

Desenvolvimento de um dispositivo eletroencefalógrafo com integração a uma interface cérebro-computador

Development of an electroencephalograph device with integration to a brain-computer interface

Desarrollo de un dispositivo electroencefalógrafo con integración a una interfaz cerebro-computadora

Vinicius Patrick Ramos Rodrigues¹
Andréia Crico dos Santos²

Resumo: Este trabalho apresenta o desenvolvimento de uma interface cérebro-computador capaz de captar e interpretar padrões mentais. A pesquisa buscou responder à seguinte questão: Como construir uma ferramenta acessível, utilizando materiais de baixo custo e métodos reproduzíveis? Como primeira etapa da metodologia, desenvolveu-se um protótipo eletroencefalográfico para captar, amplificar e filtrar sinais cerebrais. Na sequência, utilizou-se um microcontrolador para a conversão analógico-digital e implementou-se um software específico para processar e interpretar os sinais obtidos. Por fim, aplicou-se uma rede neural artificial para possibilitar a interação entre usuário e máquina. Os testes foram realizados em uma interface projetada para funcionar como um teclado virtual, com o objetivo de avaliar a capacidade do sistema de relacionar um comando mental à intenção de selecionar determinada tecla. Os resultados foram considerados animadores para um protótipo inicial, apresentando taxas de acerto satisfatórias que indicam potencial de evolução em pesquisas futuras.

Palavras-chave: Aprendizagem de máquina. Eletroencefalografia. Interface cérebro-computador. Prototipagem. Redes neurais.

Abstract: This work presents the development of a brain-computer interface capable of capturing and interpreting mental patterns. The research sought to address the question of how to build an accessible tool using low-cost materials and reproducible methods. As the first stage of the methodology, an electroencephalographic prototype was developed to capture, amplify, and filter brain signals. Subsequently, a microcontroller was used for analog-to-digital conversion, and specific software was implemented to process and interpret the acquired signals. Finally, an artificial neural network was applied to enable interaction between the user and the machine. The tests were carried out on an interface designed to function as a virtual keyboard, with the objective of assessing the system's ability to relate a mental command to the intention of selecting a given key. The results were considered promising for an initial prototype, presenting satisfactory accuracy rates that indicate potential for further development in future research.

Keywords: Machine learning. Electroencephalography. Brain-computer interface. Prototyping. Neural networks.

¹ Estudante. Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro. <https://orcid.org/0009-0003-8654-8404>. E-mail: vinicius.patrick@estudante.iftm.edu.br.

² Doutora. Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro. <https://orcid.org/0000-0002-4536-716X>. E-mail: andreiaticrico@iftm.edu.br.



Resumen: Este trabajo presenta el desarrollo de una interfaz cerebro-computadora capaz de captar e interpretar patrones mentales. La investigación buscó determinar cómo crear una herramienta accesible a partir de materiales de bajo costo y métodos reproducibles. En la primera etapa, se desarrolló un prototipo electroencefalográfico para captar, amplificar y filtrar señales cerebrales. Luego, se utilizó un microcontrolador para la conversión analógico-digital y se implementó un software destinado a procesar e interpretar las señales obtenidas. Posteriormente, se aplicó una red neuronal artificial para permitir la interacción entre el usuario y la máquina. Las pruebas se realizaron en una interfaz diseñada como teclado virtual, con el fin de evaluar la capacidad del sistema para asociar un comando mental con la selección de una tecla. Los resultados fueron prometedores para un prototipo inicial y mostraron tasas de acierto que evidencian potencial para avances futuros.

Palabras-clave: Aprendizaje automático. Electroencefalografía. Interfaz cerebro-computadora. Prototipado. Redes neuronales.

Submetido 05/12/2025

Aceito 29/07/2026

Publicado 18/08/2026

Considerações iniciais

A interação entre ser humano e máquina constitui uma das áreas mais promissoras e transformadoras da ciência contemporânea. O avanço tecnológico tem possibilitado novas formas de comunicação entre indivíduos e sistemas computacionais, o que aproxima o mundo físico e digital em uma integração cada vez mais natural. Do surgimento das primeiras interfaces gráficas até os recentes progressos em realidade virtual, observa-se uma tendência crescente de tornar as máquinas extensões das capacidades humanas. Nesse contexto, o desafio central passa a ser o desenvolvimento de formas de comunicação eficientes entre ambos, a partir de técnicas de bom custo-benefício que possam garantir acessibilidade e robustez (Machado *et al.*, 2009).

Entre as diferentes abordagens voltadas a essa interação, destacam-se as Interfaces Cérebro-Computador (do inglês *Brain-Computer Interfaces* – BCIs), que procuram estabelecer uma comunicação direta entre o cérebro e os sistemas computacionais. Essas interfaces têm como objetivo converter a atividade elétrica cerebral em sinais digitais capazes de controlar dispositivos externos, eliminando a necessidade de mediadores mecânicos convencionais, como teclado, mouse ou comandos de voz. O desenvolvimento de BCIs representa um marco importante na área da neuroengenharia, pois permite explorar o potencial cognitivo humano, possibilitando aplicações voltadas à acessibilidade, reabilitação, automação, entre outras, com base em diversas pesquisas científicas (Nicolas-Alonso; Gomez-Gil, 2012).

A técnica mais amplamente empregada na construção de sistemas BCI é a eletroencefalografia (EEG), por ser um método não invasivo, acessível e eficiente para a aquisição de sinais cerebrais. O aparelho eletroencefalógrafo permite a captação da atividade elétrica do cérebro por meio de eletrodos dispostos sobre o couro cabeludo, os quais registram variações de potencial elétrico resultantes da comunicação entre neurônios, na área conhecida como sinapses cerebrais.

Essa metodologia apresenta diversas vantagens em comparação a outras técnicas de neuroimagem, como a ressonância magnética funcional (RMf) ou a magnetoencefalografia (MEG), que exigem equipamentos mais complexos e de alto custo. A eletroencefalografia destaca-se, portanto, por sua viabilidade econômica, portabilidade e capacidade de operação em tempo real, o que a torna amplamente utilizada em ambientes clínicos, educacionais e experimentais (Demene *et al.*, 2017).

O uso da EEG em interfaces de interação computacional, entretanto, envolve desafios significativos, uma vez que as ondas cerebrais apresentam natureza complexa e variam em frequência, amplitude e intensidade, conforme o estado mental do indivíduo. Além disso, podem sofrer a influência de fatores externos, como interferências elétricas, ruídos ambientais ou variações fisiológicas. Dito isso, torna-se essencial o emprego de técnicas avançadas em processamento de sinais, capazes de filtrar ruídos e extrair padrões consistentes que possam ser interpretados de forma confiável pelos sistemas computacionais. Estudos recentes destacam a importância de algoritmos robustos, aptos a processar grandes volumes de dados ruidosos e traduzi-los em comandos estáveis, sem comprometer a experiência do usuário (Brophy *et al.*, 2022).

Ressalta-se também que o custo e a complexidade técnica dos equipamentos de EEG ainda representam barreiras para sua ampla disseminação. A maioria dos sistemas comerciais disponíveis no mercado é voltada ao uso clínico e possui valores elevados, inviabilizando sua adoção em instituições de ensino ou laboratórios de pesquisa com recursos limitados. Essa realidade restringe o avanço de estudos independentes e a experimentação prática, que são fundamentais para a inovação tecnológica e para a formação de novos pesquisadores (Santos, 2022). Assim, há uma demanda crescente por soluções de baixo custo, modulares e reproduzíveis, que democratizam o acesso às tecnologias de interface cérebro-computador (Silva; Souza; Ribeiro, 2021).

Com base nesse panorama, o presente trabalho propõe o desenvolvimento de um dispositivo eletroencefalográfico acessível, integrado a uma interface cérebro-computador experimental, como alternativa viável para fins acadêmicos e educacionais. A proposta diferencia-se de outros projetos encontrados na literatura, por combinar a construção de hardware de baixo custo, amplificação adaptada de sinais biológicos, processamento computacional e desenvolvimento de software com uso de inteligência artificial para estruturação da interface cérebro-computador.

Além desta seção introdutória, o artigo aborda os seguintes temas, os quais serão tratados nas próximas seções: a fundamentação teórica, que permite compreender as partes que constituem o protótipo, os detalhes sobre o desenvolvimento propriamente dito do projeto, os testes realizados, a discussão crítica sobre os resultados alcançados e as considerações finais.

Metodologia

Esta pesquisa caracteriza-se como aplicada, de abordagem quantitativa, com objetivos exploratórios e de caráter experimental, uma vez que busca desenvolver um protótipo funcional de interface cérebro-computador, capaz de captar e interpretar sinais eletroencefalográficos para interação com um teclado virtual. Trata-se de uma pesquisa aplicada, pois seu objetivo é solucionar um problema concreto de interação entre homem-máquina a partir do desenvolvimento de um sistema funcional. É quantitativa, já que o desempenho do protótipo foi avaliado por métricas numéricas, como as taxas de acerto na seleção de teclas em diferentes condições. Possui objetivos exploratórios, pois investiga estratégias de aquisição e interpretação de sinais cerebrais em um contexto ainda pouco estudado. Além disso, tem caráter experimental, porque envolve a construção, o teste e a validação do protótipo para avaliação do funcionamento do sistema.

O desenvolvimento da pesquisa foi estruturado em quatro etapas principais, as quais são definidas como: I) protótipo de EEG: construção do sistema de captação, amplificação e filtragem dos sinais cerebrais, assegurando a qualidade dos dados para análise subsequente; II) conversão analógica-digital: uso de microcontrolador com o objetivo de converter os sinais para o formato digital, compatível com tratamento computacional; III) processamento dos sinais em software: criação de um programa para receber, tratar e interpretar os sinais digitais, incluindo a extração de características relevantes para aprendizado de máquina; e IV) interface cérebro-computador: implementação de uma rede neural artificial para permitir a interação usuário-máquina, testada em teclado virtual, com posterior avaliação quantitativa do desempenho do sistema.


Cabe destacar que a metodologia adotada neste trabalho combina elementos inspirados em abordagens já descritas na literatura com desenvolvimentos originais propostos pelos autores. A etapa de aquisição de sinais foi parcialmente fundamentada em iniciativas de baixo custo amplamente difundidas, incluindo adaptações de módulos originalmente destinados à captação de sinais cardíacos, conforme demonstrado em plataformas abertas, como o Instructables (2018). As etapas de conversão analógico-digital e de processamento dos sinais foram integralmente desenvolvidas pelos autores, adaptadas ao contexto específico desta pesquisa, com base em princípios discutidos em trabalhos que anteriormente já se dedicaram a essa questão, como Adur (2008) e Silva, Souza e Ribeiro (2021).

No que se refere à etapa de classificação, a utilização de redes neurais artificiais está alinhada a abordagens consolidadas na área de BCI, conforme discutido em Nicolas-Alonso e Gomez-Gil (2012) e Manzan (2016), sendo, contudo, implementada aqui de forma própria, sem o uso de bibliotecas especializadas. Por fim, a aplicação em um teclado virtual aproxima-se de propostas já exploradas na literatura de interfaces cérebro-computador, especialmente aquelas voltadas à seleção de caracteres por meio de sinais eletroencefalográficos, como descrito por Krusienski e Shih (2011), os quais utilizam sinais obtidos a partir de eletrocorticografia (ECoG), um método mais invasivo do que a EEG, para aquisição de sinais cerebrais. Abordagens clássicas baseadas em potenciais evocados, como o P300, são discutidas em revisões da área, como a apresentada por Nicolas-Alonso e Gomez-Gil (2012). Esse tipo de aplicação também é revisitado em análises mais recentes voltadas especificamente a sistemas de escrita baseados em EEG (BCI spellers), como em Maslova *et al.* (2023), reforçando o caráter consolidado dessa linha de pesquisa.

Inserido nesse contexto, o presente trabalho distingue-se ao propor uma abordagem integrada e acessível, na qual todas as fases do sistema são implementadas em um único protótipo funcional, com ênfase em reprodutibilidade e baixo custo. Na sequência, o texto detalha cada uma das quatro etapas metodológicas anteriormente mencionadas.

No que se refere à etapa I, é natural pensar que o protótipo eletroencefalógrafo se inicia com a captação dos sinais provenientes do cérebro e é isso que acontece. Para tanto, foi usado um conjunto de eletrodos, posicionados estrategicamente sobre o couro cabeludo, responsáveis pela captação dos sinais bioelétricos gerados pela atividade neural. A Figura 01 mostra os pontos de acesso normalmente utilizados em exames profissionais, de acordo com a Sociedade Brasileira de Neurofisiologia Clínica (Sociedade Brasileira de Neurociências e Comportamento, 2017). Na figura, são indicados os pontos e as estruturas que orientam o posicionamento dos eletrodos, destacando-se NASIO, ponto mais anterior da sutura frontonasal que conecta o osso frontal aos ossos nasais, e INIO, proeminência óssea localizada na porção posterior do crânio.

Figura 01: Disposição de leitura em eletroencefalogramas



Fonte: Sociedade Brasileira de Neurociências e Comportamento (2017).

Neste projeto, os eletrodos foram colocados na área frontal da cabeça, nas posições Fp1 e Fp2 da Figura 01, com o objetivo de captar sinais concentrados no lobo frontal. Essa região está associada a funções cognitivas de maior complexidade, como raciocínio, planejamento e solução de problemas. Além disso, ela participa do controle dos movimentos voluntários, da linguagem, das emoções, do comportamento social e de aspectos da personalidade.


Para garantir o contato com a pele, foram usados eletrodos de superfície do tipo seco, feitos de material condutor que elimina a necessidade de gel eletrolítico, tornando a aplicação mais prática e confortável. A estrutura física do protótipo é constituída por uma bandana, produzida por material elástico, o que possibilita o ajuste a diversos tamanhos de cabeça e assegura comodidade mesmo em períodos prolongados de uso.

Como os sinais captados apresentam amplitude muito baixa, a próxima etapa do eletroencefalógrafo envolve um amplificador de alta precisão, cuja função é aumentar a amplitude dos sinais, sem comprometer a integridade das informações capturadas. Para contornar o fato de os sinais serem fortemente suscetíveis a interferências, ruídos ou variações de ordem fisiológica, faz-se necessário implementar também um processo de filtragem. A intenção é manter apenas o espectro correspondente às ondas cerebrais de interesse, tipicamente entre 0,5 Hz e 50 Hz (Adur, 2008).

Para desempenhar as tarefas de amplificação e filtragem, foi usado o módulo AD8232. Esse módulo é destinado originalmente à composição de dispositivos de eletrocardiogramas

(ECG), contudo, mediante modificações no circuito, é possível adaptá-lo para uso em EEG, desde que respeitadas as boas práticas de isolamento e filtragem de ruído (Instructables, 2018). Dessa forma, o trabalho busca validar a hipótese de que é possível desenvolver um modelo eletroencefalógrafo funcional, com baixo custo, capaz de captar sinais cerebrais com qualidade suficiente para análise e experimentação, a partir do uso do AD8232. A Figura 02 apresenta um módulo AD8232, da forma disponível comercialmente, ainda sem a realização de nenhuma alteração.

Figura 02: Módulo AD8232 - composição original disponível comercialmente




Fonte: Ilha da Eletrônica ([20--]).

Na Figura 02, é possível perceber que os eletrodos de captura de sinais para o ECG são nomeados RA, LA e RL. De acordo com a folha de dados do módulo, o ponto RA deve ser conectado ao braço direito (do inglês *Right Arm*), o ponto LA deve ser conectado ao braço esquerdo (do inglês *Left Arm*) e o ponto RL deve ser conectado à perna direita (do inglês *Right Leg*), sendo que este último funciona como referencial para redução de ruídos (Analogue Devices, [2025]).

Com a adaptação para o funcionamento como EEG, destaca-se que LA e RA são posicionados nos pontos Fp1 e Fp2 da Figura 01, respectivamente. Já o eletrodo RL, usado como referência, é posicionado na região central, entre Fp1 e Fp2. A Figura 03 apresenta

modificações feitas no circuito do módulo, sendo que à esquerda, há o esquema original usado para ECG, enquanto à direita, há a configuração adaptada para EEG.

Figura 03: Alterações no circuito do Módulo AD8232 de ECG (à esquerda) para EEG (à direita)



Fonte: Elaborada pelos autores (2025).

Após apresentada a parte de captação, amplificação e filtragem dos sinais cerebrais, a etapa II da pesquisa compreende a digitalização dos sinais biológicos a partir de um microcontrolador, que converte os dados analógicos em amostras digitais. O Arduino, por sua simplicidade e versatilidade, foi escolhido como plataforma central para essa etapa, permitindo o envio dos dados para um computador.

No Arduino, a conversão de sinais analógicos para digitais é feita por um componente interno denominado Conversor Analógico-Digital (ADC, do inglês *Analog-to-Digital Converter*). Esse módulo é responsável por transformar sinais analógicos, os quais variam de maneira contínua, em valores digitais discretos que o microcontrolador pode interpretar e manipular.


Durante o processo, o sinal analógico é comparado internamente – por meio de um comparador de tensão incorporado ao ADC – com a tensão produzida por um Conversor Digital-Analógico (DAC, *Digital-to-Analog Converter*). Um registrador de aproximações sucessivas ajusta gradualmente, bit a bit, o valor digital de saída, aumentando ou reduzindo a

tensão gerada pelo DAC até que ela se iguale à tensão de entrada. Quando essa correspondência é alcançada, o valor digital final é enviado ao processador do Arduino.

Os valores digitais obtidos na conversão são enviados ao computador como uma série temporal de amostras. Essas variações ao longo do tempo representam o comportamento dinâmico do sinal original e podem ser examinadas de diferentes maneiras, conforme a finalidade da aplicação ou o objetivo do estudo.

Neste ponto, após apresentação das etapas I e II, pode-se dizer que o hardware do protótipo está concluído. A Figura 04 mostra a bandana com os eletrodos, o módulo AD8232 e uma placa universal de fenolite perfurada, onde foi soldado o microcontrolador Arduino.

Figura 04: Hardware concluído




Fonte: Arquivo pessoal dos autores (2025).

Após a conclusão do desenvolvimento do hardware, iniciou-se a etapa III, que abrange o aprimoramento do sinal a partir do desenvolvimento de um software, usando a linguagem de programação Python. O foco principal foi reduzir ruídos remanescentes e ajustar a taxa de amostragem do Arduino para torná-la compatível com as características das ondas eletroencefalográficas, que variam em frequência e amplitude. Paralelamente, foram criadas

bibliotecas próprias para otimizar a comunicação com o microcontrolador e organizar o fluxo de aquisição dos dados. O primeiro módulo implementado, destinado à leitura serial, utilizou a biblioteca *pyserial* para estabelecer a comunicação contínua entre o Arduino e o computador. Essa biblioteca foi projetada para receber, interpretar e armazenar as informações do microcontrolador em *buffers* de tempo, garantindo que os dados fossem organizados de forma estruturada e permitindo a verificação de leituras corrompidas ou inconsistentes. Além disso, implementou-se a segmentação dos sinais em blocos de 100 amostras, facilitando o armazenamento, o pré-processamento e a aplicação de algoritmos de análise digital.

Desenvolveu-se, ainda, um módulo voltado à visualização gráfica, utilizando a biblioteca *matplotlib*, que permitiu acompanhar em tempo real as características dos sinais captados. Essa ferramenta possibilitou a identificação imediata de picos, padrões de oscilação e interferências externas, fornecendo suporte visual para monitoramento do comportamento cerebral. Um exemplo de gráfico obtido pode ser visto na Figura 05. Essa etapa também facilitou a observação qualitativa das ondas cerebrais em diferentes estados, como relaxamento ou atenção, servindo de base para a análise quantitativa posterior.

Figura 05: Exemplo de gráfico obtido a partir da captação de sinal cerebral



Fonte: Elaborada pelos autores (2025).

Por fim, foi implementado o módulo de processamento espectral, que aplicou a Transformada Rápida de Fourier (FFT) aos segmentos de sinais coletados, convertendo-os do domínio do tempo para o domínio da frequência. Esse procedimento permitiu decompor os sinais para identificar as principais faixas de frequência associadas às ondas Alfa, Beta, Teta, Delta e Gama. Testes realizados com o sistema demonstraram coerência com padrões esperados: em estados de relaxamento predominavam os componentes Alfa, enquanto em tarefas de atenção e concentração, as faixas Beta apresentavam maior intensidade. Esses resultados confirmaram a confiabilidade do protótipo na aquisição e no processamento de sinais neurofisiológicos.

A etapa IV, última da pesquisa, refere-se ao desenvolvimento da interface cérebro-computador propriamente dita. O trabalho incorpora algoritmos de aprendizagem de máquina para aprimorar a interpretação dos sinais EEG. Essa abordagem segue uma tendência recente na área de BCIs, que busca usar a Inteligência Artificial (IA) como um elemento de ligação entre a neuroengenharia e a computação inteligente, ampliando o potencial de aplicação dos sistemas EEG (Eldawlatly, 2024).

Utilizou-se Redes Neurais Artificiais (RNA) para interpretar os sinais cerebrais processados e convertê-los em comandos computacionais. Essa fase buscou demonstrar a aplicação prática do protótipo, usando aprendizado de máquina para reconhecer padrões mentais associados a diferentes intenções cognitivas.

As amostras espectrais processadas pelo software, obtidas pela FFT, foram organizadas em vetores de características, contendo as amplitudes normalizadas das principais bandas de frequência cerebral. Esses vetores, extraídos após o processamento inicial do sinal, foram utilizados como entradas para uma rede neural do tipo *Multilayer Perceptron* (MLP), construída com uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A quantidade de neurônios em cada camada foi definida de acordo com a complexidade do problema e com o número de características extraídas dos sinais (Manzan, 2016).


O treinamento da rede foi realizado utilizando dados previamente coletados, em que cada amostra estava associada a uma ação específica, como mover um personagem em um jogo ou selecionar uma tecla virtual.

Durante o processo de treinamento, a rede neural ajustou seus pesos sinápticos por meio do algoritmo de retropropagação do erro (*backpropagation*), buscando minimizar a diferença

entre as saídas previstas e os valores desejados (Manzan, 2016). O conjunto de dados foi dividido em amostras de treino e teste, permitindo avaliar o desempenho do modelo em termos de acurácia e generalização.

Após a validação da rede, implementou-se a aplicação prática da interface em dois ambientes distintos: um jogo inspirado em *Flappy Bird* (*Flappy Bird*, ©2025) e um teclado virtual. No primeiro caso, a atividade cerebral do usuário foi utilizada para controlar o movimento do personagem, substituindo o clique do mouse por comandos mentais identificados pela rede neural. Quando a rede reconhecia um padrão correspondente à intenção de “pular”, o personagem executava a ação dentro do jogo. A Figura 06 mostra o jogo desenvolvido para testes do protótipo.


Figura 06: Interface de BCI, com o jogo nomeado como *Flappy Brain*



Fonte: Elaborada pelos autores (2025).

Já no segundo caso, do teclado virtual, a rede neural interpreta os sinais cerebrais de modo a identificar intenções de seleção de teclas. Essa aplicação demonstrou o potencial da interface para comunicação assistiva, possibilitando o controle de dispositivos por meio de pensamentos, sem necessidade de interação física. A Figura 07 mostra a interface criada para substituição do teclado mecânico.

Figura 07: Interface de BCI para substituição de teclado mecânico por teclado virtual



Fonte: Elaborada pelos autores (2025).

A integração entre o processo de aquisição de dados, o módulo de processamento e a rede neural resultou em um sistema completo de interface cérebro-computador funcional. A comunicação entre os módulos foi estruturada de modo que os dados do eletroencefalógrafo fossem processados em tempo real, alimentando continuamente a rede neural, que, por sua vez, emitia respostas computacionais imediatas.

Análise dos dados e resultados

Para utilizar o sistema, o usuário precisa colocar a bandana na cabeça, com os três eletrodos posicionados adequadamente. Então, o hardware deve ser conectado ao computador que executa o software, o qual identifica automaticamente o dispositivo. Caso não haja reconhecimento, as funções ficam inativas até que a conexão seja validada, assegurando que somente dados confiáveis sejam processados. Após a detecção correta, inicia-se a aquisição dos sinais cerebrais, exibidos tanto no domínio do tempo quanto em seus componentes de frequência. Em seguida, procede-se ao treinamento da rede neural, etapa essencial para ajustar seus parâmetros e melhorar a capacidade do sistema de reconhecer diferentes padrões de

atividade cerebral, cuja duração varia conforme a resposta do usuário e a complexidade dos sinais.

Para testar o protótipo construído, nesta seção, são analisados os dados e os resultados obtidos quanto à utilização da BCI para uso de um teclado virtual, que visa substituir o teclado mecânico. Durante o processo de treinamento, são coletados valores associados a dez estados mentais possíveis, cada um correspondente a um padrão distinto de atividade cerebral. Dois desses estados são desconsiderados por corresponderem a momentos de repouso ou de ausência de interação com a ferramenta, os quais não contribuem para o controle da interface. Os outros oito estados são registrados e vinculados a categorias específicas de leitura, permitindo que a rede neural aprenda a relacionar cada padrão de sinal às ações correspondentes no software. Essa etapa fornece à rede neural dados calibrados, aumentando a precisão no reconhecimento dos sinais durante o uso da ferramenta.

A RNA utilizada no sistema possui arquitetura do tipo *feedforward*, composta por uma camada de entrada com 100 neurônios, responsáveis pela recepção das características extraídas dos sinais eletroencefalográficos, seguida por uma camada oculta densamente conectada, contendo 64 neurônios. A camada de saída é composta por 10 neurônios, correspondentes aos estados mentais considerados no processo de classificação.


Durante o treinamento, emprega-se o algoritmo de retropropagação do erro, utilizando gradiente descendente clássico (*gradient descent*), com inicialização aleatória dos pesos sinápticos em uma distribuição uniforme no intervalo de -1 a 1 e atualização iterativa ao longo de múltiplas épocas, sendo adotado, por padrão, 1000 épocas por ciclo de treinamento. Esse valor foi definido durante os testes, com base no desempenho observado durante as avaliações. A função de ativação usada em todas as camadas da rede é a sigmoide, permitindo a modelagem de relações não lineares entre os sinais de entrada e as saídas do modelo.

O processo de treinamento é conduzido de forma supervisionada a partir de dados coletados do próprio usuário durante a utilização da aplicação. Para cada estado mental, são adquiridas aproximadamente 10 amostras de sinais, totalizando cerca de 100 instâncias por sessão de treinamento. Cada amostra corresponde a um segmento de sinal capturado em tempo real, sendo a duração total de uma sessão de coleta de aproximadamente 7 minutos, podendo variar de acordo com as condições de uso e o desempenho do sistema.

Em termos práticos, observou-se que sessões contendo cerca de 100 instâncias são suficientes para inicializar o processo de aprendizagem, enquanto a realização de 2 a 3 sessões consecutivas de treinamento tende a proporcionar resultados mais estáveis durante a utilização do sistema. Ressalta-se que o desempenho do modelo está diretamente relacionado à variabilidade dos sinais eletroencefalográficos e à adaptação do usuário à interface, sendo esta um fator inerente a sistemas de interface cérebro-computador.

Após o treinamento da rede neural, o usuário atribui as leituras aprendidas a teclas do teclado, por meio da interface gráfica mostrada na Figura 08.

Figura 08: Interface de BCI para associar leituras aprendidas a teclas do teclado



Fonte: Elaborada pelos autores (2025).

Para avaliação dos resultados, foram categorizadas quatro vertentes, a saber: I) quanto à usabilidade, II) quanto à acessibilidade, III) quanto à viabilidade, e IV) quanto à qualidade.

Sobre o quesito I, pode-se afirmar que analisar a usabilidade do protótipo consiste em verificar se todo o aparato desenvolvido opera de acordo com as expectativas, de forma estável e confiável. Nesse contexto, foi feita uma investigação sobre o desempenho do sistema na ausência de ruídos externos, em condições ideais de funcionamento. A metodologia consistiu na realização de dez baterias de testes, com 100 sequências cada uma, sendo que cada sequência

incluía oito leituras. Para fins de análise quantitativa, considerou-se como sequência correta apenas aquelas que obtiveram êxito nas oito leituras, ou seja, a ocorrência de erro em uma única leitura já conferia a condição de erro à sequência toda. A Tabela 1 mostra quantas sequências corretas foram obtidas, dentre as 100 testadas em cada bateria.

Tabela 1 – Resultados de acertos em baterias realizadas sem ruídos

BATERIA	1º	2º	3º	4º	5º	6º	7º	8º	9º	10º
ACERTOS	54	56	61	51	56	46	45	46	50	48

Fonte: Elaborada pelos autores (2025).

Os resultados indicaram valores entre 45 e 61 acertos por bateria, resultando em média geral de 51,3% de acerto. Essa variação moderada entre as baterias sugere influência de flutuações inerentes ao processo de aquisição de sinais ou limitações do hardware empregado. Destaca-se uma queda de percentual de acertos a partir da quinta bateria, o que pode estar associado ao fato de esses testes terem acontecido após um reparo decorrente de uma falha momentânea no protótipo.

De forma complementar, após o término das baterias descritas anteriormente, foram feitos 50 treinamentos com apenas uma leitura cada um, para calcular a média de acertos simples da ferramenta, sem estar associada a sequências de oito leituras. Nesse caso, foram obtidos 33 acertos, o que resultou em uma taxa de acerto de 66%.

Do exposto, observa-se que o protótipo apresentou operação estável em suas condições, sem interferências, demonstrando coerência no reconhecimento dos padrões mentais. A taxa média de acertos, embora possa parecer modesta sob certo ponto de vista, é considerada satisfatória tendo em vista o caráter experimental do projeto, a simplicidade dos recursos utilizados e o uso de uma rede neural tradicional totalmente programada sem o uso de bibliotecas externas especializadas. É razoável supor que modelos mais avançados ou bibliotecas prontas de aprendizado de máquina poderiam elevar significativamente a precisão das classificações.

Com relação ao quesito II, a acessibilidade do protótipo foi testada a partir da observação do comportamento do sistema perante as diferentes condições possíveis de ocorrência durante sua operação, a fim de concluir sobre robustez e adaptabilidade. Assim,

foram avaliadas quatro condições: sem ruído (SR), bandana posicionada incorretamente (BPI), ruído elétrico adicionado (REA) e presença de ruído biológico no ponto de leitura (RBPL). A mesma metodologia descrita anteriormente foi adotada: realização de dez baterias, com 100 sequências cada, de forma a contabilizar como correta apenas sequências que não apresentaram nenhum erro ao longo de suas oito leituras. A Tabela 2 mostra os resultados obtidos durante os testes de acessibilidade.

Tabela 2 – Resultados de acertos em baterias com adição de ruídos

BATERIA	1º	2º	3º	4º	5º	6º	7º	8º	9º	10º
ACERTOS SR	54	56	61	51	56	46	45	46	50	48
ACERTOS BPI	30	33	40	30	36	26	30	27	36	30
ACERTOS REA	33	28	35	28	30	33	29	27	30	31
ACERTOS RBPL	40	49	50	39	45	40	36	36	38	37

Fonte: Elaborada pelos autores (2025).

Vale mencionar que a condição SR é aquela que alcançou média de acerto de 51,3%, de acordo com os dados apresentados na Tabela 1. Os casos de BPI, REA e RBPL evidenciaram que o sistema é sensível a interferências externas. As condições BPI e REA apresentaram médias de acertos de 31,4% e 30,4%, respectivamente, o que representa queda significativa de desempenho quando é feita a comparação com o caso SR. Esse comportamento indica que o desalinhamento dos eletrodos e interferências elétricas afetam diretamente a precisão da leitura dos sinais biológicos. Por sua vez, o ruído biológico considerado no caso RBPL impactou de forma moderada o índice de acertos, o qual alcançou média de 41%.

A análise dos resultados dos testes de acessibilidade revela que o protótipo é vulnerável a variações comuns, que podem acontecer em contextos reais de uso. Isso demonstra a necessidade de aprimoramentos futuros em termos estruturais e algorítmicos, como: reforço no mecanismo de fixação da bandana e dos eletrodos, adição de técnicas de blindagem e filtragem para redução de ruídos elétricos e implementação de algoritmos de pré-processamento e normalização dos sinais para minimizar ruídos biológicos.

No que tange ao quesito III, a viabilidade do protótipo foi avaliada tanto sob a perspectiva econômica quanto sob a praticidade de montagem e uso. O levantamento de custos, apresentado na Tabela 3, indicou que os principais componentes usados totalizaram R\$ 186,84,

considerando os valores praticados no período de desenvolvimento do projeto, no ano de 2025. A quantia corresponde a US\$ 33,48, com base na cotação média do dólar, no referido ano, de aproximadamente R\$ 5,58/US\$ (Banco Central do Brasil, [2026]). Ressalta-se que esses valores estão sujeitos a variações ao longo do tempo, em função de fatores econômicos e de mercado, como flutuações cambiais e disponibilidade de componentes.

O que mais importa observar é que o custo total do protótipo permanece significativamente inferior ao de equipamentos comerciais de interface cérebro-computador disponíveis no mercado, que usualmente apresentam valores na ordem de dezenas de milhares de reais (Otoni, 2019), evidenciando o potencial da proposta em termos de acessibilidade.

Tabela 3 – Tabela de preços dos principais componentes utilizados

PRODUTO	QUANTIDADE	PREÇO UNITÁRIO	PREÇO TOTAL
ARDUINO NANO	1 kit, com cabo	R\$ 25,31	R\$ 25,31
MÓDULO AD8232	1 kit, com pontos	R\$ 64,30	R\$ 64,30
CONECTORES	1 kit, com 40 unidades	R\$ 0,48	R\$ 19,01
SOLDA	1 Tubo	R\$ 29,99	R\$ 29,99
ELÁSTICO	1 Rolo	R\$ 18,71	R\$ 18,71
ELETRODOS	1 caixa, com 10 unidades	R\$ 2,95	R\$ 29,52
TOTAL	-	-	R\$ 186,84

Fonte: Elaborada pelos autores (2025).

Do ponto de vista financeiro, o projeto demonstra ser altamente acessível, especialmente para ambientes acadêmicos, laboratórios didáticos e grupos de pesquisa iniciantes. A estrutura utilizada viabiliza replicações do protótipo sem grande investimento, possibilitando avanços iterativos e experimentações diversas.

Entretanto, a análise de viabilidade prática aponta desafios a serem considerados. A fragilidade estrutural do dispositivo implica necessidade de manutenção frequente e substituição periódica de componentes, especialmente eletrodos e fios soldados. Esses fatores podem aumentar custos secundários e impactar a durabilidade do sistema. Assim, embora o custo inicial seja baixo, a viabilidade plena depende de melhorias na resistência física do projeto, visando reduzir falhas e prolongar a vida útil do equipamento.

Sobre o quesito IV, a análise da qualidade envolveu a averiguação do desempenho do sistema ao longo do tempo, bem como sua integridade estrutural. A Tabela 4 mostra as taxas de acertos obtidas após transcorridos períodos de tempo de utilização contínua do dispositivo.

Tabela 4 – Acerto ao longo do tempo

TEMPO DE USO	10min	20min	30min	40min	50min	60min
ACERTOS	56,16%	52,05%	54,11%	52,74%	46,58%	43,84%

Fonte: Elaborada pelos autores (2025).

Durante os testes de operação contínua, observou-se que o protótipo apresentava um desempenho inicial satisfatório, com taxa de acerto de 56,16% nos primeiros 10 minutos. Contudo, ocorreu uma queda progressiva ao longo da primeira hora de uso, atingindo 43,84% aos 60 minutos. Essa degradação pode ser atribuída a fatores, como: aquecimento dos componentes eletrônicos, perda gradual de contato dos eletrodos devido à, por exemplo, formação de suor e ao aumento de ruído acumulado.

Além disso, foram registrados desconexões e desgastes que enfatizaram a existência de fragilidade estrutural e a necessidade de aprimoramentos para garantir estabilidade prolongada. As evidências obtidas oferecem subsídios valiosos para o desenvolvimento de versões futuras que envolvam melhorias na montagem, no isolamento dos componentes, na fixação dos eletrodos e na implementação de mecanismos de calibração periódica.

Os resultados obtidos podem ser contextualizados à luz de trabalhos aplicados na área de interfaces cérebro-computador, especialmente aqueles voltados à comunicação por meio de teclados virtuais e seleção de caracteres. Revisões recentes, como Maslova *et al.* (2023), indicam que sistemas de BCI spellers, baseados em EEG, podem alcançar altos níveis de acurácia, embora com variações significativas dependendo do paradigma e das condições experimentais. As taxas de acerto elevadas têm sido frequentemente associadas ao uso de equipamentos especializados e estruturas de aquisição de dados mais complexas, como observado em Krusienski e Shih (2011). Esse tipo de abordagem é amplamente discutido na literatura da área, conforme revisões como a de Nicolas-Alonso e Gomez-Gil (2012).

Por outro lado, iniciativas voltadas ao desenvolvimento de dispositivos de captação de sinais cerebrais de baixo custo, como as descritas por Silva, Souza e Ribeiro (2021) e Otoni

(2019), apresentam limitações semelhantes às observadas neste trabalho, especialmente no que se refere à sensibilidade a ruídos e à variabilidade dos sinais. Nesse contexto, os resultados aqui apresentados demonstram alinhamento com o estado da arte quanto aos desafios práticos da implementação de sistemas acessíveis, ao mesmo tempo em que evidenciam uma das principais contribuições deste estudo: a integração, em uma única arquitetura funcional, das etapas de aquisição, processamento e aplicação dos sinais em uma interface de teclado virtual, sob uma perspectiva de baixo custo e reprodutibilidade.

Considerações finais

O presente artigo apresentou o processo completo de desenvolvimento de um protótipo de interface cérebro-computador baseado em eletroencefalografia, com foco em baixo custo, acessibilidade e aplicabilidade em contextos acadêmicos e experimentais. O projeto demonstrou que é possível realizar a captação e a interpretação de sinais cerebrais utilizando componentes eletrônicos simples, aliados a técnicas modernas de processamento digital de sinais e aprendizado de máquina. Essa integração interdisciplinar entre eletrônica, computação e neurociência constituiu o principal alicerce do trabalho, evidenciando que tecnologias tradicionalmente restritas a ambientes laboratoriais de alto investimento podem ser reproduzidas em escala educacional.

O protótipo desenvolvido foi composto por uma bandana com eletrodos para captação de sinais cerebrais, um circuito eletrônico de amplificação e filtragem, um módulo de comunicação responsável pela digitalização e transferência dos dados ao computador e um software de processamento e classificação baseado em redes neurais artificiais. O conjunto mostrou-se funcional, validando a hipótese central de que é possível implementar um sistema de aquisição EEG confiável utilizando hardware acessível. Os testes realizados demonstraram que o dispositivo conseguiu identificar padrões mentais simples com coerência e estabilidade, ainda que com limitações inerentes ao baixo custo dos sensores empregados.

Entre as principais contribuições do trabalho, destacam-se a integração completa entre hardware e software próprios, o desenvolvimento de um modelo de rede neural personalizado para o reconhecimento de padrões neurais e a aplicação prática em um ambiente interativo, como o jogo *Flappy Brain* e o teclado virtual. Essas demonstrações práticas consolidaram o potencial educacional e experimental do sistema, reforçando sua utilidade, tanto em contextos

de ensino quanto de pesquisa em neuroengenharia. Além da contribuição tecnológica, o projeto apresentou relevância pedagógica, ao servir como instrumento introdutório para o estudo de sistemas biomédicos e de inteligência artificial. A documentação técnica produzida, incluindo esquemas, códigos-fonte e registros experimentais, forma uma base de conhecimento que pode ser utilizada em disciplinas relacionadas à eletrônica aplicada, bioengenharia e processamento de sinais.

Apesar dos avanços obtidos, reconhece-se que há oportunidades de aprimoramento em diversos aspectos do sistema. Entre as principais melhorias possíveis, menciona-se: o fortalecimento do método de fixação da bandana e dos eletrodos, a substituição de certos componentes analógicos por módulos mais adequados à leitura de sinais EEG, o refinamento do software de interface para maior estabilidade e facilidade de uso e, por fim, a implementação de técnicas de aprendizado profundo, como redes convolucionais e recorrentes.

Para trabalhos futuros, pretende-se expandir a aplicação do protótipo em sistemas de realidade virtual e aumentada, explorando o controle de ambientes imersivos por meio da atividade cerebral. Também se vislumbra o uso do sistema em dispositivos assistivos e próteses neurais, voltados à reabilitação de pessoas com limitações motoras, de forma a aproximar o projeto das demandas reais de acessibilidade tecnológica.

Em síntese, o desenvolvimento realizado comprova que a democratização das interfaces cérebro-computador é viável e promissora, desde que acompanhada de uma abordagem científica integrada e acessível. O trabalho aqui descrito representa um marco inicial nesse caminho, oferecendo não apenas um protótipo funcional, mas um ponto de partida para futuras inovações na interação homem-máquina, capazes de ampliar as fronteiras entre tecnologia, biologia e imaginação humana.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e ao Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro (IFTM) pelo apoio financeiro concedido para a realização deste trabalho.

Referências

ADUR, Ricardo. **Sistema de Processamento de Sinais Biomédicos: Módulo Didático de Eletroencefalograma**. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal de Santa Catarina, Florianópolis, 2008. Disponível em: <https://repositorio.ufsc.br/bitstream/handle/123456789/92158/260093.pdf>. Acesso em: 20 out. 2025.

ANALOGUE DEVICES. **AD8232**: Single-Lead, Heart Rate Monitor Front End, [2025]. Disponível em: <https://www.analog.com/en/products/ad8232.html>. Acesso em: 22 out. 2025.

BANCO CENTRAL DO BRASIL. **Taxas de câmbio** (dados da PTAX), [2026]. Disponível em: <https://www.bcb.gov.br>. Acesso em: 22 abr. 2026.

BROPHY, Eoin; REDMOND, Peter; FLEURY, Andrew; DE VOS, Maarten; BOYLAN, Geraldine; WARD, Tomás. Denoising EEG signals for real-world BCI applications using GANs. **Frontiers in Neuroergonomics**, Lausanne, v. 2, p. 805573, 2022. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10790876/>. Acesso em: 3 nov. 2025.

DEMENE, Charlie; BARANGER, Jérôme; BERNAL, Miguel; DELANOË, Catherine; AUVIN, Stéphane; BIRAN, Valérie; ALISON, Marianne; MAIRESSE, Jérôme; HARRIBAUD, Elisabeth; PERNOT, Mathieu; TANTER, Mickaël; BAUD, Olivier. Functional ultrasound imaging of brain activity in human newborns. **Science Translational Medicine**, Washington, v. 9, n. 411, 2017. DOI: 10.1126/scitranslmed.aah6756.

ELDAWLATLY, Sherif. On the role of generative artificial intelligence in the development of brain-computer interfaces. **BMC Biomedical Engineering**, London, v. 6, n. 1, 2024. Disponível em: <https://bmcbiomedeng.biomedcentral.com/articles/10.1186/s42490-024-00080-2>. Acesso em: 24 out. 2025.

FLAPPY BIRD. **Play Flappy Bird**, ©2025. Disponível em: <https://flappybird.io/>. Acesso em: 5 nov. 2025.

ILHA DA ELETRÔNICA. **Módulo ECG AD8232 – monitorando batimento cardíaco**, [20-]. Disponível em: <https://www.ilhadaelettronica.com.br/modulo-ecg-ad8232-monitorando-batimento-cardiaco>. Acesso em: 22 out. 2025.

INSTRUCTABLES. **Mind Control**: 3-EEG Monitor, 2018. Disponível em: <https://www.instructables.com/Mind-Control-3-EEG-Monitor/>. Acesso em: 20 out. 2025.

KRUSIENSKI, Dean; SHIH, Jerry. Control of a visual keyboard using an electrocorticographic brain-computer interface. **Neurorehabilitation and Neural Repair**, Kansas City, v. 25, n. 4, p. 323-331, 2011. Disponível em: <https://doi.org/10.1177/1545968310382425>. Acesso em: 22 abr. 2026.

MACHADO, Sergio; CUNHA, Marlo; VELASQUES, Bruna; MINC, Daniel; BASTOS, Victor Hugo; BUDDE, Henning; CAGY, Maurício; PIEDADE, Roberto; RIBEIRO, Pedro. Interface cérebro-computador: novas perspectivas para a reabilitação. **Revista Neurociências**, São Paulo, v. 17, n. 4, p. 329-335, dez. 2009. DOI: 10.34024/rnc.2009.v17.8525. Disponível em: <https://periodicos.unifesp.br/index.php/neurociencias/article/view/8525>. Acesso em: 23 nov. 2025.

MANZAN, José Ricardo Gonçalves. **Análise de desempenho de redes neurais artificiais do tipo multilayer perceptron por meio do distanciamento dos pontos do espaço de saída**. Tese (Doutorado em Engenharia Elétrica), Universidade Federal de Uberlândia, Uberlândia, 2016. Disponível em: <https://repositorio.ufu.br/bitstream/123456789/17967/1/AnaliseDesempenhoRedes.pdf>. Acesso em: 24 out. 2025.

MASLOVA, Olga; KOMAROVA, Yulia; SHUSHARINA, Natalia; KOLSANOV, Alexander; ZAKHAROV, Alexey; GARINA, Elena; PYATIN, Vladimir. Non-invasive EEG-based BCI spellers from the beginning to today: a mini-review. **Frontiers in Human Neuroscience**, Lausanne, v. 17, p. 1216648, 2023. Disponível em: <https://doi.org/10.3389/fnhum.2023.1216648>. Acesso em: 22 abr. 2026.

NICOLAS-ALONSO, Luis Fernando; GOMEZ-GIL, Jaime. Brain Computer Interfaces: a Review. **Sensors**, Basel, v. 12, n. 2, p. 1211-1279, 2012. Disponível em: <https://doi.org/10.3390/s120201211>. Acesso em: 3 nov. 2025.

OTONI, Julliano da Silva. **Desenvolvimento de um aparelho de eletroencefalografia mobile de baixo custo**. Dissertação (Mestrado em Biotecnologia), Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2019. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/20a1f6dd-1671-4324-83bd-b3aaadcda9a7/content>. Acesso em: 20 out. 2025.

SANTOS, Rafael Leandro dos. **Estudo de mercado e análise de aplicabilidade de equipamentos de eletroencefalografia**. Trabalho de Conclusão de Curso (Engenharia Biomédica), Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2022. Disponível em: <https://pantheon.ufrj.br/handle/11422/13677>. Acesso em: 20 out. 2025.

SILVA, Gabriel Augusto da; SOUZA, Maria Luiza; RIBEIRO, Tiago Pereira. Sistema de aquisição de sinais cerebrais de baixo custo para fins educacionais. **Revista UniAcademia Elétrica**, Campinas, v. 15, n. 2, p. 33-45, 2021. Disponível em: <https://seer.uniacademia.edu.br/index.php/eletrica/article/view/4460/3346>. Acesso em: 20 out. 2025.

SOCIEDADE BRASILEIRA DE NEUROCIÊNCIAS E COMPORTAMENTO. **Recomendação da SBNC para localização de eletrodos e montagens de EEG**. [S. l.]: SBNC, 2017. Disponível em: https://sbnc.org.br/wp-content/uploads/2015/05/1512584738_Norma_montagens_EEG_.pdf. Acesso em: 22 out. 2025.