

Interface Cérebro-Computador Não-Invasiva: Desafios Sócio-Técnicos e Oportunidades para a Computação

Gabriel Alves Mendes Vasiljevic^{1,2}, Leonardo Cunha de Miranda²

¹Instituto Internacional de Neurociências Edmond e Lily Safrá
Instituto Santos Dumont (ISD)
59288-999 – Macaíba, RN – Brasil

²Departamento de Informática e Matemática Aplicada
Universidade Federal do Rio Grande do Norte (UFRN)
59078-900 – Natal, RN – Brasil

`gabriel.vasiljevic@isd.org.br, leonardo@dimap.ufrn.br`

Abstract. *This paper describes and discusses the hardware and software challenges of Brain-Computer Interface (BCI) systems in a sociotechnical perspective, as well as research, development and innovation opportunities for Computing related to non-invasive BCI. The challenges are organized into different system levels, allowing to identify research opportunities and how a number of subfields of Computing can contribute to the advancement of these technologies and for broadening its applications in clinical, assistive and interactive contexts.*

Resumo. *Este artigo descreve e discute desafios de hardware e software de sistemas de Interface Cérebro-Computador (ICC) numa perspectiva sócio-técnica, bem como, oportunidades de Pesquisa, Desenvolvimento & Inovação (PD&I) para a Computação relacionadas à ICC não-invasiva. Para isso, os desafios são organizados em diferentes níveis do sistema, permitindo identificar oportunidades de pesquisa e como diversas subáreas da Computação podem contribuir para o avanço dessas tecnologias e para a ampliação de suas aplicações em contextos clínicos, assistivos e interativos.*

1. Introdução

O início do século XXI vem apresentando profundas transformações no cotidiano do mundo contemporâneo devido aos avanços do conhecimento e das tecnologias produzidas pela humanidade nas últimas décadas. A Inteligência Artificial (IA) já não é apenas uma promessa, mas uma realidade em uso no dia-a-dia, impulsionada pelo desenvolvimento de modelos generativos de uso geral. Próteses biônicas, controladas pelos músculos ou até diretamente pelo cérebro, através das interfaces cérebro-computador (BCI, do inglês, Brain-Computer Interfaces), permitiram avanços não só nas áreas da saúde, como também no entendimento sobre o funcionamento do corpo e do cérebro. Todos esses avanços são impulsionados por diversas áreas do conhecimento, mas a Computação vem ganhando papel de protagonismo nessas transformações.

Tecnologias capazes de registrar, interpretar ou modular a atividade neural vêm sendo utilizadas como ferramentas para diagnóstico, reabilitação e treinamento cognitivo. BCIs representam uma dessas abordagens, permitindo estabelecer canais de comunicação

diretos entre o sistema nervoso e dispositivos computacionais, sem necessidade de músculos ou movimentos motores [Wolpaw et al. 2002]. O desenvolvimento de sistemas capazes de registrar e interpretar sinais neurais depende tanto da compreensão dos mecanismos fisiológicos que originam esses sinais quanto da construção de modelos computacionais capazes de representá-los de forma adequada [Vasiljevic e Miranda 2026].

Apesar desses avanços, o desenvolvimento de sistemas de BCI envolve uma série de desafios que se apresentam em diferentes níveis computacionais e uso desses sistemas, indo desde a aquisição e organização dos dados neurais até sua decodificação e integração em aplicações interativas. Por ser um campo multidisciplinar, esses problemas geralmente são abordados de forma fragmentada pelas áreas, concentrando-se em aspectos específicos do sistema ou em aplicações particulares. Dessa forma, torna-se pertinente analisar esses desafios a partir de uma perspectiva integrada, considerando o papel das diferentes subáreas da Computação nas soluções para esse domínio.

Neste contexto, este trabalho apresenta e discute desafios computacionais associados a sistemas de BCI não-invasivos a partir de uma organização em níveis, que abrangem desde a aquisição de sinais neurais até sua utilização em aplicações distribuídas e questões éticas associadas a este uso. Busca-se evidenciar oportunidades de pesquisa nas diversas subáreas da Computação que podem contribuir para o avanço dessa tecnologia.

Este artigo está organizado da seguinte maneira: a Seção 2 apresenta a fundamentação deste trabalho; a Seção 3 descreve os desafios associados aos diferentes níveis computacionais de sistemas de BCI; a Seção 4 apresenta as oportunidades de pesquisa e desenvolvimento para a Computação baseadas nestes desafios; a Seção 5 discute os resultados deste trabalho; e a Seção 6 conclui o artigo.

2. Interface Cérebro-Computador Não-Invasiva

Sistemas de BCI são capazes de interpretar a atividade cerebral e converter esta atividade em comandos para controlar aplicações externas. Nestes sistemas, os sinais neurais são adquiridos por sensores, processados e transformados em ações em um sistema digital ou físico como, por exemplo, o controle de um cursor no computador ou uma perna robótica. A Figura 1a ilustra este esquema com sensores de eletroencefalografia (EEG), uma técnica não-invasiva (ou seja, não requer cirurgias para implantes dos sensores) que mede o potencial elétrico pós-sináptico de neurônios piramidais localizados na camada mais externa do córtex. Esses sistemas têm sido investigados quanto ao seu uso tanto para aplicações clínicas quanto para aplicações em interação humano-computador, jogos, realidade virtual e treinamento cognitivo, com a vantagem de poder serem utilizadas mesmo por pessoas com perdas parciais ou totais do movimento do corpo [Edelman et al. 2025].

Além da arquitetura, neste trabalho também propomos uma representação de um sistema BCI em níveis. Sete níveis foram definidos pelos autores como uma forma de abstração do sistema BCI e com o intuito de melhor agrupar as questões relacionadas ao tema. A Fig. 1b apresenta uma visão geral destes níveis, isto é, (i) físico, (ii) de dados, (iii) de algoritmo, (iv) de aplicação, (v) distribuído, (vi) interface de usuário, e (vii) social.

É possível, ainda, traçar um paralelo entre as duas representações. Considerando um exemplo de um sistema de robótica baseado em imagética motora¹, a captação do sinal

¹ A imaginação de um movimento motor (p. ex., mover o braço ou a perna) sem realizar o movimento.




Figura 1. (a) Sistema de BCI baseado em EEG. (b) Organização em níveis de um sistema de BCI; o Social é transversal a todos os outros.

elétrico cerebral pelos eletrodos seria correspondente ao nível físico. A coleta e armazenamento destes dados no dispositivo computacional seria relacionado ao nível de dados, enquanto o pré-processamento e processamento dos dados (decodificação da intenção motora) seria o nível de algoritmos. O uso da intenção motora como um sinal de controle para o dispositivo robótico seria o nível de aplicação, enquanto sistemas em que múltiplos usuários atuam na mesma aplicação, mesmo que através de dispositivos diferentes, seria o nível distribuído. O nível de interface de usuário embarca a interface e a interação do usuário com esta interface, enquanto o nível social, além de possuir questões relacionadas a cada um dos outros níveis, também está relacionado à ética e regulação destes sistemas.

3. Desafios

Os desafios do tema são apresentados e discutidos nas próximas subseções pelos níveis representados na Fig. 1b. Os desafios foram descritos baseados em revisão de literatura de duas fontes: trabalhos secundários (revisões e meta-análises) que tratam de questões específicas ou gerais da área de BCI (p. ex., [Albaiati et al. 2025, Coin et al. 2020, Vasiljevic e Miranda 2020, Vasiljevic e Miranda 2024, Edelman et al. 2025]), e trabalhos primários advindos dos trabalhos secundários. Quando pertinente, estes trabalhos serão apontados de maneira específica em cada um dos desafios. Cabe destacar que o objetivo deste trabalho não é listar de modo exaustivo todos os desafios de sistemas de BCI, mas descrever os que estão mais relacionados à Computação e suas áreas temáticas.

3.1. Físico

O primeiro nível de um sistema de BCI consiste nos sensores e na aquisição de dados, incluindo os mecanismos de transdução analógico-digital da atividade neural, possíveis pré-processamentos embarcados nos dispositivos de coleta e os protocolos de transmissão de dados. Técnicas de transdução não-invasivas de sinais, como EEG, não possuem boa precisão espacial em comparação a técnicas invasivas, já que fazem uma medição indireta da atividade neural, o que introduz limitações físicas inerentes ao processo de medição. Essas restrições físicas também limitam as informações disponíveis para os níveis seguintes, pois os algoritmos de decodificação dependem de dados coletados neste nível.

Um desafio deste nível, relacionada também às limitações de coleta, é a (d#1.1) **baixa proporção sinal-ruído**. Além de ser um sinal captado na ordem de microVolts,

pode haver contaminação pela rede elétrica (60 Hz, no caso do Brasil) ou por outros sinais eletrofisiológicos como, por exemplo, batimentos cardíacos, o movimento de músculos, ou até dos olhos [Yadav e Maini 2025]. Muitos desses artefatos e ruídos ocorrem na mesma faixa de frequência que a atividade neurofisiológica, tornando a (d#1.2) **separação e localização das fontes** um desafio adicional da perspectiva computacional.

A etapa de transmissão de dados também integra a camada física. O principal desafio nesta etapa é a (d#1.3) **transmissão e sincronia dos dados em tempo real**. Sistemas cabeados geralmente possuem maior estabilidade e menor latência, sendo mais utilizados em ambientes laboratoriais. Em contrapartida, dispositivos sem fio permitem maior mobilidade, mas possuem contrapontos relacionados a largura de banda, perda de pacotes e latência variável. Cabe destacar que, como o processamento neural ocorre a nível de micro-/milissegundos, a sincronia entre os diferentes canais e entre cada canal e os eventos de interesse é tão importante quanto obter o dado em si.

De maneira geral, o nível físico estabelece os limites estruturais que afetam todas as demais camadas do sistema de BCI. A qualidade do sinal adquirido, a precisão temporal e a estabilidade da transmissão definem o conjunto de informações que vão estar disponíveis para o treinamento e uso do sistema e controle por parte dos usuários.

3.2. Dados

O nível de dados, definido a partir da coleta e envolvendo seu armazenamento e uso, possui desafios específicos decorrentes da natureza dos dados. Dados eletrofisiológicos contínuos, como EEG, são séries temporais com taxa de amostragem relativamente alta, entre centenas e milhares de Hertz, e geralmente multidimensionais, envolvendo espaço (número de canais e sua localização), tempo (amostras discretizadas em função da taxa de amostragem, tipicamente em Volts por segundo) e indivíduo (sujeitos experimentais). Em contextos experimentais e clínicos, é possível ainda haver uma dimensão adicional relacionada a condições experimentais ou sessões repetidas.

Do ponto de vista computacional, a combinação entre esses fatores (i.e., taxa de amostragem, número de canais, duração do registro e quantidade de coletas) pode resultar em (d#2.1) **volumes significativos de dados**. Em estudos com protocolos longitudinais (ou seja, com várias sessões experimentais por indivíduo), essa escala cresce proporcionalmente ao número de sessões. Embora esses dados geralmente sejam estruturados, o armazenamento requer o uso e a definição de formatos adequados, compressão sem perda de informações relevantes e metadados que guardam informações sobre a configuração do experimento e eventos que ocorreram durante as sessões experimentais.

Outro desafio desta camada é a (d#2.2) **segurança dos dados**. Dados eletrofisiológicos podem conter informações sensíveis que podem ser decodificadas, como estados emocionais, cognitivos ou clínicos do indivíduo (p. ex., detectar sua reação emocional a uma determinada imagem ou vídeo, ou se uma determinada condição clínica está presente ou não). Além disso, pode ser possível utilizar dados de EEG como biometria para identificar um indivíduo pelos padrões da atividade cerebral [Albaiati et al. 2025]. Portanto, deve-se levar em consideração metadados e propriedades estatísticas que podem ser anonimizados, já que pode ser possível a re-identificação dos indivíduos.

Esse armazenamento e organização dos dados é particularmente importante considerando o nível seguinte, de algoritmos. Como há alta variabilidade inter-sujeitos de

vido à diferenças fisiológicas naturais, dados armazenados de maneira incorreta podem incorrer em vazamento de dados durante o treinamento dos modelos de IA, principalmente considerando o processamento offline para uso posterior na decodificação online, resultando em *over-* ou *under-fitting* do modelo. Portanto, um outro desafio deste nível refere-se à (d#2.3) **padronização e rastreabilidade dos dados** ao longo de seu ciclo de vida, incluindo a definição de formatos padronizados de armazenamento e o registro das transformações aplicadas aos dados durante etapas de pré-processamento e análise.

3.3. Algoritmos

O nível de algoritmos compreende os métodos responsáveis por transformar os dados eletrofisiológicos brutos ou pré-processados em representações computacionais adequadas à inferência, classificação, regressão ou controle em tempo real. Este nível inclui técnicas de processamento digital de sinais, extração e seleção de características, redução de dimensões, modelagem e/ou análise estatística e aprendizado de máquina. Enquanto o nível físico estabelece os limites relacionados à informação decorrentes das propriedades naturais do sinal adquirido, o nível de algoritmos define como essas informações são estruturadas, combinadas e utilizadas para produzir os sinais de controle do sistema.

Um dos principais desafios deste nível decorre não somente da baixa proporção sinal-ruído, mas da (d#3.1) **variabilidade intrínseca dos dados**. Os algoritmos de decodificação devem processar sinais ruidosos, não estacionários e com distribuições estatísticas que variam entre e dentre indivíduos, sessões e condições experimentais. Modelos treinados em uma sessão podem apresentar diminuição de desempenho em sessões posteriores devido a, por exemplo, alterações na impedância dos eletrodos, no posicionamento dos sensores, ou nos estados cognitivo, emocional ou hormonal do usuário, além de outros fatores como sono, alimentação e uso de medicamentos. Essa característica impõe a necessidade de métodos capazes de adaptação contínua, atualização online de parâmetros e detecção de mudanças de distribuição estatística dos dados, evitando a necessidade de calibrações extensas e repetidas entre sessões.

A etapa de extração de características possui também um papel central nesse nível, com abordagens tradicionalmente focadas em análises no domínio do tempo, da frequência, no tempo-frequência, e métricas de conectividade funcional e de coerência entre canais diferentes. Em algoritmos baseados em aprendizado raso (*shallow learning*), é necessário escolher representações que estejam relacionadas ao fenômeno neurofisiológico que quer-se decodificar, como a imagética motora (p. ex., dessincronização seguida de sincronização na faixa de ondas beta) ou estados cognitivos (p. ex., proporção de ondas theta sobre ondas beta relacionada a estados de atenção [Torgersen et al. 2025]). A escolha dessas representações influencia diretamente na dimensionalidade do problema, na complexidade computacional e na interpretabilidade dos resultados. A (d#3.2) **seleção de características adequadas** envolve, portanto, um problema de otimização sob restrições de dimensionalidade, latência e capacidade computacional disponíveis.

A (d#3.3) **redução de dimensionalidade** é outro desafio deste nível. Considerando o exposto no d#3.1, e considerando ainda a alta dimensionalidade inerente aos dados multicanais e à representação de séries temporais discutida no nível de dados, técnicas baseadas em matrizes de covariância, como *manifolds* neurais e geometria Riemanniana [Andreev et al. 2025], têm sido usadas em dados invasivos para explorar as propriedades

estruturais da dinâmica cerebral em tarefas estereotipadas, e se mostrado consistente entre sessões, sujeitos e espécies diferentes [Schneider et al. 2023], apesar de ainda não ser possível obter o mesmo nível de precisão com dados não-invasivos. O método de redução de dimensionalidade e a métrica subjacente impacta a estabilidade do modelo, sua capacidade de generalização e o custo computacional de cada etapa/ passo de inferência.

Como comentado no nível de dados, o uso de sistemas de BCI gera uma quantidade considerável de dados. Sistemas em tempo real precisam processar essa quantidade de dados de maneira eficiente, e essa eficiência é tida como uma combinação da coleta, pré-processamento e do processamento em si. Algoritmos mais precisos não necessariamente são os mais rápidos, pois podem não capturar toda a complexidade das interações neurais entre diferentes áreas do cérebro e a dinâmica temporal destas interações. Portanto, há outros dois desafios relacionados ao processamento dos dados: (d#3.4) **processar grandes volumes de dados em tempo real**; e (d#3.5) **desenvolver modelos que consigam decodificar estados neurais a partir destes dados**, considerando que a informação pode estar incompleta ou corrompida devido aos desafios d#1.1 e d#3.1.

Esses desafios são particularmente importantes para os níveis seguintes, já que os modelos devem (d#3.6) **decodificar os dados em uma janela de tempo compatível com a integração sensorial e motora do indivíduo** (i.e., ser rápida o suficiente para o usuário sentir que a ação foi decorrente de sua intenção, com tempo de resposta que varia entre 200 a 300 ms [Shimada 2022]), o que impõe restrições à complexidade (tanto temporal quanto energética e espacial) do modelo utilizado e à arquitetura do sistema, principalmente em dispositivos embarcados. Neste caso, técnicas de predição parcial, ou seja, que estima o estado neural antes da janela temporal e depois corrige a saída à medida que novas amostras são adquiridas, podem reduzir a latência percebida pelo usuário.

3.4. Aplicação

O nível de aplicação envolve a utilização dos sinais de controle produzidos do nível anterior para realizar tarefas, como controle de dispositivos externos, comunicação assistiva, ou reabilitação motora. Nesse nível, a BCI deixa de ser um sistema separado de processamento de sinais e passa à integrar a aplicação computacional. Por este motivo, um dos desafios deste nível é a (d#4.1) **integração sistêmica**, ou seja, a necessidade de integrar o sistema de BCI a ambientes computacionais de naturezas distintas sem comprometer a consistência temporal e desempenho no processamento dos dados, a confiabilidade na comunicação entre os módulos controlados pela BCI e a estabilidade do sistema.

Outro desafio refere-se à (d#4.2) **reprodutibilidade e generalização das aplicações fora do ambiente experimental**. Sistemas com determinado desempenho em condições laboratoriais controladas podem apresentar alteração significativa quando utilizados em ambientes clínicos ou cotidianos, nos quais fatores como movimentação da pessoa, interferências ambientais e variações nas condições de uso introduzem fontes de variabilidade. A validação de aplicações requer, portanto, protocolos experimentais que considerem diferentes contextos de operação. A ausência de padrões e a diversidade de tarefas e métricas utilizadas na literatura também dificultam comparações diretas, tornando a avaliação objetiva de desempenho entre diferentes abordagens complexa.

Há também o desafio da (d#4.3) **interoperabilidade com dispositivos e infraestruturas externas**. Aplicações de BCI frequentemente dependem da comunicação com

outros sistemas. Essa integração exige a definição de APIs padronizadas, com formatos de dados compatíveis entre si e protocolos de comunicação capazes de garantir sincronização e consistência entre componentes distribuídos. Pelos aspectos de segurança, também é necessário que esses protocolos sejam seguros. Em contextos clínicos, a possível necessidade de integração com prontuários eletrônicos e outras plataformas institucionais também podem impor requisitos adicionais relacionados à segurança da informação, rastreabilidade das operações e compatibilidade com os padrões existentes.

3.5. Distribuído

O nível distribuído refere-se a cenários nos quais múltiplos sistemas de BCI são utilizados simultaneamente por diferentes usuários ou em diferentes ambientes físicos ou computacionais, no qual dados, estados ou sinais de controle podem ser compartilhados entre sistemas independentes. Nesse contexto, cada BCI opera como uma unidade funcional completa, com seus próprios sensores, algoritmos e interface de interação, mas pode participar de atividades coletivas que envolvem coordenação entre usuários ou integração com plataformas compartilhadas. Um dos desafios deste nível está relacionado à (d#5.1) **interoperabilidade entre diferentes sistemas de BCI**, que podem utilizar arquiteturas de software e formatos de dados diferentes. A ausência de padrões para representação de sinais, eventos e sinais de controle pode dificultar a comunicação entre sistemas ou limitar a possibilidade de integração em ambientes multiusuário.

Outro desafio refere-se à (d#5.2) **consistência e sincronização de estados entre múltiplos sistemas independentes**. Em aplicações colaborativas, diferentes usuários podem interagir simultaneamente com um ambiente compartilhado, como em tarefas cooperativas ou jogos. Para que a interação seja consistente, os sistemas de BCI envolvidos precisam manter uma representação sincronizada do estado do ambiente e das ações produzidas por cada participante. Diferenças de latência de rede, variações nas taxas de atualização dos sistemas ou discrepâncias no processamento local podem levar a inconsistências na percepção do ambiente compartilhado.

Aplicações mais recentes têm explorado cenários envolvendo múltiplos usuários em atividades cooperativas, que remete ao desafio de (d#5.3) **coordenação e colaboração cérebro-cérebro**. Esse tipo de aplicação investiga o compartilhamento de informações neurais ou estados cognitivos entre indivíduos durante a execução de tarefas conjuntas [Jiang et al. 2019], exigindo o alinhamento temporal de sinais advindos de diferentes indivíduos e a definição de métodos para combinar ou interpretar sinais de forma conjunta.

3.6. Interface de usuário

Este nível está relacionado ao uso do sistema através de uma interface de usuário (IU), em que os sinais de controle são apresentados na IU para influenciar o ambiente ou executar ações dentro do sistema. Assim, um desafio neste nível é a (d#6.1) **co-adaptação humano-sistema**, no qual ambos modificam seu comportamento ao longo do tempo para se adaptar ao outro. O sistema de BCI pode melhorar gradativamente o desempenho, mas também podem ocorrer instabilidades decorrentes de mudanças de comportamento do usuário ou nos parâmetros do modelo, que ocorrem simultaneamente.

A (d#6.2) **latência e precisão do controle percebido pelo usuário** é um outro desafio deste nível. Como o sistema de BCI traduz a intenção do usuário em uma ação,

atrasos significativos nesta decodificação faz com que o usuário possa não perceber a ação como derivada da sua intenção. Mesmo que haja uma captação de dados de qualidade, há limitações neurofisiológicas de quanto tempo o cérebro demora a gerar o sinal necessário para ser decodificado, necessitando, por vezes, que o algoritmo “preveja” a saída com menos dados que o necessário. Pode ser necessário planejar o design da interação considerando que nem sempre a decodificação será precisa ou rápida o suficiente.

A interação com sistemas de BCI pode ocorrer também em contextos multimodais, envolvendo a combinação de sinais neurais com outras formas de entrada ou feedback sensorial. Esse contexto está relacionado ao desafio de (d#6.3) **integração multimodal**, no qual diferentes fontes de informação, como sinais musculares, rastreamento ocular, sensores inerciais, estímulos visuais e auditivos, ou até dispositivos físicos, como mouse e teclado, são combinados para melhorar o controle ou a experiência do usuário. Por exemplo, aplicações de jogos e ambientes de realidade virtual podem explorar esse tipo de integração para criar interfaces mais naturais ou adaptativas. Porém, a fusão de múltiplas modalidades requer a sincronização precisa e consistente dos dados no tempo, o que faz esse desafio estar ligado tanto ao nível de algoritmos quanto ao nível distribuído.

Outro desafio é a (d#6.4) **variabilidade de estratégias cognitivas entre usuários**. Diferentes indivíduos podem utilizar estratégias mentais distintas para realizar a mesma tarefa, e essas estratégias podem variar ao longo do tempo para o mesmo usuário. Essa variabilidade pode afetar a consistência dos padrões neurais utilizados pelos algoritmos de decodificação [Niu et al. 2025]. Sistemas de BCI frequentemente dependem de treinamento nas quais o usuário aprende a produzir padrões neurais discrimináveis, o que introduz um desafio adicional relacionado à (d#6.5) **dependência de treinamento e aprendizado do usuário**. Em muitos casos, parte do desempenho do sistema depende da capacidade do usuário de adaptar seu comportamento cognitivo à IU, o que pode limitar a acessibilidade da tecnologia em populações com diferentes perfis cognitivos ou clínicos.

Por fim, a interação contínua com sistemas de BCI também impõe desafios relacionados à (d#6.6) **sobrecarga cognitiva e fadiga sensorial**. Muitas aplicações exigem que o usuário mantenha estados mentais específicos por períodos prolongados ou realize tarefas cognitivas repetitivas para produzir padrões neurais que possam ser decodificados pelo sistema. Esse processo pode resultar em fadiga cognitiva, redução da atenção ou perda gradual de desempenho ao longo da sessão, mesmo que o usuário aumente seu desempenho ao longo dos dias. Além disso, IUs baseadas em estímulos visuais ou auditivos podem introduzir sobrecarga sensorial e, portanto, o design das IUs deve considerar aspectos perceptuais que reduzam o esforço cognitivo do usuário.

3.7. Social

O nível social abrange os aspectos supra-sistemas de BCI, como questões éticas e regulamentatórias da implementação, avanço, uso e distribuição desses sistemas. Diferentemente das camadas anteriores, que tratam de desafios técnicos associados ao funcionamento do sistema, este nível envolve desafios sociais que surgem a partir da possibilidade de registrar, interpretar e inferir estados neurais de indivíduos. Um desses desafios refere-se à (d#7.1) **regulação e governança do uso de dados neurais**, incluindo a definição de diretrizes padronizadas para coleta, armazenamento, compartilhamento e uso desses dados em contextos clínicos, científicos e comerciais, assim como essas questões são tratadas com outros tipos de dados sensíveis, como a Lei Geral de Proteção de Dados.

Um segundo desafio está relacionado à (d#7.2) **privacidade e reidentificação de dados neurais**. Embora bases de dados possam passar por processos de anonimização, padrões de atividade cerebral podem funcionar como biomarcadores capazes de identificar indivíduos [Albaiati et al. 2025]. Modelos de aprendizado de máquina podem aprender essas “assinaturas neurais” para reconhecer ou associar registros a indivíduos específicos, mesmo quando os identificadores diretos foram removidos dos dados. Essa possibilidade está associada a questões éticas sobre a possibilidade de reidentificação involuntária de participantes e sobre o uso indevido de dados neurais em contextos nos quais a identidade do usuário deveria permanecer protegida [Ienca et al. 2022].

Outro desafio refere-se à (d#7.3) **inferência não intencional ou não desejada de estados mentais**. É possível que sistemas de BCI identifiquem informações sobre o estado interno de um indivíduo sem que este tenha explicitamente consentido com essa interpretação, através da decodificação de padrões associados a emoções, intenções ou estados cognitivos. Mesmo em aplicações que necessitem destas informações como parte de seu funcionamento, como jogos, monitoramento cognitivo ou interfaces adaptativas, a possibilidade de detectar emoções ou reações afetivas pode gerar situações de constrangimento ou de exposição involuntária de informações pessoais [Sun e Ye 2023].

Também há questões relacionadas à (d#7.4) **responsabilidade e segurança no uso desses sistemas**. Tecnologias assistivas controladas diretamente por sinais cerebrais podem resultar em ações incorretas ou potencialmente perigosas caso hajam falhas na decodificação da intenção do usuário. Nesse contexto, surge a questão de como e a quem atribuir responsabilidade em situações nas quais o comportamento do sistema diverge da intenção do usuário. Determinar se um erro deve ser atribuído ao algoritmo, ao sistema de aquisição, ao desenvolvedor ou ao próprio usuário é um problema semelhante ao discutido em tecnologias como veículos autônomos, porém com a particularidade de que o sinal de controle se origina diretamente da atividade neural do próprio indivíduo.

4. Oportunidades

Nesta seção, os desafios descritos na Seção 3 são agrupados com base nas oportunidades de pesquisa para as subáreas da Computação que podem abordar estes desafios, e, desse modo, provendo uma “agenda de pesquisa” de como cada área pode contribuir para o desenvolvimento e o avanço de sistemas de BCI. As oportunidades são apresentadas na Tabela 1, que relaciona cada nível aos desafios, oportunidades e áreas da Computação. As áreas da Computação relacionadas são indicadas pela sigla da respectiva Comissão Especial (CE- x)² da Sociedade Brasileira de Computação (SBC).

5. Discussão

A análise dos desafios mostra uma dependência entre os níveis, já que limitações no nível físico impactam diretamente a qualidade dos dados, que por sua vez condicionam o desempenho dos algoritmos e, conseqüentemente, a eficácia das aplicações e da interação do usuário. Essa propagação de restrições mostra que, assim como outros sistemas que podem ser vistos sob a perspectiva de múltiplos níveis, um sistema de BCI é acoplado. Portanto, melhorias isoladas num único nível podem ser insuficientes para avanços significativos, reforçando a necessidade de abordagens integradas que considerem simulta-

²Conforme descrito em: <https://sbc.org.br/comissoes-especiais/>.

Tabela 1. Oportunidades e áreas relacionadas a cada desafio computacional para sistemas baseados em BCI.

Nível	Oportunidade	Desafio associado	Área relacionada (CE-r)
1. Físico	- Desenvolvimento de sensores especializados: co-design de hardware e software, sensores multimodais integrados; - Sistemas embarcados para pré-processamento digital ou analógico em tempo real (filtragem embarcada).	1.1. Baixa proporção sinal-ruído	ACPAD, CCI & ESC
		1.2. Separação e localização de fontes	ACO, BioComp & IC
		1.3. Transmissão e sincronia em tempo real	RES D
2. Dados	- Estruturas de armazenamento escaláveis para séries temporais multicanaís; - Métodos de fusão de dados multimodais; - Compressão sem perda de informações.	2.1. Volume: quantidade de dados, multidimensionalidade, multimodalidade	BD
		2.2. Segurança dos dados	BD, ESC, IA & SEG
		2.3. Padronização e rastreabilidade dos dados	BD, ES & SI
3. Algoritmos	- Definição (e adoção) de formatos padronizados; - Estruturação de metadados; - Integração de bases heterogêneas.	3.1. Variabilidade intra- e inter-sujeitos, sessões e atividades	ACO, BioComp, IA & IC
		3.2. Seleção de características	ACO, BioComp, IA & IC
		3.3. Redução de dimensionalidade	ACO, BioComp, IA & IC
	- Generalização e tempo de treinamento; - Transferência de aprendizado (<i>transfer learning</i>); - Meta-aprendizado.	3.4. Processamento de grandes volumes de dados em tempo real	ACO & RES D
		3.5. Decodificação de estados neurais	ACO, ACPAD & IA
		3.6. Processamento e decodificação em tempo real	ACO, ACPAD & IA
4. Aplicação	- Métodos automáticos de seleção de atributos; - Otimização de subconjuntos de canais; - Integração com conhecimento neurofisiológico. - Modelos de representação latente (<i>autoencoders</i>, <i>manifolds</i> neurais); - Geometria Riemanniana; - Preservação de estrutura temporal e espacial. - Processamento incremental/<i>streaming</i>; - Paralelização; - Uso de <i>edge computing</i>. - Modelos probabilísticos e de deep learning; - Integração multimodal; - Modelagem temporal (p. ex., redes recorrentes); - Aprendizado resistente a ruído e dados incompletos	4.1. Integração sistêmica	ES & RES D
		4.2. Reprodutibilidade e generalização de aplicações	ES & IA
		4.3. Interoperabilidade com dispositivos e infraestruturas externas	SC & WEBMEDIA
5. Distribuído	- Arquiteturas orientadas a serviços; - APIs padronizadas	5.1. Interoperabilidade entre sistemas de BCI	ES, RES D, SC & WEBMEDIA
		5.2. Consistência e sincronização entre estados	ES, RES D & WEBMEDIA
		5.3. Coordenação e colaboração cérebro-cérebro	RES D & SC
6. Interface de usuário	- Padronização de protocolos; - Plataformas multiusuário; - Integração entre diferentes arquiteturas de BCI.	6.1. Co-adaptação humano-sistema	IA & IHC
		6.2. Percepção da latência e precisão do controle	ACO & IHC
		6.3. Integração multimodal	ES, IA & IHC
	- Algoritmos de sincronização distribuída; - Controle de consistência. - Modelos colaborativos multiusuário; - Compartilhamento de estados neurais.	6.4. Variabilidade de estratégias cognitivas (variabilidade cognitiva: estratégias mentais distintas, fadiga)	IA & IHC
		6.5. Dependência de treinamento e aprendizado do usuário	IA & IHC
7. Social	- Modelos adaptativos bidirecionais; - Aprendizado personalizado; - Sistemas interativos com feedback dinâmico. - Modelos personalizados/adaptativos; - Otimização de latência. - Fusão de dados multimodais; - Interfaces híbridas (EEG + <i>eye-tracking</i> etc.); - Sincronização entre modalidades. - Modelos personalizados; - Adaptação baseada no usuário.	7.1. Regulação e governança no uso de dados neurais	ES & SI
		7.2. Privacidade e reidentificação de dados neurais	IA & SEG
		7.3. Inferência não intencional ou não desejada de estados	ES, SEG, SI & TF
		7.4. Responsabilidade e segurança no uso de sistemas de BCI	ES, SEG, SI & TF

neamente aspectos de aquisição, processamento, modelagem e interação, incluindo estratégias de co-projeto e design entre hardware, algoritmos e IU.

Além disso, o nível social atua de forma transversal a todos os outros, introduzindo desafios relacionados à privacidade, segurança, regulação e responsabilidade. Esses aspectos influenciam desde a coleta e armazenamento de dados até o desenvolvimento de algoritmos e a implementação de aplicações, e ainda estão relacionados com alguns dos Grandes Desafios da Computação (2025-2035), como, por exemplo, os que tratam do uso responsável de IA, desenvolvimento de cibersegurança, e construção de ecossistemas computacionais éticos [Wagner 2025].

Cabe destacar as possíveis aplicações de sistemas de BCI em outras subáreas, além das mencionadas na Seção 4, como CE-R, CE-JOGOS e CE-RV. Muitas destas aplicações são possíveis devido à própria natureza desses sistemas e que estão relacionados também a seus desafios, já que permitem identificar e treinar, por exemplo, estados atencionais, estados cognitivos, controle de dispositivos externos e decodificação de intenções. Muitas dessas aplicações têm potencial de disseminação para o público em geral, como no Sistema Único de Saúde (SUS) ou em aplicações domésticas, considerando ainda o advento de tecnologias como dispositivos de aquisição comerciais de EEG.

Em relação às limitações deste trabalho, há um fator “subjetivo” na análise da relação entre os desafios e as oportunidades. Por ser um trabalho de natureza secundária e terciária, envolvendo a revisão de estudos experimentais e outras revisões, metodologias mais formais, como integrativas e sistemáticas, podem prover resultados diferentes.

6. Conclusão

Neste artigo, apresentamos desafios computacionais associados ao desenvolvimento, funcionamento e aplicações de sistemas de BCI, organizando-os em diferentes níveis que abrangem desde a aquisição de sinais neurais até sua utilização em aplicações interativas e ambientes distribuídos. A partir dessa organização em níveis, foram discutidas as limitações técnicas e operacionais em cada etapa do processamento e uso da atividade neural. A apresentação destes desafios e oportunidades visa compartilhar com a comunidade de Computação como diferentes subáreas podem contribuir para o avanço desse campo, servindo também como uma agenda de pesquisa para desenvolvedores e pesquisadores da área ou que desejam ingressar e conhecer sobre o campo.

Como trabalhos futuros, sugerimos, além do aprofundamento nas oportunidades de pesquisa apresentadas, o desenvolvimento de estudos que integrem de forma mais sistemática os diferentes níveis dos sistemas de BCI, além de metodologias padronizadas e interdisciplinares para o desenvolvimento desses sistemas, considerando a natureza multifacetada dos dados e das aplicações que estes sistemas são empregados.

Agradecimentos

Este trabalho foi apoiado pelo Grupo de Pesquisa em Artefatos Físicos de Interação (PAIRG) da Universidade Federal do Rio Grande do Norte (UFRN), e parcialmente financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq processo #157784/2025-8). Também agradecemos pelos recursos do Laboratório de Computação Física e Fisiológica do PAIRG (PAIRG L2PC) da UFRN.

Referências

- Albaiati, A. E. et al. (2025). Deep learning approaches for EEG-based biometrics: A systematic review. *IEEE Access*, 13:171025–171047.
- Andreev, A., Cattan, G., e Congedo, M. (2025). The riemannian means field classifier for EEG-based BCI data. *Sensors*, 25(7):2305.
- Coin, A., Mulder, M., e Dubljević, V. (2020). Ethical aspects of BCI technology: What is the state of the art? *Philosophies*, 5(4):31.
- Edelman, B. J. et al. (2025). Non-invasive brain-computer interfaces: State of the art and trends. *IEEE Reviews in Biomedical Engineering*, 18:26–49.
- Ienca, M. et al. (2022). Towards a governance framework for brain data. *Neuroethics*, 15(2).
- Jiang, L. et al. (2019). BrainNet: A multi-person brain-to-brain interface for direct collaboration between brains. *Scientific Reports*, 9(1).
- Niu, X., Yuan, M., e Wang, D. (2025). Influence of age, cognitive function, attention, and mental state on the effectiveness of EEG-based brain-computer interface device use: A systematic review. *Journal of NeuroEngineering and Rehabilitation*, 22(1).
- Schneider, S., Lee, J. H., e Mathis, M. W. (2023). Learnable latent embeddings for joint behavioural and neural analysis. *Nature*, 617(7960):360–368.
- Shimada, S. (2022). Multisensory and sensorimotor integration in the embodied self: Relationship between self-body recognition and the mirror neuron system. *Sensors*, 22(13):5059.
- Sun, X.-y. e Ye, B. (2023). The functional differentiation of brain–computer interfaces (BCIs) and its ethical implications. *Humanit Soc Sci Commun*, 10(1).
- Torgersen, E. L. et al. (2025). Decoding attention through EEG: Paving the way for BCI applications in attention-related disorders. In *47th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, page 1–7. IEEE.
- Vasiljevic, G. A. M. e Miranda, L. C. (2020). Brain–computer interface games based on consumer-grade EEG devices: A systematic literature review. *International Journal of Human–Computer Interaction*, 36(2):105–142.
- Vasiljevic, G. A. M. e Miranda, L. C. (2024). The CoDIS taxonomy for brain-computer interface games controlled by electroencephalography. *International Journal of Human–Computer Interaction*, 40(15):3908–3935.
- Vasiljevic, G. A. M. e Miranda, L. C. (2026). The MEG21 unified model for modern electronic games of the 21st century based on electroencephalography-controlled brain-computer interface. *Journal on Interactive Systems*, 17(1):143–163.
- Wagner, F. R. (2025). *Grandes Desafios da Computação 2025-2035*. SBC.
- Wolpaw, J. R. et al. (2002). Brain–computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6):767–791.
- Yadav, H. e Maini, S. (2025). Decoding brain signals: A comprehensive review of EEG-based BCI paradigms, signal processing and applications. *Computers in Biology and Medicine*, 196:110937.