh	0,001	0,0001	adam	-	256
6	(150, 300)	tanh	0,0005	0,0001	adam	-	256
7	(100, 200, 300)	tanh	0,0005	0,0001	adam	-	256
8	(50, 100, 200, 300)	tanh	0,0005	0,0001	adam	-	256
9	(300)	relu	0,0001	0,0001	adam	-	256
10	(150, 300)	relu	0,0001	0,0001	adam	-	256
11	(100, 200, 300)	relu	0,0005	0,001	adam	-	256
12	(50, 100, 200, 300)	relu	0,0005	0,001	adam	-	256
13	(300)	relu	0,0005	0,0001	adam	-	512
14	(150, 300)	relu	0,0005	0,0001	adam	-	512
15	(300)	relu	0,0005	0,0001	adam	-	128
16	(150, 300)	relu	0,0005	0,0001	adam	-	128
17	(300)	relu	0,001	0,0001	sgd	0,9	256
18	(150, 300)	relu	0,001	0,0001	sgd	0,9	256
19	(400, 400)	relu	0,0001	0,0001	adam	-	256
20	(500)	relu	0,0001	0,0001	adam	-	256

Tabela II
CONFIGURAÇÕES SELECIONADAS PARA RANDOM FOREST (RF)

Config	Tipo	Estimators	Max Depth	Min Split	Cr�terio	Bootstrap	Max Features	Min Leaf	OOB Score
1	rf	100	-	2	gini	True	sqrt	1	True
2	rf	200	-	2	gini	True	sqrt	1	True
3	rf	300	-	2	gini	True	sqrt	1	True
4	rf	150	10	5	gini	True	sqrt	4	True
5	rf	150	15	10	entropy	True	sqrt	2	True
6	et	150	-	2	gini	False	sqrt	1	False
7	et	200	20	2	entropy	False	sqrt	1	False
8	rf	150	20	5	gini	True	log2	2	True
9	rf	200	-	2	entropy	True	0.7	1	True
11	rf	200	-	2	gini	True	1.0	1	True
12	rf	150	25	2	entropy	True	sqrt	1	True
13	rf	500	-	2	gini	True	sqrt	1	True
14	et	300	-	2	entropy	False	0.8	1	False
15	rf	200	30	2	gini	True	sqrt	1	True
16	rf	200	-	2	entropy	True	sqrt	1	True
18	rf	200	15	5	gini	True	0.7	4	True
19	rf	250	20	3	entropy	True	sqrt	2	True

interpol     entre exemplos vizinhos mais pr ximos [14], equilibrando as distribui  es das classes.

Al m disso, para cada vers  o do conjunto de dados, foram avaliadas duas abordagens: (1) aplica   o de PCA para redu    o de dimensionalidade, e (2) utiliza     das caracter  sticas originais sem redu    o

dimensional.

Para valida    o, foi empregado o protocolo de valida    o cruzada estratificada k-fold com $k = 10$, e os resultados reportados correspondem   m dia aritm tica das m tricas obtidas nos folds.

Tabela III
CONFIGURAÇÕES TESTADAS PARA O CLASSIFICADOR SVM

Config	Tipo	Kernel	C	Gamma	Degree	Coef0	Shrinking
1	svc	rbf	1,0	scale	-	-	True
2	svc	rbf	10,0	scale	-	-	True
3	svc	rbf	0,1	scale	-	-	True
4	svc	linear	1,0	-	-	-	True
5	svc	poly	1,0	scale	2	-	True
6	svc	poly	1,0	scale	3	-	True
7	svc	sigmoid	1,0	scale	-	-	True
8	svc	rbf	5,0	0,1	-	-	True
9	svc	rbf	0,5	0,01	-	-	True
10	linear_svc	-	1,0	-	-	-	-
11	linear_svc	-	0,1	-	-	-	-
18	svc	poly	1,0	scale	4	1	True
19	svc	rbf	2,0	auto	-	-	True
20	svc	linear	10,0	-	-	-	True

VI. RESULTADOS


A análise inicial foi conduzida utilizando o conjunto de dados original, sem aplicação de técnicas específicas de pré-processamento. Conforme pode ser observado na Fig. 3 e na Tab. IV, os resultados demonstram que, neste cenário, o modelo Random Forest (configuração 13: 500 estimadores, critério gini, sem limitação de profundidade) apresentou desempenho superior em todas as métricas avaliadas. A acurácia alcançada pelo Random Forest foi de 83,83%, significativamente superior ao MLP, que obteve 77,90%, e ao SVM, com 69,97%. De maneira similar, a precisão do Random Forest (87,10%) superou os demais modelos (MLP: 79,25%; SVM: 67,73%).

Tabela IV
COMPARAÇÃO DE MODELOS - DADOS ORIGINAIS

Métrica	MLP	RF	SVM
Acurácia (%)	77,90	83,83	70,00
Precisão (%)	79,25	87,10	67,73
Recall(%)	77,90	83,83	70,00
F1-Score (%)	76,33	83,00	68,11
Pontuação Geral	2,57	2,78	2,28

No que refere-se ao F1-Score, o Random Forest manteve sua superioridade com valor de 83,00%, seguido pelo MLP (76,33%) e pelo SVM (68,11%).

Figura 3. Comparação de desempenho dos modelos utilizando dados originais



A. Impacto da Análise de Componentes Principais (PCA)

A aplicação de PCA como técnica de redução de dimensionalidade foi avaliada, porém resultou em redução nas métricas de acurácia, precisão e F1-Score para todos os algoritmos quando comparados à abordagem com dados originais. Embora o Random Forest tenha continuado apresentando o melhor desempenho entre os modelos, esta técnica não se mostrou vantajosa para o problema em questão.

B. Aplicação de Técnicas de Balanceamento

A estratégia de remoção de instâncias (*undersampling*) foi testada, mas resultou em degradação do desempenho para todos os modelos em comparação com a abordagem utilizando dados originais, não sendo recomendada para este contexto.

Em contrapartida, a implementação da técnica SMOTE produziu resultados promissores, conforme Fig 4 e Tab. V. O Random Forest destacou-se com acurácia de 81,65%, precisão de 85,70%, e F1-Score de 82,03%. Estes valores são apenas ligeiramente inferiores aos obtidos com o conjunto de dados original, porém com tempo de treinamento significativamente reduzido (10,00 segundos versus 30,04 segundos).

Figura 4. Desempenho dos modelos após aplicação da técnica SMOTE




Tabela V
COMPARAÇÃO DE MODELOS - DADOS COM SMOTE

Métrica	MLP	RF	SVM
Acurácia (%)	68,79	81,65	57,90
Precisão (%)	71,88	85,70	58,39
Recall (%)	68,79	81,65	57,90
F1-Score (%)	68,46	82,03	56,13
Pontuação Geral	2,29	2,73	1,90

C. Análise Comparativa Global

A análise comparativa global dos resultados revela padrões consistentes no desempenho dos mo-

delos sob diferentes técnicas de pré-processamento. O Random Forest demonstrou superioridade em todas as configurações avaliadas, tanto em métricas de classificação quanto em eficiência computacional. A Tab. VI sintetiza os melhores resultados obtidos para cada combinação modelo-técnica, destacando a pontuação geral como métrica agregada de desempenho.

Tabela VI
COMPARAÇÃO GLOBAL DAS PONTUAÇÕES GERAIS

Técnica	RF	MLP	SVM
Original	2,78	2,57	2,28
PCA	2,60	2,28	2,28
Remoção	2,57	1,98	1,90
Remoção+PCA	2,12	1,65	1,75
SMOTE	2,73	2,29	1,90
SMOTE+PCA	2,73	2,29	1,90
Média	2,59	2,17	2,00

O Random Forest com dados originais apresentou a melhor pontuação geral (2,78), seguido pelo mesmo modelo utilizando SMOTE (2,73) e SMOTE+PCA (2,73). A técnica SMOTE demonstrou potencial para manter desempenho próximo ao obtido com dados originais, particularmente para o Random Forest (redução de apenas 1,98% na pontuação geral), com a vantagem adicional de reduzir significativamente o tempo de processamento.

VII. CONCLUSÃO

Os resultados apresentados demonstram a superioridade consistente do modelo Random Forest em todas as configurações de pré-processamento avaliadas. A configuração utilizando dados originais, sem aplicação de técnicas específicas de pré-processamento, resultou nas métricas mais elevadas de acurácia (83,83%), precisão (87,10%), F1-Score (83,00%) e pontuação geral (2,78).

A aplicação de técnicas de pré-processamento como PCA e remoção de instâncias problemáticas não proporcionou benefícios em termos de métricas de classificação, resultando em degradação do desempenho para todos os modelos analisados. A técnica SMOTE, por outro lado, demonstrou capacidade de manter desempenho próximo ao obtido

com dados originais, especialmente para o Random Forest, com a vantagem adicional de reduzir significativamente o tempo de processamento.

A análise comparativa das diferentes combinações modelo-técnica revelou que a escolha do algoritmo de classificação exerce maior influência sobre o desempenho global do que a técnica de pré-processamento empregada. No entanto, a interação entre modelo e técnica mostrou-se relevante, com o Random Forest demonstrando maior robustez frente a diferentes abordagens de pré-processamento quando comparado ao MLP e ao SVM.

Estes resultados sugerem que para o conjunto de dados analisado, a aplicação direta do algoritmo Random Forest aos dados originais representa a abordagem mais eficaz em termos de desempenho preditivo. Alternativamente, a técnica SMOTE pode ser considerada quando há necessidade de equilíbrio entre desempenho e eficiência computacional, um requisito crucial para aplicações BCI em tempo real.

Como próximos passos, pretende-se aprofundar a investigação do modelo Random Forest, que demonstrou resultados promissores, explorando otimizações de hiperparâmetros e técnicas de ensemble para potencializar ainda mais seu desempenho. Além disso, planeja-se expandir o escopo da pesquisa através da implementação e avaliação de outros métodos de classificação como LSTM (*Long Short-Term Memory*) para captura de dependências temporais nos sinais EEG e KNN (*K-Nearest Neighbors*) por sua simplicidade e eficácia em problemas de classificação. Esta ampliação metodológica visa estabelecer um panorama mais abrangente das possibilidades de classificação para interfaces cérebro-computador.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pela concessão da bolsa de pesquisa e pelo apoio financeiro para a publicação deste trabalho.

REFERÊNCIAS

- [1] W. H. Organization and T. W. Bank, *World Report on Disability*. Geneva: World Health Organization, 2011, [Online]. Disponível em: www.who.int/publications. Acesso em: 21 de julho de 2025.
- [2] IBGE, “Pessoas com deficiência têm menor acesso à educação, ao trabalho e à renda,” Agência IBGE Notícias, 2022, [Online]. Disponível em: agenciadenoticias.ibge.gov.br. Acesso em: 21 de julho de 2025.
- [3] J. d. R. Millán, R. Rupp, G. R. Müller-Putz, R. Murray-Smith, C. Giugliemma, M. Tangermann, C. Vidaurre, F. Cincotti, A. Kübler, R. Leeb *et al.*, “Combining brain-computer interfaces and assistive technologies: state-of-the-art and challenges,” *Frontiers in Neuroscience*, vol. 4, p. 161, 2010, 10.3389/fnins.2010.00161.
- [4] F. Lotte, L. Bougrain, A. Cichocki, M. Clerc, M. Congedo, A. Rakotomamonjy, and F. Yger, “A review of classification algorithms for eeg-based brain-computer interfaces: a 10 year update,” *Journal of Neural Engineering*, vol. 15, no. 3, p. 031005, 2018, DOI: 10.1088/1741-2552/aab2f2.
- [5] D. D. Ferreira, T. M. Mendes, J. M. de Seixas, A. S. Cerqueira, and A. M. F. L. Miranda de Sá, “Independent component analysis-based method for electroencephalogram analysis during photic stimulation,” *Journal of Neuroscience Methods*, vol. 235, pp. 252–261, 2014, DOI: 10.1016/j.jneumeth.2014.07.017.
- [6] R. Naves, B. H. Barbosa, and D. D. Ferreira, “Classification of lung sounds using higher-order statistics: A divide-and-conquer approach,” *Computer Methods and Programs in Biomedicine*, vol. 129, pp. 12–20, 2016, DOI: 10.1016/j.cmpb.2016.02.013.
- [7] L. Breiman, “Random forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001, DOI:10.1023/A:1010933404324.
- [8] B. Blankertz, R. Tomioka, S. Lemm, M. Kawanabe, and K.-r. Müller, “Optimizing spatial filters for robust eeg single-trial analysis,” *IEEE Signal Processing Magazine*, vol. 25, no. 1, pp. 41–56, 2008, DOI:10.1109/MSP.2008.4408441.
- [9] McGill NeuroTech, M. Xiong, J. Patel, R. Hotter, D. Nadin, S. Tartakovsky, C. Leung, and A. Brandenberger, “Milo: A wheelchair controlled by eeg brain signals and enhanced with assisted driving,” McGill University, Montreal, Canada, 2019, software desenvolvido por 35 estudantes da McGill University. Vencedor do primeiro lugar na competição NeuroTechX Student Clubs Competition 2019 [Online]. Disponível em: github.com/ahamez/milo. Acesso em: 21 de julho de 2025.
- [10] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ: Pearson Education, 2009.
- [11] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, 1986, DOI:10.1038/323533a0.
- [12] C. Cortes and V. Vapnik, “Support-vector networks,” *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995, DOI:10.1007/BF00994018.
- [13] V. Jurcak, D. Tsuzuki, and I. Dan, “10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems,” *NeuroImage*, vol. 34, no. 4, pp. 1600–1611, Feb 2007, DOI:10.1016/j.neuroimage.2006.09.024.
- [14] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “Smote: synthetic minority over-sampling technique,” *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002, DOI:10.1613/jair.953.