

Algoritmos e Técnicas Computacionais em Interfaces Cérebro-Máquina para Recuperação Motora de Pacientes pós-AVC: uma Revisão Sistemática

Matheus William G. dos Santos¹, Francisco das C. Rocha¹, Rodrigo Augusto R. S. Baluz¹

¹Ciência da Computação – Universidade Estadual do Piauí (UESPI)
Caixa Postal 64.215-130 – Parnaíba – PI – Brasil

matheuswilliamsantos22@gmail.com, {rocha, rodrigo.baluz}@phb.uespi.br

Abstract. *Stroke is considered a global health problem, with motor paralysis as one of the main sequelae. In this scenario, devices called Brain-Machine Interface (BCI), make their treatment viable by converting brain signals into outputs that show the patient's intention. However, the construction of these devices has difficulties caused by the nature of these signals. Thus, this systematic review aimed to identify the algorithms and computational techniques used in BCIs for motor rehabilitation. The results showed the main algorithms, techniques and software used, as well as relevant information within the clinical context.*

Resumo. *O Acidente Vascular Cerebral (AVC) é considerado um problema global de saúde, tendo como uma das principais sequelas a paralisção motora. Neste cenário, dispositivos denominados Interface Cérebro-Máquina (ICM), viabilizam seu tratamento por meio da conversão de sinais cerebrais em saídas que mostram a intenção do paciente. Entretanto, a construção desses dispositivos possui dificuldades causadas pela natureza desses sinais. Com isso, esta revisão sistemática visou identificar os algoritmos e técnicas computacionais utilizados em ICMs para reabilitação motora. Os resultados evidenciaram os principais algoritmos, técnicas e softwares usados, bem como informações relevantes dentro do contexto clínico.*

1. Introdução

Nos últimos anos, o Acidente Vascular Cerebral (AVC) tem se tornado um problema global de saúde [Langhorne et al. 2011], sendo considerado o terceiro maior causador de incapacidade adulta em inúmeros países ao redor do mundo [Fisher et al. 2017]. Esta doença é decorrente da interrupção súbita do suprimento de sangue a uma parte específica do cérebro, provocando a paralisia da região [Langhorne et al. 2011, Markus 2008] e está diretamente ligada à vida cotidiana atual que inclui fatores como sedentarismo e estresse [Boehme et al. 2017]. Na maioria das ocorrências do AVC, o mais comum é que a vítima apresente sequelas, que podem ser motoras ou mentais. Entre as mais frequentes estão a dificuldade na fala [Crinion and Leff 2007] e paralisção de parte do corpo [Li et al. 2018]. Além disso, essas sequelas geram inúmeras consequências a longo prazo tanto para as vítimas quanto para suas famílias. Embora a reabilitação pós-AVC tenha sido aprimorada, ela ainda apresenta inúmeros desafios específicos, como:

tratamentos altamente complexos e específicos, custos elevados e lenta recuperação [Langhorne et al. 2011].

Dentro do contexto da saúde, diversas técnicas e algoritmos computacionais têm sido utilizadas para minimizar e auxiliar problemas causados não só pelo AVC [Asadi et al. 2014, Pichiorri et al. 2015], mas também por outras doenças [Khandoker et al. 2009, Borghese et al. 2013]. Esses algoritmos, muitos deles baseados em inteligência artificial, podem ser utilizados tanto em diagnósticos quanto em previsões e tratamentos [Amin et al. 2017, Doborjeh et al. 2018]. Tratando especificamente do AVC, a área de pesquisa dentro da Ciência da Computação denominada Interface Cérebro-Máquina (ICM) ou *Brain-Computer Interface* (BCI), vem possibilitando seu tratamento assim como outras doenças e sequelas cerebrais [Wolpaw et al. 2002]. Os dispositivos desenvolvidos dentro dessa área funcionam estabelecendo um canal de comunicação que converte sinais cerebrais em saídas que mostram a intenção do usuário ou paciente, permitindo a estimulação da plasticidade cerebral e acelerando tratamentos de reabilitação [Wolpaw et al. 2002].

Com base nisso, este trabalho é proposta uma revisão sistemática com o objetivo de apresentar e sumarizar os algoritmos e técnicas computacionais utilizados na construção de BCIs que utilizam EEG, Imagética Motora e *Neurofeedback* para reabilitação motora de pacientes pós-AVC. Esta revisão também concentra-se na identificação dos softwares e métricas de avaliação utilizadas para implementação e avaliação dos BCIs encontrados, também levando em consideração as informações relacionadas ao contexto clínico. A revisão foi realizada com base nas diretrizes definidas por [Kitchenham and Charters 2007], utilizando sete relevantes bibliotecas digitais para obtenção dos artigos primários e posterior seleção e análise dos estudos relevantes. Além disso, foram discutidas limitações e evidências encontradas, as quais são bastante relevantes para trabalhos futuros.

O artigo está organizado da seguinte forma: A seção 2 apresenta o referencial teórico dos conceitos abordados neste trabalho. Na seção 3 é apresentada a metodologia de pesquisa utilizada para condução da revisão. Na seção 4 são relatados os resultados obtidos ao final da revisão. Na seção 5 são feitas as discussões a respeito dos resultados encontrados. E por fim, na seção 6 as considerações finais são apresentadas, bem como recomendações de trabalhos futuros.

2. Referencial Teórico

2.1. Neuroplasticidade Cerebral

A Neuroplasticidade é uma característica cerebral extremamente importante que possibilita a reabilitação pós-traumas cerebrais. [Markus 2008] caracteriza a Neuroplasticidade como a capacidade das células cerebrais mudarem em resposta a fatores intrínsecos e extrínsecos, ou seja, sua habilidade para modificar sua organização estrutural própria e funcionamento. Sendo assim, a Neuroplasticidade é a propriedade do sistema nervoso que permite o desenvolvimento de alterações estruturais em resposta à experiência e como adaptação a certas condições e a estímulos repetidos [Cramer et al. 2011].

A cada experiência de um indivíduo, redes de neurônios são rearranjadas, outras inúmeras sinapses são reforçadas, e múltiplas possibilidades de respostas ao ambiente

tornam-se possíveis [Hammond 2007]. Além disso, em cada contato e estímulo realizado na época certa, faz-se a realização de conexões sinápticas, e criam-se condições favoráveis para o surgimento de determinadas habilidades e funções sejam elas motoras ou mentais [DeFelipe 2006]. Podemos concluir que a atuação correta no estímulo da plasticidade é fundamental para desenvolver uma boa função motora do paciente, e conseqüentemente, na sua reabilitação.

2.2. Eletroencefalograma e Imagética Motora

Um dos métodos mais utilizados para verificar a atividade cerebral do paciente após um caso de AVC é o eletroencefalograma, que é um exame de monitoramento não-invasivo que registra a atividade elétrica cerebral. Eles são capturados por máquinas EEG de múltiplos eletrodos, de dentro do cérebro, sobre o córtex, sobre o crânio ou em determinados locais no couro cabeludo, e podem ser gravados em diferentes formatos [Wolpaw et al. 2002]. Seu objetivo é registrar a atividade cerebral para detectar possíveis anormalidades neurológicas. O teste é mais usado para poder detectar uma variedade de doenças como: Epilepsia, problemas com perda de consciência, tumores cerebrais e inclusive mapear o estado cerebral após a ocorrência de um derrame.

Uma das maiores vantagens do EEG é o fato de sua gravação ser um processo não invasivo e de baixo custo comparado a outros processos. Além disso, [Niedermeyer and da Silva 2005] comprovaram conclusivamente que sinais de EEG são de fato produzidos pela atividade cerebral em vez de serem apenas uma representação de algum tipo de artefato, como sugeridos por alguns cientistas. Mais ainda, os traços de EEG são diferentes para diferentes atividades cerebrais [Mani and Dasgupta 2010]. Essas e outras vantagens tornam viáveis o uso desse tipo de gravação para monitoramento de sinais cerebrais em pesquisa na área de BCIs.

Uma das técnicas usadas para registro dos sinais EEG é a Imagética Motora que é basicamente uma técnica neurocognitiva baseada na representação mental, feita por algum paciente, de algum movimento motor sem que este ocorra efetivamente. [Bajaj et al. 2015] definiu a Imagética Motora como a capacidade de simular o movimento corporal, sem ser excessivamente manifestada como movimento físico. Este processo apresenta uma variedade subjacente de comportamentos cognitivos e motores, incluindo a observação da ação, operação mental cognitiva e planejamento de movimentos em cadeia aberta. Existem dois tipos de técnicas de imaginação: externas ou visuais, nas quais os sujeitos imaginam ver-se do ponto de vista de um observador externo e interno; ou cinestésico, em que os sujeitos imaginam as sensações de movimento em seus próprios corpos. [Pfurtscheller and Neuper 2001].

Usando Imagética Motora, a ciência nos últimos anos mostrou que as seqüências de ativação no córtex motor, durante as imagens mentais de um movimento, são similares àsquelas ocorridas durante a realização desse movimento [Zimmermann-Schlatter et al. 2008]. Esse achado serve como uma base científica para o desenvolvimento de uma metodologia para treinamento de imagens motoras em indivíduos saudáveis e deficientes. A Imagética Motora tem sido usada na reabilitação motora de pacientes com AVC [Liu 2004] e também tem sido associada ao BCI em diversos trabalhos com o mesmo intuito. Sua relevância se deve ao fato de oferecer ao paciente tratamentos não invasivos e menos desconfortáveis, além de sua eficácia comprovada.

2.3. Técnica de Neurofeedback

Um dos tratamentos mais eficientes utilizados para a recuperação de pessoas com seqüela pós-AVC é o *Neurofeedback* [Shindo et al. 2011]. Também chamado de neuroterapia, *neurobiofeedback* ou EEG *biofeedback*, o *Neurofeedback* é basicamente um tipo de *biofeedback* que utiliza variados métodos, como o eletroencefalograma, exibidos em tempo real, com a finalidade de monitoramento da atividade cerebral e a melhoria das regiões afetadas pela doença [Hammond 2007].

No caso do eletroencefalograma, um par de eletrodos são colocados no couro cabeludo e um ou dois são normalmente colocados nos lóbulos das orelhas. Em seguida, o equipamento eletrônico de alta tecnologia fornece *feedback* instantâneo em áudio e visual em tempo real sobre sua atividade de ondas cerebrais. Os eletrodos medem os padrões elétricos vindos do cérebro – da mesma forma que um médico ouve seu coração pela superfície de sua pele. Nenhuma corrente elétrica é colocada em seu cérebro. A atividade elétrica do cérebro é transmitida ao computador e registrada [Heinrich et al. 2007].

O *Neurofeedback* consiste no registro e análise automática da atividade elétrica do cérebro, com um considerável número de aplicações, com excelentes resultados. Se associado a outras técnicas, as aplicações podem bastante significativas, a exemplo do trabalho com atenção, foco e concentração; reabilitação cognitiva; regulação do sono e reabilitação motora [Doppelmayr et al. 2007].

Normalmente, uma pessoa não pode influenciar de maneira confiável seus padrões de ondas cerebrais porque não tem consciência deles. No entanto, quando o paciente pode ver suas ondas cerebrais em uma tela de computador alguns milésimos de segundo depois que elas ocorrem, isso lhe dá a capacidade de influenciá-las e alterá-las sendo o mecanismo de ação o principal condicionante [Heinrich et al. 2007]. No início, as mudanças são de curta duração, mas gradualmente se tornam mais duradouras. Com *feedback*, treinamento e prática contínuos, padrões de ondas cerebrais mais saudáveis geralmente podem ser retreinados na maioria das pessoas. É um pouco como exercitar ou fazer fisioterapia com o cérebro, melhorando a flexibilidade e o controle cognitivos [Shindo et al. 2011].

2.4. Interface Cérebro-Máquina

De acordo com a definição de [McFarland and Wolpaw 2011], uma Interface Cérebro-Máquina é um sistema que traduz atividades elétricas produzidas por sinais cerebrais em comandos, permitindo que usuários possam se comunicar controlando um dispositivo externo sem fazer uso de músculos ou nervos periféricos. Os sistemas de BCI podem ser utilizados tanto para objetivos de assistência quanto de reabilitação, fornecendo aos usuários em potencial um feedback sensorial dependente do estado cerebral (por meio de estimulação elétrica funcional, ambientes de realidade virtual ou sistemas robóticos).

Como descrito na Figura 1, o funcionamento desses dispositivos é composto por 4 etapas: aquisição de sinais, pré-processamento, extração de características (processamento de sinais) e reconhecimento de padrões [Wolpaw et al. 2002], podendo ser utilizadas algumas técnicas ao longo dessas etapas. Para a aquisição de sinais, o mais comum é que se utilize o Eletroencefalograma (EEG), que permite o registro da atividade elétrica cerebral de forma não-invasiva [Niedermeyer and da Silva 2005]. Entretanto, para a utilização eficiente do EEG, é necessário que o usuário produza ativi-

dade elétrica cerebral correspondente aos movimentos motores visados no tratamento. Neste cenário, aparece como alternativa o uso da técnica neurocognitiva conhecida como Imagética Motora. Baseada na representação mental, ela permite que o paciente consiga produzir sinais elétricos motores sem efetivamente realizar os movimentos correspondentes [Pfurtscheller and Neuper 2001]. Além da Imagética Motora, também é possível aplicar a técnica de *Neurofeedback* que permite ao paciente monitorar sua atividade cerebral em tempo real, lhe dando a capacidade de influenciá-la e alterá-la, acelerando o processo de reabilitação [Hammond 2007].

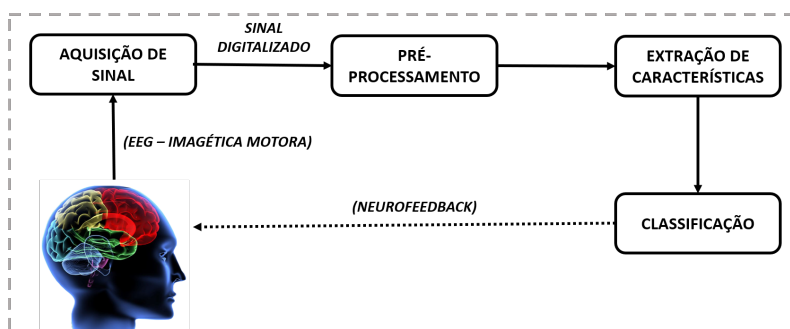


Figura 1. Funcionamento geral de um BCI

Na sua revisão, [Nicolas-Alonso and Gomez-Gil 2012] classificam as aplicações baseadas em BCI em cinco áreas principais: comunicação, controle do ambiente, locomoção, restauração motora e entretenimento. Falando mais especificamente de aplicações de BCI em reabilitação motora, existem treinamentos onde o BCI fornece feedback ao córtex sensorio-motor e, com isso, o movimento é restaurado à medida que as vias cerebrais se reorganizam para conectar comandos motores a movimentos motores. Usuários podem adquirir controle seletivo sobre certas áreas do cérebro por meio de *Neurofeedback*, técnica citada e descrita anteriormente, como objetivo de induzir mudanças no comportamento do cérebro.

Por fim, existem diversos caminhos para a construção de um BCI. Diferentes propósitos levam a diferentes escolhas de algoritmos e métodos, além de diferentes tipos de sinais de controle, ou seja, para cada finalidade, um algoritmo ou conjunto de algoritmos pode ser mais adequado para apresentar um melhor resultado. Se o objetivo, por exemplo, é criar um sistema para traduzir comandos motores imaginados de forma voluntária (Imagética Motora), então um tipo de sinal de controle que pode ser usado são os ritmos sensorio-motores, que podem ser observados, por exemplo, sobre o córtex motor. Com base nisso e nos conceitos e técnicas supracitadas, apresentamos a metodologia que guia esta revisão.

3. Metodologia de Pesquisa

Revisão Sistemática da Literatura é uma revisão sistematizada que visa identificar, avaliar e sintetizar evidências de resultados empíricos, a fim de responder a uma ou mais questões de pesquisa e também retratar o estado da arte na área pesquisada [Kitchenham and Charters 2007]. Este tipo de revisão deve ser feita seguindo um protocolo bem definido, sendo este protocolo composto pelas próprias questões de pesquisas, estratégias e critério na busca de estudos, seleção dos trabalhos relevantes e extração de

dados [Carvalho et al. 2019, Kitchenham and Charters 2007]. Existem inúmeros artigos detalhando revisões sistemáticas cujos temas abordam alguns dos conceitos utilizados nesta revisão como [Carvalho et al. 2019] e [Kinney-Lang et al. 2016].

Com isso, foi modelada esta Revisão Sistemática da Literatura na qual o planejamento, a execução, bem como a descrição da análise dos resultados seguiram as diretrizes sugeridas por [Kitchenham 2007]. Além disso, esta revisão foi conduzida com o auxílio da ferramenta online Parsifal¹, que foi criada baseada nessas diretrizes. Segundo [Klock 2018], o Parsifal é uma ferramenta on-line criada para auxiliar os pesquisadores na elaboração de revisões sistemáticas, a qual permite que os pesquisadores trabalhem colaborativamente de forma mais simples e sem limitação de plataforma.

Segundo estas diretrizes, a Revisão Sistemática é dividida em seis etapas, sendo elas: identificação da questão de pesquisa, desenho da estratégia de busca, seleção do estudo, avaliação da qualidade do estudo, extração de dados e síntese dos dados. Nas subseções subsequentes serão detalhados os critérios definidos para a realização de cada uma dessas etapas.

3.1. Objetivo e Questões de Pesquisa

O objetivo desse estudo foi identificar algoritmos e técnicas utilizados na construção de Interfaces Cérebro-Máquina combinadas com EEG, *Neurofeedback* e Imagética Motora, propostos na literatura e analisar suas funcionalidades bem como as métricas de avaliação utilizadas. Para atingir esse objetivo, foram definidas as seguintes questões de pesquisa (QP): (QP1) Quais trabalhos, ao longo do período definido, propõem o uso de Interface Cérebro-Computador com EEG, *Neurofeedback* e Imagética motora na reabilitação motora de pacientes pós-AVC?; (QP2) Quais as técnicas e algoritmos computacionais estão sendo utilizados na construção dessas interfaces?; (QP3) Quais métricas estão sendo utilizadas para avaliar a eficiência desses algoritmos e técnicas?; (QP4) Quais softwares são utilizados para a realização das etapas dos BCIs?

3.2. Estratégia de Busca

A estratégia de busca é utilizada para encontrar estudos primários que serão utilizados para a condução da revisão. A estratégia deste trabalho empregou uma cadeia de pesquisa construída com base na estrutura PICOC. Esta estrutura, apresentada no trabalho de [Kitchenham and Charters 2007], define que a questão principal de uma Revisão Sistemática é reescrita em termos de cinco elementos: População, Intervenção, Comparação, Resultado e Contexto. Podemos ressaltar que, de acordo com [Uman 2011], a PICOC pode ser bastante útil para garantir que se decida sobre todos os componentes-chave antes de iniciar a revisão. Neste trabalho, o componente “comparação” não foi utilizado devido ao objetivo da revisão sistemática ser de caracterizar as evidências existentes. A estrutura PICOP deste trabalho ficou definida como: População - Sujeitos com sequela motora pós-AVC; Intervenção - Interface cérebro-computador com EEG, *Neurofeedback* e Imagética Motora para a reabilitação motora pós-AVC; Resultado - Algoritmos e técnicas computacionais usadas na construção de Interface Cérebro-Computador com *Neurofeedback*, EEG e Imagética Motora bem como suas métricas de avaliação.; Contexto - Projetos que visam o desenvolvimento de BCIs com *Neurofeedback* para a reabilitação motora de pacientes pós-AVC.

¹<https://parsif.al>

Tabela 1. String de Busca

Base de Dados	String
<i>Neurofeedback</i>	" <i>Neurofeedback</i> " OR " <i>Biofeedback</i> " OR " <i>EEG Feedback</i> "
Interface Cérebro-Máquina	" <i>Brain-Computer Interface</i> " OR " <i>Brain-Machine Interface</i> " OR "BCI" OR "BMI"
EEG	"EEG" OR " <i>Electroencephalography</i> " OR " <i>Electroencephalogram</i> "
AVC	" <i>Stroke</i> "

As bases estabelecidas para a captura dos artigos foram as seguintes: Biblioteca Digital do IEEE, Science Direct, Biblioteca Digital da ACM, SCOPUS, PUBMED, Springer Link e Web of Science. Essas bases de dados foram escolhidas pois possuem inúmeros trabalhos relacionados tanto a área de Ciência da Computação quanto de Ciências Médicas.

Posteriormente, determinou-se que a pesquisa consideraria apenas termos em inglês para a escolha das strings de busca utilizadas em cada base de dados, devido a maior disponibilidade e credibilidade de trabalhos nesse idioma. Para a montagem dessas strings, foi utilizada a plataforma DECS², com o uso dela é possível encontrar todos os descritores relacionados a um termo requisitado sendo esses termos estando relacionados à área da saúde, deixando assim, mais preciso o processo de busca dos artigos como relatado na revisão feita por [Nunes et al. 2011]. A Tabela 1 apresenta as palavras e sinônimos usadas para a montagem das strings de busca tendo como base os seguintes termos principais: *Neurofeedback*, Interface Cérebro-Máquina, EEG e AVC.

3.3. Critérios de Seleção

Os estudos foram incluídos nessa revisão caso atendessem aos seguintes critérios: (1) Artigos escritos em inglês, publicados entre 1 de janeiro de 2010 e 31 de agosto de 2019; (2) Artigos que tenham disponibilidade de acesso completo em sua respectiva base digital; (3) Artigos que usaram BCI para reabilitação motora de pacientes com sequelas pós-AVC; (4) Artigos que usaram sinais de EEG como entrada para ao BCI; (5) Artigos que descreveram as técnicas e algoritmos utilizadas para a construção de um BCI.

Além disso, estudos foram excluídos caso atendessem a pelo menos um dos seguintes critérios: (1) Artigos do tipo revisão, capítulos ou estudos descritivos; (2) Artigos que estejam indisponíveis para leitura na íntegra ou escritos em outras línguas; (3) Artigos que descrevem a construção de um BCI sem o uso da técnica de *Neurofeedback*; (4) Artigos que não fazem uso de sinais de EEG como entrada e/ou não associada à Imagética Motora; (5) Artigos que tratam de BCI não associada à função de reabilitação motora pós-AVC.

3.4. Critérios de Qualidade

Após o processo de seleção, os artigos restantes passaram pela aplicação de critérios de qualidade a fim de mensurar sua credibilidade e relevância. Os critérios de qualidade usados nesta revisão foram onze questões elaboradas com base na adaptação do modelo Critical Appraisal Skills Program (CASP)³, sendo assim, denominadas de questões de

²<http://decs.bvs.br>

³http://casp-uk.net/wp-content/uploads/2018/01/CASP-Systematic-Review-Checklist_2018.pdf

Tabela 2. Questões de qualidade

Identificação	Descrição
QQ1	O documento é baseado em pesquisa (ou é meramente um relatório de "lições aprendidas" baseado em opiniões de especialistas)?
QQ2	Existe uma descrição adequada do contexto em que a pesquisa foi realizada?
QQ3	Existe uma declaração clara dos objetivos da pesquisa?
QQ4	O desenho da pesquisa foi apropriado para abordar os objetivos da pesquisa?
QQ5	A estratégia de recrutamento foi adequada aos objetivos da pesquisa?
QQ6	Os dados foram coletados de forma a abordar a questão da pesquisa?
QQ7	A análise de dados foi suficientemente rigorosa?
QQ8	O método de estimativa proposto é comparado com outros métodos?
QQ9	As conclusões do estudo são claramente declaradas e apoiadas pelos resultados do relatório?
QQ10	As limitações do estudo são analisadas explicitamente?
QQ11	O estudo agrega valor à comunidade acadêmica ou clínica?

qualidade (QQ), bem como descrito na Tabela 2. Para cada artigo, cada questão recebeu uma resposta de "sim" ou "não", sendo a resposta "sim" equivalente a 1 ponto nessa análise. Por fim, após o somatório do resultado dessas questões, cada artigo obteve uma nota de qualidade de 0 a 11. Todos os artigos com nota inferior a 7 foram excluídos da etapa seguinte.

3.5. Extração dos Dados

Para a etapa de extração dos dados foi levado em consideração o objetivo do trabalho e as questões de pesquisa. Sendo assim, foi definido que as informações a serem obtidas seriam respectivamente: Autor, Ano, Membro (Superior ou Inferior), Tipo de BCI (Puro ou Combinado), Técnica Combinada (em caso de BCI do tipo combinado), Tipo de feedback, Funcionamento do BCI (Online ou Offline), Dataset (em caso de funcionamento offline do BCI), Número de Participantes, Software (se utilizado algum), Técnica para Aquisição do Sinal, Técnica para Pré-Processamento do Sinal, Técnica para Processamento do Sinal, Técnica para Reconhecimento/Classificação do Sinal, Métrica(s) de Avaliação dos Algoritmos e Métrica(s) de Avaliação Clínica.

4. Resultados

4.1. Seleção dos Estudos

Todo o processo de planejamento e execução da revisão foi realizado por dois pesquisadores independentes dentre o período de 10 de abril a 21 de outubro de 2019. Inicialmente, foram obtidos os artigos com a utilização das strings de busca definidas nas bases de dados citadas anteriormente. Em seguida, foi iniciado o processo de seleção, com a remoção de todos os artigos duplicados. O processo continuou com a seleção após a leitura de título, palavras-chave e abstract, seguido da seleção por leitura completa. Por fim, os artigos restantes passaram respectivamente pela aplicação dos critérios de qualidade e a pela etapa de extração dos dados. Ao longo da execução desses passos, foi calculado o índice Kappa de [Cohen 1968] por duas vezes, a fim de mensurar o nível de concordância entre os pesquisadores.

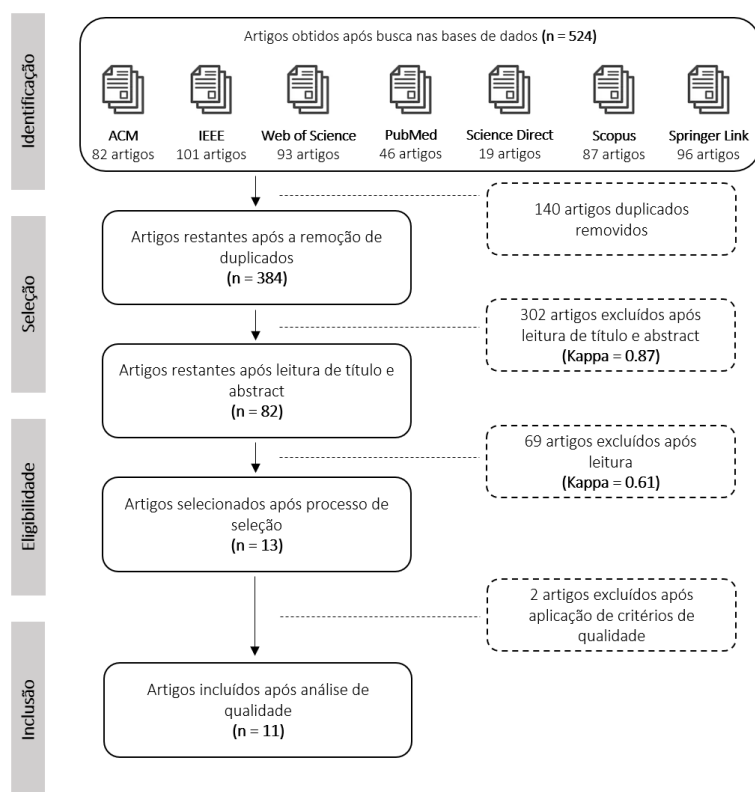


Figura 2. Fluxo de Execução da Revisão Sistemática

Tabela 3. Pontuações de qualidade

Pontuação	Referências
6	[McMahon and Schukat 2018], [Mizuno et al. 2018]
9	[Irmia et al. 2017]
10	[Chowdhury et al. 2018], [Cincotti et al. 2012], [Cisotto et al. 2014], [Frisoli et al. 2012], [Liang et al. 2013], [Shindo et al. 2011], [Arvaneh et al. 2014]
11	[Ang and Guan 2015], [Naros and Gharabaghi 2017], [Prasad et al. 2010]

A Figura 2 mostra o diagrama que representa o fluxo dos processos realizados pela nossa revisão. Por meio da pesquisa inicial, foram obtidos 524 artigos e, após a análise independente feita por dois revisores, foram obtidos dois índices Kappa, sendo o primeiro calculado após a primeira fase de seleção (leitura de título, abstract e palavras-chave) e o segundo calculado após a segunda fase de seleção (leitura completa dos artigos). Os valores desses índices foram 0,87 e 0,61, respectivamente, indicando uma boa concordância entre os revisores. Além disso, todos os desacordos foram resolvidos entre os mesmos dois revisores, resultando ao final em 13 artigos, que passaram posteriormente pelas etapas de aplicação da avaliação de qualidade e extração dos dados.

4.2. Avaliação de Qualidade

A Tabela 3 apresenta uma distribuição dos artigos selecionados de acordo com sua respectiva pontuação de qualidade. Nota-se que três artigos alcançaram a pontuação máxima (11 pontos), e que a menor pontuação aplicada (6 pontos), foi dada a dois artigos, os quais foram excluídos da etapa de extração dos dados. Os demais artigos tiveram suas pontuações

equivalentes a 9 ou 10 pontos.

4.3. Informações Clínicas dos Estudos

Em relação aos dados clínicos, por meio da Tabela 4 observa-se uma enorme similaridade entre todos os artigos em dois quesitos: membros alvo da reabilitação e funcionamento do BCI (tempo real ou offline). No primeiro quesito, nota-se que todos tiveram como foco de reabilitação os membros superiores. Essa preferência, observada também por [Varghese 2009], pode ser explicada pela localização anatômica da região que produz sinais cerebrais correspondentes aos membros inferiores. O que dificulta a detecção de imagética motora durante gravações de EEG. No segundo, identifica-se que apenas o BCI detalhado por [Arvaneh et al. 2014] possui funcionamento offline. [Arvaneh et al. 2014] teve como objetivo a proposição e comparação do algoritmo OSSSF com outros 5 baseados no algoritmo CSP. Para validação, o OSSSF foi avaliado com o uso de um conjunto de dados coletados por [Ang and Guan 2015] de 11 pacientes pós-AVC que realizaram tratamento de neuro-reabilitação. Em razão disso, as informações clínicas correspondentes a este BCI, foram coletadas de acordo com [Ang and Guan 2015].

Os BCIs foram classificados em tipo puro e combinado, sendo o tipo combinado caracterizado pela utilização de outra técnica além do EEG, seja ela para captação de outros tipos de sinais, como a Eletromiografia (EMG), ou para alguma estimulação feita previamente ou ao longo do processo de reabilitação como a Estimulação Elétrica Transcraniana (tDCS), Estimulação Transcraniana de Corrente alternada (tACS) e Estimulação Magnética Transcraniana (TMS). Além dessas já citadas, destaca-se [Frisoli et al. 2012], cuja abordagem clínica se baseou na aplicação do sistema de Kinect, para facilitar o processo de imersão do paciente durante a realização da imaginação motora e do sistema de rastreamento ocular para analisar com mais precisão a intenção de movimento dos usuários.

Em relação aos tipos de feedback relatados, houve uma considerável variabilidade de combinações com frequente recorrência do feedback de tipo robótico, cuja aparição esteve em todos os trabalhos com exceção de [Liang et al. 2013] e de uma das abordagens de [Cincotti et al. 2012]. Os outros tipos de feedback encontrados foram: Estimulação Elétrica Funcional (FES), Áudio e tACS. O tACS reaparece nesta posição pois foi aplicado aos participantes de [Naros and Gharabaghi 2017] na etapa seguinte ao treinamento BCI de acordo com suas imaginações motoras.

As quantidades de participantes recrutados em cada trabalho foram bastante distintas entre si. Essas quantidades variaram de 2 participantes, descrito por [Cisotto et al. 2014] a até 54 participantes, encontrada em uma das abordagens realizadas por [Ang and Guan 2015]. A diferença significativa entre esses valores decorre dos distintos objetivos de cada tratamento, bem como a capacidade dos autores em realizar o monitoramento da evolução clínica dos participantes ao longo dos treinamentos com BCI.

A variabilidade entre as abordagens de reabilitação motora empregadas também ocasionou em métricas de avaliações clínicas relativamente distintas. Em [Prasad et al. 2010], houve a maior quantidade de métricas calculadas, sendo relatadas: Valor de Dessincronização Relacionada a Eventos (ERD), Coeficiente de Correlação de Pearson, Aderência, Índice de Motricidade (Mcl), Teste do braço de pesquisa-ação (ARAT), Índice de Força de Preensão (GS), e Teste de Peg de Nove Buracos (NHPT).

Tabela 4. Informações clínicas dos estudos selecionados

Estudo	Membro	Tipo de BCI	Técnica Combinada	Tipo de Feedback	Tempo Real/ Offline	Dataset	Pop.	Métricas de Avaliação Clínicas
[Prasad et al. 2010]	Superior	Combinado	EMG	Visual + Robótico	Tempo Real	-	5	Coefficiente de Correlação de Pearson, Aderência, Valor de ERD, Mcl, ARAT, GS, NHPT
[Shindo et al. 2011]	Superior	Combinado	EMG + TMS	Visual + Robótico	Tempo Real	-	8	Valor de ERD
[Cincotti et al. 2012]	Superior	Puro	-	Visual	Tempo Real	-	29	Densidade Espectral
	Superior	Combinado	EMG + TMS	FES + Robótico	Tempo Real	-	29	Densidade Espectral
[Frisoli et al. 2012]	Superior	Combinado	Kinect + Rastreamento Ocular	Visual + Robótico	Tempo Real	-	4	-
[Liang et al. 2013]	Superior	Puro	-	Visual + Audio + FES	Tempo Real	-	8	-
[Arvaneh et al. 2014]	Superior	Puro	-	Robótico	Offline	[Ang et al. 2011]	11	-
[Cisotto et al. 2014]	Superior	Puro	-	Visual + Robótico	Tempo Real	-	2	Densidade Espectral
[Ang and Guan 2015]	Superior	Puro	-	Robótico	Tempo Real	-	54	Índice FMIMA
	Superior	Combinado	tDCS	Robótico	Tempo Real	-	37	Índice FMIMA
	Superior	Puro	-	Robótico	Tempo Real	-	34	Índice FMIMA
[Irimia et al. 2017]	Superior	Puro	-	FES + Robótico	Tempo Real	-	2	Valor de ERD
[Naros and Gharabaghi 2017]	Superior	Combinado	tACS	Robótico	Tempo Real	-	10	Valor de ERD
	Superior	Combinado	tACS	tACS + Robótico	Tempo Real	-	10	Valor de ERD
[Chowdhury et al. 2018]	Superior	Combinado	EMG	Visual + Robótico	Tempo Real	-	20	-

Primeiramente, a ERD trazida em [Shindo et al. 2011], [Irimia et al. 2017] e [Naros and Gharabaghi 2017], corresponde à atenuação de curta duração ou o bloqueio de ritmos na banda alfa (beta) presentes na atividade cerebral e reflete uma diminuição da atividade oscilatória relacionada a eventos de ritmo interno ou externo. Por conseguinte, a ERD está intrínsecamente ligada à detecção de imagética motora pois, momentos antes ou durante a execução de um movimento, os ritmos mu e beta se dessincronizam. A segunda métrica, é caracterizada por medir o grau de correlação entre duas variáveis de escala métrica, no trabalho em questão essas variáveis foram os valores de ERD e a acurácia de classificação. Já a aderência mensura a confortabilidade do usuário ao utilizar o BCI. O McI é definido como um método que calcula a força dos membros. A métrica ARAT é uma medida usada por profissionais de saúde para avaliar o desempenho dos membros superiores na reabilitação de AVC, lesões cerebral e populações de esclerose múltipla. O GS estima força de preensão voluntária das mãos. E por último, NHPT é usado para medir a agilidade dos dedos em pacientes.

Outrossim, as métricas descritas nos demais artigos selecionados ficaram entre Densidade Espectral (Ritmos EEG), Índice FMMA e novamente o valor de ERD. A Densidade Espectral de Potência, calculada por [Cincotti et al. 2012] e [Cisotto et al. 2014] representa a distribuição da potência em função da frequência. O Índice FMMA, medido em [Ang and Guan 2015], é um índice que mensura o comprometimento sensorio-motor de pacientes que pós-AVC. Em [Frisoli et al. 2012], [Liang et al. 2013], [Arvaneh et al. 2014] e [Chowdhury et al. 2018] não houve apresentação de nenhuma métrica de avaliação clínica evidente para ser considerada nesta revisão.

4.4. Informações Computacionais dos Estudos

4.4.1. Aquisição de sinais e Pré-processamento

Na Tabela 5 estão sumarizados os métodos e algoritmos usados nas etapas de aquisição de sinais e pré-processamento. As informações a respeito da primeira etapa informam as quantidades de eletrodos/canais EEG utilizados por cada trabalho, cujos variam de 2 canais, como descrito por [Prasad et al. 2010] a até 45 eletrodos, tal como em [Irimia et al. 2017]. Essas distinções podem ser explicadas pelas diferentes demandas e recursos/equipamentos disponíveis. Por exemplo, quanto maior o número de eletrodos empregados na aquisição de sinais, maior a quantidade de dados coletados e consequentemente mais custoso se torna o processamento ao longo do fluxo de execução do BCI.

A respeito das informações de pré-processamento, percebe-se que as distinções entre os BCIs encontrados permanecem, porém de forma menos evidente. A maioria dos trabalhos empregou o uso de dois filtros cujas finalidades são bastante similares, sendo eles: Passa-Faixa e Notch, com pequenas diferenças entre as faixas de frequência estipuladas. O primeiro filtro é responsável pela passagem de frequências de uma faixa definida, e pela atenuação de frequências que se encontram fora dessa faixa. Já o segundo caracteriza-se pela permissão da passagem da maioria das frequências inalteradas, e atenuação daquelas que estejam em uma faixa determinada. O único trabalho que fugiu desse padrão foi o de [Frisoli et al. 2012], o qual detalhou apenas o processo de digitalização de sinais utilizado.

Tabela 5. Métodos de Aquisição de Sinais e Pré-processamento utilizados

Estudo	Aquisição de Sinais	Pré-processamento
[Prasad et al. 2010]	2 canais bipolares	Filtro passa-faixa (0.5 - 30Hz) com filtro Notch (50 Hz) e amostrado em 500 Hz
[Shindo et al. 2011]	-	Filtro passa-faixa (2 - 100 Hz) e digitalizado em 256 Hz
[Cincotti et al. 2012]	32 eletrodos	Filtro passa-faixa (0.1– 70 Hz)
[Frisoli et al. 2012]	13 eletrodos	Digitalizado em 256 Hz
[Liang et al. 2013]	16 canais	Filtro passa-faixa (8-30Hz) e digitalizado em 256Hz
[Arvaneh et al. 2014]	27 canais	Filtro passa-faixa (8-35 Hz) com filtros elípticos
[Cisotto et al. 2014]	18 eletrodos	Digitalização em 512Hz com 16 amostradores e 16 quantizadores, resolução de 24-bits, filtro passa faixa (0.1 - 60 Hz) e filtro notch (50 Hz).
[Ang and Guan 2015]	27 canais com eletrodos unipolares	Digitalização em 250 Hz e filtro passa-faixa (0.05 - 40 Hz)
[Irimia et al. 2017]	45 eletrodos	Filtro passa-faixa (8 - 30) Hz.
[Naros and Gharabaghi 2017]	32 eletrodos	Filtro passa-alta (0.16Hz) e filtro passa-baixa (1 kHz)
[Chowdhury et al. 2018]	12 eletrodos	Filtro passa-faixa (0.1 - 100 Hz), amostrado em 512 Hz e filtro notch (50 Hz).

4.4.2. Processamento e Reconhecimento de sinais

Por outro lado, na Tabela 6 estão listados os algoritmos e técnicas usadas no Processamento e Reconhecimento/Classificação de sinais. Entre os algoritmos de processamento, destaca-se a ampla utilização do algoritmo CSP, principalmente a partir de 2012, com variações relacionadas à sua implementação e busca por otimização de desempenho. O CSP é caracterizado por ter como objetivo maximizar a diferença entre duas classes de sinais, sendo vastamente utilizada em aplicações BCI na identificação de imagética motora de sinais equivalentes ao movimento da mão esquerda ou direita, por exemplo [Nicolas-Alonso and Gomez-Gil 2012]. Entre os estudos que o utilizaram, destacam-se [Arvaneh et al. 2014] e [Ang and Guan 2015]. No primeiro, foi descrita a implementação do algoritmo OSSSF, que tem como objetivo principal a minimização dos problemas de sensibilidade a ruídos e da dependência da faixa de frequência operacional do CSP, de forma simultânea, por meio de uma abordagem mútua baseada em informações em vez de usar a abordagem de validação cruzada. No segundo, foram descritas 3 abordagens de BCI utilizando o algoritmo denominado *Filter Bank Common Spatial Pattern* (FBCSP). O FBCSP foi proposto em busca de um aprimoramento do CSP por meio da combinação de um banco de filtros no início do processamento em conjunto da seleção dos recursos mais discriminativos do CSP usando o algoritmo MIBIF (Mutual Best Individual Feature). As demais técnicas utilizadas no processamento de sinais foram: Logaritmos de banda alfa e beta, Recursão de LevinsonDurbin recursion, Método de Máxima Entropia, Fusion Module, Burg Algorithm.

Tabela 6. Métodos de Processamento e Reconhecimento de Sinais utilizados

Estudo	Processamento	Reconhecimento/ Classificação de Sinais
[Prasad et al. 2010]	Power Spectral Density (PSD) + Yule-Walker equations + LevinsonDurbin recursion	Sistema de lógica fuzzy
[Shindo et al. 2011]	Logaritmos da banda alfa (8–16 hz) e banda beta (16–26 hz)	Análise Discriminante Linear (LDA)
[Cincotti et al. 2012]	Maximum Entropy Method	Combinação linear de características (EEG) + Valores R ² (EEG)
[Frisoli et al. 2012]	Common Spatial Patterns (CSP)	SVM + Filtro passa-baixa
[Liang et al. 2013]	Common Spatial Patterns (CSP)	SVM
[Arvaneh et al. 2014]	OSSSF	Naive Bayesian Parzen Window
[Cisotto et al. 2014]	Maximum Entropy Method	Maximum Entropy Method
[Ang and Guan 2015]	Filter Bank Common Spatial Pattern (FBCSP)	Filter Bank Common Spatial Pattern (FBCSP)
[Irimia et al. 2017]	Common Spatial Patterns (CSP)	Análise Discriminante Linear (LDA)
[Naros and Gharabaghi 2017]	Burg Algorithm (Auto Regressive Model)	Classificador Linear
[Chowdhury et al. 2018]	Common Spatial Patterns (CSP)	SVM (Linear kernel + Covariate shift adaption)

Na etapa de reconhecimento/classificação de sinais, destaca-se a utilização dos algoritmos de *Machine Learning*: *Lógica Fuzzy*, por [Prasad et al. 2010]; *Naive Bayes*, por [Arvaneh et al. 2014] e *Support Vector Machine* (SVM), por [Frisoli et al. 2012], [Liang et al. 2013] e [Chowdhury et al. 2018]. Sendo a SVM a mais requisitada. Em sua revisão sobre classificadores utilizados em BCIs, [Lotte et al. 2007] havia concluído que Máquinas de Vetores de Suporte são particularmente eficientes para BCIs, atribuindo essa eficiência à sua capacidade de regularização. Além disso, nota-se a aparição do algoritmo FBCSP após ter sido citado na etapa de processamento por [Ang and Guan 2015]. Os demais métodos utilizados foram: Combinação Linear de Características, Classificador Linear, Análise Discriminante Linear (LDA), Método de Máxima Entropia.

4.4.3. Softwares EEG

Na Tabela 7, são elencados todos os softwares empregados. Nota-se que 7 dos BCIs encontrados usufruíram do uso de pelo menos uma dessas ferramentas ao longo do funcionamento do sistema. O principal intuito dessa utilização é fornecer auxílio os projetistas BCI, a medida que os softwares geralmente oferecem funcionalidades de diversos algoritmos acelerando assim todo o processo de funcionamento e utilização do sistema. Ao todo, 4 softwares diferentes foram citados, sendo eles: *BCI2000*, *MATLAB Simulink*, *g.BSanalyze* e *RecoveriX*.

O *BCI2000*, citado por [Cisotto et al. 2014], [Naros and Gharabaghi 2017] e [Cincotti et al. 2012] possui aplicação desde a etapa de aquisição de dados até o processamento online do sinal, assim como o software *MATLAB Simulink*, mencionado por [Chowdhury et al. 2018] e [Prasad et al. 2010], e o software *g.BSanalyze*, reportado por

Tabela 7. Softwares utilizados

Estudo	Software
[Prasad et al. 2010]	MATLAB Simulink
[Shindo et al. 2011]	g.bSanalyze
[Cincotti et al. 2012]	BCI2000
[Frisoli et al. 2012]	-
[Liang et al. 2013]	-
[Arvaneh et al. 2014]	-
[Cisotto et al. 2014]	BCI2000
[Ang and Guan 2015]	-
[Irimia et al. 2017]	RecoveriX + g.Bsanalyze
[Naros and Gharabaghi 2017]	BCI2000
[Chowdhury et al. 2018]	MATLAB Simulink

[Shindo et al. 2011] e [Irimia et al. 2017]. Entretanto, o *g.BSanalyze* possui uma funcionalidade adicional de análise de dados, onde essa análise é obtida a partir da produção de gráficos gerados pelos resultados da fase de processamento dos sinais.

O último dos softwares citados anteriormente, merece uma análise a parte devido a uma característica peculiar. Produzido por [Irimia et al. 2017], o *RecoveriX* também é composto por hardware e isso o permite viabilizar tanto a execução de etapas do BCI, quanto a produção de *feedback* visual para o usuário ou paciente.

4.4.4. Métricas de avaliação computacionais

Os estudos identificados empregaram o uso métricas de avaliação a fim de mensurar o desempenho dos BCIs construídos, conforme exposto na Tabela 8 com seus respectivos valores. Entre essas métricas de avaliação computacionais, a acurácia apareceu em todos os estudos com exceção apenas de [Cincotti et al. 2012], que evidenciou apenas as métricas de avaliação clínica. Apesar da frequente aparição dessa métrica, foram encontradas distinções em relação ao seu cálculo. Por exemplo, em [Arvaneh et al. 2014], [Ang and Guan 2015] e [Irimia et al. 2017] ela foi aplicada baseada no método de *cross-validation* (*5-fold* e *10-fold*), que realiza o cálculo do valor por um número determinado de vezes, permitindo o acompanhamento de desempenho do sistema. Por outro lado, em [Naros and Gharabaghi 2017], o valor da acurácia foi medido de acordo com a taxa de verdadeiros-positivos e verdadeiros-negativos. Além dos métodos de cálculo, as acurácias possuem outra divergência pois alguns autores relataram o resultado dessa medida como um valor único e outros como um valor médio.

Além da acurácia, outras métricas computacionais foram calculadas por [Chowdhury et al. 2018], sendo elas: o Índice Kappa Médio, caracterizado por destacar a eficiência do classificador e Taxa de Transferência de Informação Média, responsável por medir o desempenho online do sistema implementado.

5. Discussões

A busca por métodos de reabilitação motora pós-AVC mais eficientes e menos custosos propiciou a produção de vários BCIs de construções, algoritmos e técnicas diferentes. Dentro do campo de pesquisa aqui abordado, foram identificados 11 artigos descrevendo

Tabela 8. Métricas de avaliação utilizados e seus respectivos valores

Estudo	Métricas de Avaliação
[Prasad et al. 2010]	Acurácia: 60 a 75%
[Shindo et al. 2011]	Acurácia: 68 a 85%
[Cincotti et al. 2012]	-
[Frisoli et al. 2012]	Acurácia: $88.2 \pm 10.4\%$ e $89.4 \pm 5.0\%$
[Liang et al. 2013]	Acurácia: 48 a 79%
[Arvaneh et al. 2014]	Acurácia média (5-fold e 10-fold cross-validation): $\sim 83\%$ e 78.58%
[Cisotto et al. 2014]	Acurácia: $28 \pm 5\%$ a $50 \pm 8\%$
[Ang and Guan 2015]	Acurácia média (10-fold cross-validation): $\sim 70\%$ Acurácia média(10-fold cross-validation): $\sim 70\%$ Acurácia média(10-fold cross-validation): $\sim 70\%$
[Irimia et al. 2017]	Acurácia média (10-fold cross-validation): $\sim 70\%$
[Naros and Gharabaghi 2017]	Acurácia(Taxa de Verdadeiros-Positivos e Verdadeiros-Negativos): 60,12% Acurácia(Taxa de Verdadeiros-Positivos e Verdadeiros-Negativos): 80,08%
[Chowdhury et al. 2018]	Acurácia média: 75.75%, Índice Kappa médio: 0.63, Taxa de transferência de informação média: 0.2629

a produção de BCIs que abrangem as técnicas e métodos supracitados para recuperação motora de sequelas pós-AVC. Desses 11 artigos, 3 trouxeram mais de uma abordagem, contabilizado assim um total de 15 BCIs (QP1).

Esses trabalhos selecionados tiveram seus dados relacionados à parte clínica dispostos na Tabelas 4. Essas informações ilustram que os pesquisadores da área possuem como foco a reabilitação motora de membros superiores e utilizam aplicações em tempo real. Além disso, o feedback do tipo robótico foi o mais requisitado pelos autores. Entretanto, a natureza complexa e detalhada dos sinais EEG faz com que qualquer mudança de metodologia ao longo do tratamento de reabilitação, principalmente as técnicas combinadas, pode acarretar em resultados bastante distintos, o que dificulta a comparação direta entre o desempenho clínicos dos participantes de um trabalho diferentes, como já observado por [Nicolas-Alonso and Gomez-Gil 2012] em sua revisão.

Analisando a QP2, que trata dos algoritmos utilizados pelos BCIs, foi realizada uma subdivisão em aquisição de sinal, pré-processamento, processamento e reconhecimento de sinais, bem como exposto nas tabelas 6 e 7. Com essas informações coletadas, observou-se uma relativa congruência entre os sistemas até a etapa de processamento, apesar de contextos de aplicação bastante distintos. Essa congruência se deu pela recorrência dos filtros notch e passa-faixa, no pré-processamento, que são esperados devido à natureza dos sinais cerebrais captados durante a aquisição dos sinais EEG. Essa congruência, também é notada pela aplicação do algoritmo CSP em 6 dos 11 trabalhos, variando nas formas de implementação na busca por otimização de desempenho.

Na etapa seguinte às duas mencionadas, foram empregados 8 algoritmos distintos dentre os 11 trabalhos selecionados, o que mostra a clara dificuldade em aumentar a eficiência dos sistemas após o processamento do sinal. Apesar de algoritmos de inteligência artificial serem bastante empregados nessa área, 6 dos 11 autores recorreram

a abordagens que não envolveram algoritmos de *Machine Learning* em preferência a métodos como: Combinação linear de características, LDA, Classificadores lineares e até mesmo uma das variações do CSP que geralmente se encarrega da etapa anterior.

O desempenho dos sistemas BCI propostos e a evolução clínica dos pacientes foram avaliados utilizando as métricas presentes na tabela 4 e 8, respectivamente (QP3). A partir desses resultados, notou-se que a acurácia mede satisfatoriamente o desempenho computacional dos sistemas na maioria dos contextos empregados, apesar de algumas diferenças entre os seus métodos de cálculo de um trabalho para o outro. Os autores dos trabalhos que utilizaram essa métrica também relataram o aumento de precisão dos BCIs em relação a comparação feita com outros modelos, isso confirma-se pelos valores relativamente altos das acurácias calculadas. Para a análise de desempenho clínico dos participantes recrutados, o valor de ERD foi usado de forma recorrente nos trabalhos devido a sua eficiência em medir se a imaginação motora pacientes está sendo produzida de maneira correta pelos pacientes, conseqüentemente ajudando-os a avançar no tratamento.

Em relação ao ano de publicação dos artigos, percebe-se que há uma constância no número de publicações ao longo dos anos. Esse número varia entre 1 e 2 publicações, sendo o ano de 2016 o único que não teve nenhum artigo. Esses dados reforçam os principais entraves encontrados na produção científica dentro dessa área que são o tempo de implementação dos sistemas e o tempo de acompanhamento da evolução dos pacientes no decorrer dos tratamentos de reabilitação. Isso reforça a grande utilização de softwares para acelerar o processo de desenvolvimento e aplicação dos BCIs, tanto para a execução das etapas principais (pré-processamento, processamento e reconhecimento de sinais), quanto para o retorno de feedback ao usuário ou análise dos dados ao projetista, conforme ilustrado na tabela 7 (QP4).

Os artigos selecionados tiveram pontuação de qualidade de 6 a 11 pontos. Aqueles que obtiveram a menor pontuação e conseqüentemente não foram incluídos nas etapas posteriores da revisão, apresentaram como principal limitação a não aparição de resultados e discussões, tendo como principal justificativa a apresentação dessas informações em trabalhos futuros e a necessidade de um período de tempo considerável para a realização do acompanhamento dos participantes. Em relação aos demais, os que não foram classificados com a maior pontuação tiveram em comum o fato de não terem seus métodos comparados à outros. As pontuações de qualidade também mostraram que nenhum dos artigos teve um índice de qualidade abaixo de 50%, revelando que a maioria foi capaz de atender à grande parte dos critérios de qualidade.

6. Considerações Finais

Em suma, esta revisão sistemática teve como objetivo a identificação dos algoritmos e técnicas computacionais presentes em BCIs que utilizam EEG, Imagética Motora e *Neurofeedback* bem como as métricas de avaliação empregadas em cada um desses. Adicionalmente, o trabalho fornece um enfoque mais aprofundado na questão computacional presentes nesses BCIs, sem abster-se de explicitar informações clínicas relevantes.

Ademais, esta pesquisa provê informações valiosas a respeito de quais métodos estão sendo empregados na implementação e aplicação de vários sistemas BCI pelos pesquisadores deste campo nos últimos anos. Esta revisão também apresenta informações médicas relevantes que auxiliam na discussão de várias questões importantes relaciona-

das à pesquisa em reabilitação motora pós-AVC.

Para tal, a revisão foi conduzida de acordo com a metodologia descrita em [Kitchenham and Charters 2007], juntamente com o auxílio de ferramentas e sites como Parsifal e DECS. Isto permitiu a obtenção satisfatória de artigos que obtiveram boas pontuações de qualidade. Por meio dos artigos selecionados nessa revisão, foi possível também coletar todas as informações definidas no planejamento da etapa de extração dos dados.

Como trabalhos futuros, sugere-se a análise mais aprofundada de outros aspectos dos trabalhos como: condição clínica pós-AVC dos participantes, evolução clínica dos participantes após o tratamento, equipamentos de hardware empregados na captação dos sinais EEG, e principalmente, os modelos de calibração dos sistemas BCI.

Referências

- Amin, H. U., Mumtaz, W., Subhani, A. R., Saad, M. N. M., and Malik, A. S. (2017). Classification of EEG Signals Based on Pattern Recognition Approach. *Frontiers in Computational Neuroscience*, 11:103.
- Ang, K. K. and Guan, C. (2015). Brain-Computer Interface for Neurorehabilitation of Upper Limb After Stroke. *Proceedings of the IEEE*, 103(6):944–953.
- Arvaneh, M., Guan, C., Ang, K. K., and Quek, C. (2014). Mutual information-based optimization of sparse spatio-spectral filters in brain-computer interface. *Neural Computing and Applications*, 25(3-4):625–634.
- Asadi, H., Dowling, R., Yan, B., and Mitchell, P. (2014). Machine Learning for Outcome Prediction of Acute Ischemic Stroke Post Intra-Arterial Therapy. *PLoS ONE*, 9(2):e88225.
- Bajaj, S., Butler, A. J., Drake, D., and Dhamala, M. (2015). Brain effective connectivity during motor-imagery and execution following stroke and rehabilitation. *NeuroImage: Clinical*, 8:572–582.
- Boehme, A. K., Esenwa, C., and Elkind, M. S. (2017). Stroke Risk Factors, Genetics, and Prevention. *Circulation Research*, 120(3):472–495.
- Borghese, N. A., Pirovano, M., Lanzi, P. L., Wüest, S., and de Bruin, E. D. (2013). Computational Intelligence and Game Design for Effective At-Home Stroke Rehabilitation. *Games for Health Journal*, 2(2):81–88.
- Carvalho, R., Dias, N., and Cerqueira, J. J. (2019). Brain-machine interface of upper limb recovery in stroke patients rehabilitation: A systematic review. *Physiotherapy Research International: The Journal for Researchers and Clinicians in Physical Therapy*, 24(2):e1764.
- Chowdhury, A., Raza, H., Meena, Y. K., Dutta, A., and Prasad, G. (2018). Online Covariate Shift Detection-Based Adaptive Brain-Computer Interface to Trigger Hand Exoskeleton Feedback for Neuro-Rehabilitation. *IEEE Transactions on Cognitive and Developmental Systems*, 10(4):1070–1080.
- Cincotti, F., Pichiorri, F., Arico, P., Aloise, F., Leotta, F., de Vico Fallani, F., del R Milani, J., Molinari, M., and Mattia, D. (2012). EEG-based Brain-Computer Interface to

- support post-stroke motor rehabilitation of the upper limb. In *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 4112–4115, San Diego, CA. IEEE.
- Cisotto, G., Pupolin, S., Cavinato, M., and Piccione, F. (2014). An EEG-Based BCI Platform to Improve Arm Reaching Ability of Chronic Stroke Patients by Means of an Operant Learning Training with a Contingent Force Feedback. *International Journal of E-Health and Medical Communications*, 5(1):114–134.
- Cohen, J. (1968). Nominal scale agreement with provision for scaled disagreement or partial credit. page 8.
- Cramer, S. C., Sur, M., Dobkin, B. H., O'Brien, C., Sanger, T. D., Trojanowski, J. Q., Rumsey, J. M., Hicks, R., Cameron, J., Chen, D., Chen, W. G., Cohen, L. G., deCharms, C., Duffy, C. J., Eden, G. F., Fetz, E. E., Filart, R., Freund, M., Grant, S. J., Haber, S., Kalivas, P. W., Kolb, B., Kramer, A. F., Lynch, M., Mayberg, H. S., McQuillen, P. S., Nitkin, R., Pascual-Leone, A., Reuter-Lorenz, P., Schiff, N., Sharma, A., Shekim, L., Stryker, M., Sullivan, E. V., and Vinogradov, S. (2011). Harnessing neuroplasticity for clinical applications. *Brain*, 134(6):1591–1609.
- Crinion, J. T. and Leff, A. P. (2007). Recovery and treatment of aphasia after stroke: functional imaging studies. *Current Opinion in Neurology*, 20(6):667–673.
- DeFelipe, J. (2006). Brain plasticity and mental processes: Cajal again. *Nature Reviews Neuroscience*, 7(10):811–817.
- Doborjeh, G. Z., Doborjeh, M. G., and Kasabov, N. (2018). Attentional Bias Pattern Recognition in Spiking Neural Networks from Spatio-Temporal EEG Data. *Cognitive Computation*, 10(1):35–48.
- Doppelmayr, M., Nosko, H., Pecherstorfer, T., and Fink, A. (2007). An Attempt to Increase Cognitive Performance After Stroke With Neurofeedback. page 5.
- Fisher, M., Iadecola, C., and Sacco, R. (2017). Introduction to the Stroke Compendium. *Circulation Research*, 120(3):437–438.
- Frisoli, A., Loconsole, C., Leonardi, D., Banno, F., Barsotti, M., Chisari, C., and Bergamasco, M. (2012). A New Gaze-BCI-Driven Control of an Upper Limb Exoskeleton for Rehabilitation in Real-World Tasks. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 42(6):1169–1179.
- Hammond, D. C. (2007). What Is Neurofeedback? *Journal of Neurotherapy*, 10(4):25–36.
- Heinrich, H., Gevensleben, H., and Strehl, U. (2007). Annotation: Neurofeedback ? train your brain to train behaviour. *Journal of Child Psychology and Psychiatry*, 48(1):3–16.
- Irimia, D. C., Cho, W., Ortner, R., Allison, B. Z., Ignat, B. E., Edlinger, G., and Guger, C. (2017). Brain-Computer Interfaces With Multi-Sensory Feedback for Stroke Rehabilitation: A Case Study: BCI for Stroke Rehabilitation. *Artificial Organs*, 41(11):E178–E184.
- Khandoker, A., Palaniswami, M., and Karmakar, C. (2009). Support Vector Machines for Automated Recognition of Obstructive Sleep Apnea Syndrome From ECG Recordings. *IEEE Transactions on Information Technology in Biomedicine*, 13(1):37–48.

- Kinney-Lang, E., Auyeung, B., and Escudero, J. (2016). Expanding the (kaleido)scope: exploring current literature trends for translating electroencephalography (EEG) based brain–computer interfaces for motor rehabilitation in children. *Journal of Neural Engineering*, 13(6):061002.
- Kitchenham, B. and Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering. 2.
- Klock, A. C. T. (2018). Mapeamentos e Revisões Sistemáticas da Literatura: um Guia Teórico e Prático. page 9.
- Langhorne, P., Bernhardt, J., and Kwakkel, G. (2011). Stroke rehabilitation. *The Lancet*, 377(9778):1693–1702.
- Li, M., Xu, G., Xie, J., and Chen, C. (2018). A review: Motor rehabilitation after stroke with control based on human intent. *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, 232(4):344–360.
- Liang, J., Zhang, H., Liu, Y., Wang, H., Li, J., and Zhang, L. (2013). A Frequency Boosting Method for Motor Imagery EEG Classification in BCI-FES Rehabilitation Training System. In Hutchison, D., Kanade, T., Kittler, J., Kleinberg, J. M., Mattern, F., Mitchell, J. C., Naor, M., Nierstrasz, O., Pandu Rangan, C., Steffen, B., Sudan, M., Terzopoulos, D., Tygar, D., Vardi, M. Y., Weikum, G., Guo, C., Hou, Z.-G., and Zeng, Z., editors, *Advances in Neural Networks – ISNN 2013*, volume 7952, pages 284–291. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Liu, R. H. (2004). Potential Synergy of Phytochemicals in Cancer Prevention: Mechanism of Action. *The Journal of Nutrition*, 134(12):3479S–3485S.
- Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F., and Arnaldi, B. (2007). A review of classification algorithms for EEG-based brain–computer interfaces. *Journal of Neural Engineering*, 4(2):R1–R13.
- Mani, S. and Dasgupta, U. (2010). Explaining Randomized Evaluation Techniques Using Classroom Games. *SSRN Electronic Journal*.
- Markus, H. (2008). Stroke: causes and clinical features. page 6.
- McFarland, D. J. and Wolpaw, J. R. (2011). Brain-computer interfaces for communication and control. *Communications of the ACM*, 54(5):60.
- McMahon, M. and Schukat, M. (2018). A low-cost, open-source, BCI-VR prototype for real-time signal processing of EEG to manipulate 3d VR objects as a form of neurofeedback. In *2018 29th Irish Signals and Systems Conference (ISSC)*, pages 1–6, Belfast. IEEE.
- Mizuno, K., Abe, T., Ushiba, J., Kawakami, M., Ohwa, T., Hagimura, K., Ogura, M., Okuyama, K., Fujiwara, T., and Liu, M. (2018). Evaluating the Effectiveness and Safety of the Electroencephalogram-Based Brain-Machine Interface Rehabilitation System for Patients With Severe Hemiparetic Stroke: Protocol for a Randomized Controlled Trial (BEST-BRAIN Trial). *JMIR research protocols*, 7(12):e12339.
- Naros, G. and Gharabaghi, A. (2017). Physiological and behavioral effects of -tACS on brain self-regulation in chronic stroke. *Brain Stimulation*, 10(2):251–259.

- Nicolas-Alonso, L. F. and Gomez-Gil, J. (2012). Brain Computer Interfaces, a Review. *Sensors*, 12(2):1211–1279.
- Niedermeyer, E. and da Silva, F. (2005). *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. LWW Doody's all reviewed collection. Lippincott Williams & Wilkins.
- Nunes, B. K., Lacerda, R. A., and Jardim, J. M. (2011). Revisión sistemática y meta-análisis sobre el valor predictivo de la proteína C-reactiva en infección postoperatorias. page 6.
- Pfurtscheller, G. and Neuper, C. (2001). Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, 89(7):1123–1134.
- Pichiorri, F., Morone, G., Petti, M., Toppi, J., Pisotta, I., Molinari, M., Paolucci, S., Inghilleri, M., Astolfi, L., Cincotti, F., and Mattia, D. (2015). Brain-computer interface boosts motor imagery practice during stroke recovery: BCI and Motor Imagery. *Annals of Neurology*, 77(5):851–865.
- Prasad, G., Herman, P., Coyle, D., McDonough, S., and Crosbie, J. (2010). Applying a brain-computer interface to support motor imagery practice in people with stroke for upper limb recovery: a feasibility study. *Journal of NeuroEngineering and Rehabilitation*, 7(1):60.
- Shindo, K., Kawashima, K., Ushiba, J., Ota, N., Ito, M., Ota, T., Kimura, A., and Liu, M. (2011). Effects of neurofeedback training with an electroencephalogram-based Brain-Computer Interface for hand paralysis in patients with chronic stroke: A preliminary case series study. *Journal of Rehabilitation Medicine*, 43(10):951–957.
- Uman, L. S. (2011). Systematic Reviews and Meta-Analyses. page 3.
- Varghese, J. P. (2009). Analysis of EEG Signals For EEG-based Brain-Computer Interface. *School of Innovation, Design and Technology Mälardalen University Vasteras, Sweden*, page 54.
- Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., and Vaughan, T. M. (2002). Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, page 25.
- Zimmermann-Schlatter, A., Schuster, C., Puhan, M. A., Siekierka, E., and Steurer, J. (2008). Efficacy of motor imagery in post-stroke rehabilitation: a systematic review. *Journal of NeuroEngineering and Rehabilitation*, 5(1):8.