Capítulo

5

Interfaces Cérebro-Computador

João Luís Garcia Rosa

Laboratório de Computação Bio-inspirada (BioCom)

Departamento de Ciências da Computação

Instituto de Ciências Matemáticas e de Computação - Universidade de São Paulo

Av. Trabalhador São-carlense, 400 - Centro, São Carlos, SP, CEP: 13566-590 - Tel. 16-3373-6640

joaoluis@icmc.usp.br

Abstract

Brain-Computer Interface (BCI) is a form of communication that enables individuals unable to perform movements to connect to external assistive devices using brain signals. Noninvasive BCIs capture changes in blood flow or fluctuations in electric and magnetic fields caused by the activity of large populations of neurons. The electroencephalography (EEG), a non-invasive technique, measures the electrical activity of the brain in different locations of the head, typically using electrodes placed on the scalp. With the proper removal of artifacts, signal processing and machine learning, human EEG carries enough information about the intention of planning and execution. The objective of this mini-course is to show how the understanding of the activity of the brain can provide a way to allow communication without muscle movements.

Resumo

Interface cérebro-computador (BCI) é uma forma de comunicação que permite que indivíduos incapazes de realizar movimentos se conectem a dispositivos externos usando sinais cerebrais. BCIs não-invasivas capturam mudanças no fluxo sanguíneo ou flutuações de campos elétricos e magnéticos causados pela atividade de grandes populações de neurônios. A eletroencefalografia (EEG) mede a atividade elétrica do cérebro em diferentes locais da cabeça, geralmente usando eletrodos colocados no couro cabeludo. Com a remoção adequada de artefatos, processamento de sinal e aprendizagem de máquina, a EEG humana carrega informações suficientes sobre a intenção de planejamento e execução. O objetivo do minicurso é mostrar como o entendimento da atividade do cérebro pode fornecer uma maneira para permitir a comunicação sem movimentos musculares.

5.1. Introdução

5.1.1. Por que Interface Cérebro-Computador?

Interfaces Cérebro-Computador (Brain-Computer Interfaces) (BCI) são uma forma de comunicação que *habilita* indivíduos *incapazes* de realizar movimentos a se conectarem com dispositivos externos de assistência usando sinais cerebrais. Uma BCI é um mecanismo que permite a um usuário *interagir com o mundo exterior* por meio de medidas de atividade neural associadas com processos mentais [46].

A expressão *interface cérebro-computador* apareceu pela primeira vez na década de 1970 [66, 67]. Vidal usou a expressão para representar o conceito de colocar os *sinais elétricos observáveis do cérebro* para trabalhar como carregadores de informação em comunicações homem-computador ou para o propósito de controlar aparato externo [26]. Veja os componentes de um sistema BCI na Figura 5.1.

Figura 5.1. Esquema de uma BCI. Adaptado de [54].

Em geral, o registro da atividade neural é realizado por técnicas não invasivas. BCIs não-invasivas capturam mudanças no fluxo sanguíneo ou flutuações em campos elétricos ou magnéticos causados pela atividade de grandes *populações de neurônios* [57]. A *eletroencefalografia (EEG)*¹, uma técnica *não-invasiva*, mede a atividade elétrica do cérebro em diferentes posições da cabeça, tipicamente usando eletrodos no couro cabeludo [44, 22].

Com a remoção adequada de artefatos², processamento de sinal e aprendizado de máquina, o registro da EEG do ser humano apresenta informações suficientes sobre a *intenção* de planejamento e execução. Veja um sinal registrado pela EEG na Figura 5.2.

Modelos cerebrais com base em *neurodinâmica* procuram entender e representar as razões pelas quais os neurônios são células excitáveis. A corrente elétrica microscópica de cada neurônio soma-se com as correntes de outros neurônios, o que provoca uma

¹ *Eletroencefalografia (EEG)* é o método ou técnica de gravação dos potenciais elétricos que são gerados espontaneamente durante a atividade fisiológica de células no córtex cerebral. *Eletroencefalograma (EEG)* refere-se ao registro ou traços obtidos pela eletroencefalografia. Observe que a mesma sigla EEG é empregada nos dois casos, restando ao contexto sua distinção. Máquinas de EEG são projetadas para adquirir, processar, e exibir os sinais de EEG como formas de onda ou outras formas de dados sobre uma tela ou no papel.

² *Artefatos* são potenciais elétricos indesejados obtidos na EEG, normalmente de origem fisiológica (coração, músculos, olhos) ou externa [14].

Figura 5.2. Um segundo de sinal registrado pela EEG [25].

diferença de potencial elétrico macroscópica, medida pela EEG, que registra a atividade dos padrões de *populações de neurônios*. Isto é, um bom modelo neural deve reproduzir a dinâmica de neurônios, tendo em conta as *propriedades dinâmicas de populações de neurônios*, além das propriedades eletrofisiológicas de neurônios individuais.

O objetivo é mostrar como o entendimento da *atividade elétrica do cérebro* pode fornecer uma maneira para permitir a comunicação *sem* movimentos musculares. A intenção é, a partir do estudo do *comportamento neurodinâmico do cérebro*, investigar formas e propor modelos que permitam criar interfaces cérebro-computador, preferencialmente não-invasivas.

Nas últimas décadas, as BCIs baseadas em EEG têm atraído a atenção de pesquisadores no campo da neurociência, engenharia neural e reabilitação clínica. O plano é usar os dados obtidos por meio da BCI para analisar os *movimentos pré-motores*, mudanças no cérebro que ocorrem *antes* que haja realmente um movimento, e aplicá-los a um tratamento adequado de dispositivos protéticos.

5.1.2. Conhecendo o cérebro

Dois conceitos muito diferentes em relação à forma como o cérebro funciona como um todo coexistem em neurociência: o *modelo clássico*, no qual o cérebro é descrito como sendo composto de uma série de cadeias causais formadas por redes nervosas que funcionam em paralelo (as redes neurais artificiais convencionais [30]); e o *modelo neurodinâmico*, no qual o cérebro é operado por um caos dinâmico não-linear, que se parece com ruído, mas que apresenta uma espécie de ordem oculta [18].

Walter Freeman argumenta que existem duas unidades básicas de organização do cérebro: o *neurônio* e a *população de neurônios* [18]. Embora o neurônio tenha sido a base para a neurobiologia, massas de neurônios que interagem formando *populações de neurônios* são consideradas para uma *visão macroscópica do cérebro*. Como os neurônios, as populações de neurônios também têm estados e padrões de atividade, mas elas realizam diferentes “tarefas” macroscópicas. Entre o neurônio microscópico e essas “tarefas” macroscópicas, há populações *mesoscópicas* [18].

5.1.3. Registro

A eletroencefalografia (EEG) registra a atividade elétrica de populações mesoscópicas de neurônios. Uma BCI não-invasiva compreende a captação e análise de tal atividade, com o objetivo de oferecer uma saída alternativa às saídas normais musculares. Modelos de cérebro baseados em populações de neurônios com comportamento neurodinâmico e caótico, como os conjuntos-K [16], podem ser empregados para construir tal BCI.

As interfaces cérebro-computador (BCI) compreendem o uso da análise *on-line* de ondas cerebrais para obter informação sobre o *estado mental* de um sujeito como base para realizar alguma ação externa, como selecionar uma letra de um teclado virtual ou mover um dispositivo robótico, fornecendo um *canal de comunicação alternativa e controle* que não depende do caminho de saída normal do cérebro para nervos e músculos periféricos, que podem estar paralisados em alguns pacientes [49].

5.1.4. Tipos de BCI

Uma BCI pode ser classificada como [57]: (1) *invasiva*, baseada em eletrodos implantados, permite registrar atividade elétrica de neurônios individuais. Necessita de cirurgia; (2) *não-invasiva*, baseada em medições de atividade elétrica de populações de neurônios, por intermédio, por exemplo, da EEG. Não há necessidade de cirurgia, apenas o uso de uma “touca” de eletrodos na cabeça (Figura 5.3); e *semi-invasiva*, técnica intermediária, em que há uma certa “invasão”. Eletrodos são colocados na superfície do cérebro. Há necessidade de incisão cirúrgica.

Figura 5.3. As ondas cerebrais são registradas pela “touca” de eletrodos e analisadas por um computador [15].

A detecção e interpretação automáticas de atividades do cérebro relacionadas à atenção ou à *intenção* apresentam interesse significativo para muitas aplicações militares e civis. Essa interpretação da atividade cerebral pode prover informação sobre os movimentos intencionados de uma pessoa, movimentos imaginados ou foco de atenção e, portanto, pode ser informação valiosa para otimizar ou substituir a comunicação tradicional baseada em motor, ou seja, comunicação baseada em movimento muscular, movimentos de mãos, braços, olhos, língua, etc., entre uma pessoa e um computador ou outro dispositivo de saída [8].

5.2. Neurociência Básica

5.2.1. Neurônios

O neurônio típico tem muitos dendritos (entradas) e um axônio (saída). O axônio transmite informação por meio de trens de pulso *microscópicos* (*spikes*). Os dendritos integram

informação por meio de ondas contínuas de corrente iônica. Os neurônios estão ligados por sinapses. Cada sinapse conduz corrente elétrica. A corrente microscópica de cada neurônio é somada com as correntes de outros neurônios, o que provoca uma diferença de potencial *macroscópica*, medida com um par de eletrodos extracelulares (E) como a EEG [18, 21]. A EEG registra os padrões de atividade de *populações de neurônios mesoscópicos*. A soma das correntes que um neurônio gera em resposta a estímulos elétricos produz o potencial pós-sináptico. Veja a Figura 5.4.

Figura 5.4. Neurônio típico mostrando os dendritos (entradas), onde geralmente ocorrem as sinapses (Sy), o corpo celular, o axônio (saída), a zona de gatilho (ZG) e a direção do potencial de ação (*spike* elétrico). Note que as letras 'E' representam o par de eletrodos extracelulares. Adaptado de [58] e [18].

O tipo predominante de sinapse no cérebro do mamífero é a *sinapse química*, que opera por meio de liberação de uma substância química, o *neurotransmissor*, do terminal pré-sináptico para o terminal pós-sináptico, em resposta a uma despolarização (Figura 5.5). *Despolarização* é uma redução do potencial da membrana celular para zero mV, sendo que o interior do neurônio torna-se mais positivo. A despolarização para um nível de potencial crítico, o *limiar*, causa o início de um impulso. No seu pico, o interior da célula torna-se positivo em relação ao seu exterior.

Figura 5.5. Nas sinapses químicas, o terminal pré-sináptico libera uma substância química, o neurotransmissor, em resposta a uma despolarização [43, 58].

Nas sinapses químicas, há a *fenda sináptica*, que é uma pequena separação celular entre as células. Estão presentes vesículas contendo moléculas de neurotransmissores no terminal pré-sináptico, e quando o potencial de ação alcança estas vesículas, os neurotransmissores são liberados para a fenda sináptica.

As células nervosas influenciam outras por: (1) *excitação*, ou seja, elas *produzem* impulsos em outras células e (2) *inibição*, ou seja, elas *previnem* a liberação de impulsos em outras células.

Em uma sinapse excitatória, o transmissor liberado pelo terminal pré-sináptico despolariza a célula pós-sináptica, fazendo com que o potencial de sua membrana atinja o limiar. Em uma sinapse inibitória, o transmissor tende a manter o potencial da membrana da célula pós-sináptica abaixo do limiar.

Os neurônios corticais, por causa de suas interações sinápticas, formam *populações de neurônios*. Variáveis de estado de pulso e onda microscópicas são utilizadas para descrever a atividade dos neurônios individuais que contribuem para a população, e as variáveis de estado mesoscópicas (também de pulso e de onda) são utilizadas para descrever as atividades coletivas que os neurônios originam. Atividade de massa no cérebro é descrita por uma densidade de pulsos, em vez da frequência do pulso. Isto é feito por meio da gravação a partir do exterior da célula do disparo de pulsos de muitos neurônios simultaneamente. A mesma corrente que controla os disparos de neurônios é medida pela EEG, que não permite distinguir contribuições individuais. Felizmente, isso não é necessário [18].

A ação coletiva dos neurônios forma padrões de atividade que vão além do nível celular e se aproximam do nível do organismo. A formação de estados mesoscópicos é o primeiro passo para isso. Desta forma, o nível de atividade é decidido pela população, não por indivíduos [18].

5.2.2. Hodgkin-Huxley

A teoria de Hodgkin-Huxley (H-H) do potencial de ação, formulada há mais de 60 anos, permanece uma das grandes histórias de sucesso da biologia [29]. Juntamente com a rede neural artificial de McCulloch e Pitts [48], a teoria H-H provê a fundação para a neurociência computacional moderna. A teoria foi resultado de intensa colaboração experimental e teórica entre Alan Lloyd Hodgkin e Andrew Fielding Huxley, de 1938 até a publicação em 1952 de cinco artigos no *Journal of Physiology*. Os mecanismos iônicos responsáveis pela geração de um potencial de ação foram elucidados pelos trabalhos de Hodgkin e Huxley com o axônio gigante da lula.

Foram quatro os experimentos principais:

1. Cole e Curtis demonstraram que o potencial de ação é associado a um grande aumento na condutância da membrana [11];
2. Hodgkin e Huxley fizeram a primeira gravação intracelular de um potencial de ação [31] (Figura 5.6); Isto demonstrou que o potencial de ação excedia zero mV, contradizendo a hipótese de Bernstein [4] de que o aumento fundamental na permeabilidade da membrana é não-seletivo;

3. Hodgkin e Katz explicaram o pico do potencial de ação mostrando que era resultado de um aumento na permeabilidade do sódio [33];
4. Hodgkin, Huxley e Katz desenvolveram um circuito grampo de voltagem para habilitar medição quantitativa de correntes iônicas do axônio gigante da lula.

Figura 5.6. A primeira gravação intracelular de um potencial de ação do axônio da lula mostrou uma forma como esta. Adaptado de [68].

A lula é um invertebrado marinho que usa propulsão a jato para o movimento [61]. Seu axônio mais comprido também é o mais grosso (axônio gigante). Trata-se de uma fibra não-mielinizada com um diâmetro de aproximadamente 0.5 mm e vários centímetros de comprimento³. É uma das maiores células conhecidas. Portanto, constitui um sistema ideal para a realização de experimentos.

Hodgkin e Huxley mostraram que as despolarizações do axônio da lula engatilham uma corrente de entrada seguida de uma corrente de saída. Usando substituição iônica, eles demonstraram que esta corrente de rede poderia ser separada em dois componentes distintos: uma corrente de entrada rápida conduzida por íons Na^+ e uma corrente de saída de ativação mais lenta conduzida por íons K^+ . A partir de experimentos, eles concluíram que essas duas correntes resultam de mecanismos de permeabilidade independentes para Na^+ e K^+ com condutâncias que mudam como uma função do tempo e do potencial da membrana.

No entanto, sua contribuição mais memorável foi a representação empírica de dados experimentais em um modelo quantitativo [32], a primeira descrição completa da excitabilidade de uma única célula. Eles modelaram as mudanças suaves de corrente observadas em termos de poros ou canais que ou estavam abertos ou fechados, e usando previsões geradas por uma abordagem estatística para a probabilidade dos canais estarem abertos [29].

5.2.3. Plasticidade

Plasticidade corresponde à capacidade do cérebro em mudar a força da conexão das sinapses. As formas da plasticidade sináptica são potenciação de longo prazo (*long-term*

³As células dos vertebrados possuem diâmetros de poucos μm .

potentiation - LTP) e depressão de longo prazo (*long-term depression* - LTD). Ambas envolvem mudanças na sinapse que duram horas ou dias. Mais recentemente outros tipos de plasticidade foram propostos [57]: (1) plasticidade dependente do tempo do *spike* (*spike-timing dependent plasticity* - STDP), quando o tempo relativo dos *spikes* de entrada e saída determina a polaridade da mudança sináptica, (2) facilitação/depressão de curto prazo, quando a plasticidade é rápida mas não tem duração longa.

A LTP é uma das formas de plasticidade sináptica mais importante. Na sua forma mais simples, a LTP envolve um aumento na força da conexão sináptica entre dois neurônios causado por *disparos correlacionados* dos dois neurônios. A LTP é considerada a implementação biológica do famoso *postulado de Hebb* (também chamado de aprendizado hebbiano ou plasticidade hebbiana) [57]: “Se um neurônio A é consistentemente envolvido em causar o disparo de um outro neurônio B, então a força da conexão de A a B deve ser aumentada.” A LTP é encontrada em várias áreas do cérebro, incluindo o hipocampo e o neocortex [57].

A LTD envolve uma diminuição na força de uma conexão sináptica causada, por exemplo, por disparos *não correlacionados* entre os dois neurônios envolvidos. A LTD tem sido observada principalmente no cerebelo, ainda que coexista com a LTP no hipocampo, neocortex e outras áreas do cérebro [57].

Protocolos tradicionais que demonstram a LTP/LTD envolvem a estimulação de um neurônio pré-sináptico e um pós-sináptico simultaneamente. Esses protocolos manipulam a taxa de disparo dos neurônios pré e pós-sináptico mas não o tempo entre os *spikes* pré e pós-sinápticos. Estudos recentes revelaram que a *temporização precisa* dos *spikes* pré e pós-sinápticos pode determinar se a mudança na força sináptica é positiva ou negativa. Esta forma de plasticidade sináptica é conhecida como STDP [57].

Na STDP hebbiana, quando o *spike* pré-sináptico ocorre um pouco antes do *spike* pós-sináptico (1 a 40 ms) a sinapse é fortalecida. Quando ocorre um pouco depois (1 a 40 ms), a força sináptica é diminuída. A STDP hebbiana foi observada no cortex cerebral e no hipocampo do mamífero. O fenômeno oposto, a STDP anti-hebbiana, em que a sinapse é fortalecida quando o *spike* pré-sináptico ocorre depois do pós-sináptico e vice-versa, foi observada em algumas estruturas, como por exemplo, as sinapses inibitórias do cerebelo dos peixes elétricos [57].

LTP, LTD e STDP são plasticidades de longo prazo, pois as mudanças que elas causam podem durar horas e até dias. A plasticidade de curto prazo faz com que as sinapses correspondentes funcionem como filtros temporais nos padrões de *spikes* de entrada. Na depressão de curto prazo (*short-term depression* - STD) o efeito de cada *spike* sucessivo em um trem de *spikes* de entrada (sequência de *spikes*) é diminuído comparado com o *spike* precedente [57].

Portanto, se um neurônio recebe uma explosão de *spikes* como entrada, o primeiro *spike* tem o maior efeito, e cada *spike* sucessivo causa cada vez menos mudanças no potencial da membrana até que um ponto de equilíbrio seja alcançado e todos os *spikes* subsequentes tenham o mesmo efeito diminuído no neurônio pós-sináptico. A facilitação de curto prazo (*short-term facilitation* - STF) exhibe o efeito oposto, em que cada *spike* sucessivo tem um efeito maior que seu predecessor, até que um ponto de saturação seja

alcançado. Tanto STD quanto STF têm papéis importantes em regular a dinâmica de redes corticais [57].

5.3. Neurodinâmica

Um sistema dinâmico é um sistema cujo estado varia com o tempo. Para proceder com o estudo da neurodinâmica, é necessário um *modelo matemático espaço-estado*: conjunto de *variáveis de estado* cujos valores devem conter informação suficiente para prever a evolução futura do sistema.

5.3.1. Espaço de estados

A equação espaço-estado descreve o movimento de um ponto em um espaço de estados N -dimensional. O espaço de estados pode ser um espaço euclidiano ou um subconjunto deste. Pode ser também um espaço não-euclidiano como um círculo, uma esfera, uma tora ou algum outro elemento diferenciável. O interesse, porém, está confinado em um espaço euclidiano. O espaço de estados é importante porque provê uma ferramenta visual/conceitual para analisar a dinâmica de um sistema não-linear. Mudanças no estado do sistema com o tempo t são representadas como uma curva no espaço de estados, com cada ponto na curva carregando (explícita ou implicitamente) um rótulo que grava o tempo da observação. Esta curva é chamada de *trajetória* ou *órbita* do sistema.

5.3.2. Atratores

Sistemas dissipativos são geralmente caracterizados pela presença de conjuntos de atração ou coletores de dimensionalidade mais baixa que a do espaço de estados. Por coletor entende-se uma superfície k -dimensional embutida em um espaço de estados N -dimensional, definido por um conjunto de equações. Esses coletores são chamados de *atratores*, pois eles são subconjuntos limitados para os quais regiões de condições iniciais de volume do espaço de estados não-zero convergem quando o tempo t aumenta. O coletor pode consistir de um único ponto no espaço de estados, neste caso um atrator de ponto. Alternativamente, pode ser na forma de uma órbita periódica, nesse caso um ciclo limite estável, no sentido de que trajetórias próximas aproximam-se dele assintoticamente (Figura 5.7).

Figura 5.7. Um atrator ciclo limite [77].

5.3.3. Rede de Hopfield

A rede (ou modelo) de Hopfield consiste de um conjunto de neurônios e de um conjunto correspondente de unidades de atraso, formando um sistema de retro-alimentação (*feedback*) de *loops* múltiplos (Figura 5.8). O número de *loops* de *feedback* é igual ao número de neurônios. Basicamente, a saída de cada neurônio é retro-alimentada, via unidade de atraso, a cada um dos outros neurônios da rede. Ou seja, não há auto-retro-alimentação [30].

Figura 5.8. Uma rede de Hopfield [78].

A convergência é geralmente assegurada, uma vez que Hopfield mostrou que os atratores deste sistema dinâmico não-linear são estáveis, não periódicos ou caóticos como em alguns outros sistemas [34].

5.4. Conjuntos-K de Freeman

Nas décadas passadas, testemunhou-se avanços significativos nas técnicas de monitoramento do cérebro, em parte devido aos avanços dos métodos experimentais [64, 22]. Abordagens de modelamento foram desenvolvidas para dar suporte às descobertas empíricas. Os cérebros têm sido descritos como sistemas dinâmicos complexos com trajetórias que evoluem de um horizonte atrator com colinas e vales [16, 17].

De acordo com a abordagem de sistemas dinâmicos, a trajetória dinâmica do cérebro pode repousar intermitentemente, por uma fração de segundo, em um vale [18, 35, 56]. O vale corresponde a uma recuperação da memória pelo sujeito, que pode ser medida por meio de um padrão de atividade espacialmente distribuído. Este padrão tem significado para o sujeito baseado em suas experiências e intenções anteriores.

Em relação à neurociência no nível mesoscópico [18, 19], a conexão teórica entre a atividade dos neurônios no nível microscópico em pequenas redes neurais e a atividade de grupos de células na escala mesoscópica ainda não é bem entendida [20]. Katzir-Katchalsky sugere tratar os grupos de células usando termodinâmica formando uma hierarquia [36]: conjuntos-K de Freeman.

O modelo de rede neural K é baseado em estudos de décadas de Walter Freeman sobre a dinâmica do processamento perceptual no cérebro [16, 17, 18, 20]. Os conjuntos-K de Freeman descrevem a dinâmica espaço-temporal do cérebro usando uma abordagem

hierárquica. Incluem os conjuntos- K_0 , K_1 , K_2 , K_3 , K_4 , K_5 e K_6 , que descrevem a hierarquia de redes neurais no cérebro, com o aumento da complexidade de estrutura e função [20, 39] (Figura 5.9). Os conjuntos-K procuram representar os padrões espaciais de fase e amplitude das oscilações geradas pela população neural [40, 41] e usam um conjunto de equações diferenciais ordinárias (EDO) com parâmetros distribuídos para descrever a hierarquia de populações neurais começando das micro-colunas até os hemisférios [37]. São utilizados em diversas aplicações, sendo que uma aplicação recente do conjunto- K_3 envolve agrupamento de bases de dados sociais [42, 60].

Figura 5.9. A hierarquia dos conjuntos-K, mostrando a progressão dos conjuntos de populações neurais do K_0 ao K_4 . Adaptado de [38].

5.5. Gravação e Estimulação da Atividade do Cérebro

5.5.1. Gravação da atividade cerebral

Nosso conhecimento sobre o funcionamento do cérebro aumentou dramaticamente nas últimas décadas devido ao desenvolvimento e refinamento de várias técnicas de gravação da atividade cerebral [22]. Tais avanços vão desde o estudo da atividade sináptica no nível microscópico ao refinamento de técnicas de imagem cerebral em um nível macroscópico. Sistemas modernos de aquisição de dados e novos *designs* de eletrodos permitiram a gravação simultânea de dezenas de neurônios em uma escala maior, e os computadores poderosos permitiram simulações e análise de dados mais complexas, dando assim origem ao campo da *neurociência computacional* [57].

Como já foi dito, a comunicação entre neurônios no cérebro ocorre por meio de *spikes* ou potenciais de ação, que são pulsos elétricos tudo-ou-nada produzidos quando o neurônio recebe uma quantidade suficiente de corrente de entrada de outros neurônios via conexões sinápticas. Portanto, algumas das primeiras tecnologias para registrar a atividade do cérebro foram baseadas na detecção de mudanças nos potenciais elétricos em neurônios (técnicas invasivas baseadas em eletrodos) ou em grandes populações de neurônios (técnicas não invasivas, como a EEG). Técnicas mais recentes são baseadas na detecção da atividade neural indiretamente por meio da medida da mudança no fluxo sanguíneo que resulta da atividade neural aumentada em uma região (fMRI) ou medindo as mudanças no campo magnético em volta do crânio causadas pela atividade neural (MEG).

5.5.1.1. Técnicas invasivas

Técnicas que permitem registrar neurônios individuais no cérebro são tipicamente invasivas, ou seja, envolvem alguma forma de cirurgia, em que uma parte do crânio é removida, um eletrodo ou implante é colocado no cérebro e a parte removida do crânio é recolocada. Normalmente são gravações realizadas em animais, tais como macacos e ratos. A gravação não causa dor, pois o cérebro não tem receptores internos para dor, mas a cirurgia e o processo de recuperação podem causar dor e envolver riscos como infecções [57].

No caso de humanos, gravações invasivas são feitas apenas em instalações clínicas tais como durante cirurgia do cérebro ou quando pacientes estão sendo monitorados por causa de atividade anormal do cérebro (por exemplo, crises) antes da cirurgia. A maior vantagem das gravações invasivas é que elas permitem gravação de *spikes* (os sinais de saída dos neurônios) em uma escala de tempo de milisegundos. Isso contrasta com as técnicas não invasivas, que medem correlatos indiretos da atividade neural, tal como o fluxo do sangue, que ocorrem em uma escala de tempo maior (centenas de milisegundos). Técnicas invasivas são baseadas na tecnologia dos eletrodos.

Um *microeletrodo* é simplesmente um fio muito fino ou outro condutor elétrico usado para fazer contato com o tecido cerebral. Um eletrodo típico é feito de tungstênio ou de uma liga platina-irídio e é isolado exceto na ponta, que mede em torno de $1\ \mu\text{m}$ de diâmetro (o diâmetro do corpo celular de um neurônio está na faixa de dezenas de μm) [57].

Para registrar a atividade de um número grande de neurônios, os microeletrodos podem ser arranjados em uma estrutura de grade para formar uma *matriz multieletrodo* de $m \times n$ eletrodos, em que os valores de m e n normalmente estão entre 1 e 10 [57] (Figura 5.10). Estas matrizes foram desenvolvidas para gravações *in vitro* e *in vivo*. O foco aqui é para matrizes implantáveis para gravações *in vivo* porque elas são as mais relevantes para as BCIs. Os tipos mais comuns de matrizes implantáveis são matrizes de microfio, baseadas em silício, e de microeletrodos flexíveis.

Figura 5.10. Exemplo de uma matriz multieletrodo (matriz de Utah de 10×10 eletrodos) [69].

A maior vantagem das matrizes multieletrodos sobre os sistemas mais convencionais de único eletrodo, é a resolução espacial aumentada; a habilidade de gravação simultânea de vários neurônios abre a porta para a extração de tipos de informação complexa como sinais de posição ou velocidade que podem ser úteis para controlar dispositivos protéticos. Matrizes implantáveis também têm suas desvantagens, especialmente

se o dispositivo implantado permanece no tecido cerebral por um tempo longo (como requerido pelo controle de longo prazo das próteses) [57].

A *eletrocorticografia* (ECoG) é uma técnica para gravar sinais cerebrais colocando eletrodos na superfície do cérebro. Necessita de uma incisão cirúrgica no crânio para implantar esses eletrodos (Figura 5.11). Tipicamente, uma grade ou tira de $m \times n$ eletrodos é implantada, em que $1 \leq m, n \leq 8$. Eletrodos da ECoG podem ter ponta de carbono, platina ou liga de ouro e são tipicamente de 2-5 mm de diâmetro. O espaço entre os eletrodos na grade é usualmente de 10 mm a 1 cm. Os eletrodos são flexíveis o suficiente para acomodar movimentos normais do cérebro [57].

Figura 5.11. ECoG em humanos [7].

Ao contrário dos eletrodos de única célula e das matrizes de microeletrodos, os eletrodos de ECoG podem gravar flutuações elétricas causadas por atividade coerente de grandes populações de neurônios (várias dezenas de milhares). Enquanto os eletrodos de ECoG não medem diretamente *spikes*, o sinal gravado é diretamente relacionado às correntes de entrada recebidas pelos dendritos de neurônios corticais, particularmente nas camadas superiores do cortex cerebral.

A ECoG recentemente tem recebido atenção da comunidade de BCI como uma técnica parcialmente invasiva, entre matrizes multieletrodo invasivas e a EEG não invasiva. Ao contrário das matrizes multieletrodo, algumas formas de ECoG não penetram a barreira sangue-cérebro e são, portanto, mais seguras que matrizes implantadas dentro do cérebro [57].

Por causa de sua proximidade à atividade neural, a ECoG oferece [57]: (1) resolução espacial maior do que técnicas não invasivas como a EEG (dezenas de milímetros versus centímetros), (2) maior largura de banda espectral (0-200 Hz versus 0-40 Hz), (3) amplitude maior (50-100 μV versus dezenas de μV), e (4) consideravelmente menos vulnerabilidade a artefatos tais como atividade muscular e ruído ambiente.

As limitações da ECoG incluem [57]: (1) pode ser usada apenas em instalações cirúrgicas, (2) apenas porções cirurgicamente relevantes do cérebro podem ser gravadas,

e (3) pode haver interferência devido a drogas ou condições relacionadas ao paciente, tal como crises.

Uma desvantagem da ECoG é o tamanho relativamente grande de seus eletrodos (vários mm de diâmetro). Isso está sendo resolvido usando eletrodos microECoG, que são apenas uma fração de um milímetro de diâmetro e espaçados apenas de 2-3 mm em uma grade, permitindo a detecção da atividade neural em uma resolução muito melhor que a da ECoG tradicional. Isso abre a possibilidade de decodificar movimentos finos, como os movimentos de dedos individuais ou mesmo a fala, sem realmente penetrar o cérebro.

5.5.1.2. Técnicas não invasivas

Um pouco menos espetacular, mas também notável e de progresso constante, tem sido feito no nível mesoscópico intermediário [16, 18] na análise de EEG [22]. A EEG mede a atividade elétrica do cérebro em diferentes locais da cabeça, geralmente usando eletrodos colocados no couro cabeludo (veja Figura 5.3).

A EEG registra diferentes faixas de frequências [22, 57]:

- *ritmos α* (7,5-12,5 Hz): aparecem espontaneamente em adultos normais durante vigília, sob relaxamento e condições de inatividade mentais. São melhores vistos com os olhos fechados, mais pronunciados nos locais occipitais.
- *ritmos β* (12,5-30 Hz): são melhores definidos em locais centrais e frontais, com menor amplitude que ondas α . São reforçados em cálculos mentais, expectativa ou tensão ao longo de toda a superfície do couro cabeludo.
- *ritmos θ* (3,5-7,5 Hz): são típicos durante o sono profundo. Desempenham um papel importante na infância. No adulto acordado, alta atividade θ é considerada anormal e relacionada com distúrbios cerebrais, como a epilepsia.
- *ritmos δ* (0,5-3,5 Hz): também são característicos de estágios de sono profundo. Dependendo de sua morfologia, localização e ritmicidade, oscilações δ podem ser normais, tal como durante o sono de ondas lentas ou patológicas como em tumores cerebrais.
- *ritmos γ baixos* (30-60 Hz em EEG humano, 30-80 Hz em ECoG de animais): vários trabalhos têm mostrado correlações de atividade γ com diferentes processos sensoriais e cognitivos, notavelmente durante percepção visual, auditiva, somática e olfativa, bem como com a atenção.
- *ritmos γ altos* (variadamente definidos entre 80-120+ Hz): também chamados de ritmos ϵ , têm sido encontrados em ECoG humano e animal, em associação com potenciais de ação disparados em sequências regulares (“chattering”).

As principais vantagens da EEG sobre as outras técnicas de gravação são a sua *alta resolução temporal* e o fato de que pode ser gravado de forma *não invasiva* (por exemplo, sem a necessidade de uma cirurgia). Devido ao seu *custo relativamente baixo*, gravações

de EEG são amplamente utilizadas tanto em ambientes clínicos quanto em laboratórios de pesquisa. Isso faz da EEG uma ferramenta muito útil e acessível, o que é particularmente interessante para a análise dos processos cerebrais de alto nível, que surgem a partir da atividade de grupo de grandes *populações de neurônios*. Tais processos podem ser bem localizados no tempo, ou eles podem ser correlacionados com os padrões de variação de tempo, como oscilações cerebrais, que estão além da resolução de tempo das técnicas de imagem como a fMRI.

A desvantagem de EEGs não invasivas é o fato de que elas refletem a atividade média de um grande número de fontes distantes dos locais de gravação e, portanto, elas não têm uma resolução espacial ideal. Embora a forma de gravar sinais de EEG não se alterou, tanto quanto no caso de gravações microscópicas e macroscópicas, tem havido avanços significativos na metodologia de análise de dados de EEG. Na verdade, as gravações de EEG têm sido um desafio final para a maioria dos métodos de processamento de sinal, devido à sua alta complexidade, baixa relação sinal-ruído, não-linearidade e não-estacionariedade, características que tornam o processamento de sinais de EEG uma tarefa extremamente difícil [51].

O desenvolvimento e implementação de novos algoritmos que são especificamente projetados para sinais complexos como os EEG nos permitirá obter muito mais informações das que têm sido acessíveis com métodos anteriores e com a inspeção visual convencional de gravações, como é feita por eletroencefalógrafos treinados. Estes métodos abrem uma nova janela para o estudo de processos cognitivos de alto nível em seres humanos com técnicas não invasivas e sem grande despesa [57].

Figura 5.12. Exemplo de sistema MEG [73].

A *magnetoencefalografia* (MEG) mede os campos magnéticos produzidos pela atividade elétrica no cérebro. A Figura 5.12 mostra a instalação de uma MEG típica na qual um sujeito senta em uma cadeira e responde a estímulos em uma tela apertando botões em um dispositivo. Tanto sinais MEG quanto EEG originam do efeito de rede de correntes iônicas que fluem para os dendritos dos neurônios devido às entradas sinápticas provenientes de outros neurônios. Essas correntes produzem um campo magnético

orientado ortogonalmente (como ditado pela equações de Maxwell) [57].

Como a EEG, a MEG apresenta resolução temporal alta pois reflete diretamente a atividade neural, ao invés da atividade metabólica como é o caso de técnicas como a fMRI ou PET. Uma vantagem sobre a EEG é que os campos magnéticos produzidos pela atividade neural não são distorcidos pela matéria orgânica intermediária (como o crânio e o couro cabeludo), como é o caso dos campos elétricos medidos pela EEG. Portanto, a MEG tem resolução espacial melhor que a EEG e é independente da geometria da cabeça. Por outro lado, os sistemas MEG são consideravelmente mais caros que os sistemas de EEG, grandes, pesados e não portáteis e necessitam de uma sala isolada magneticamente para barrar interferências de sinais magnéticos externos, incluindo o campo magnético da Terra.

A imagem de ressonância magnética funcional (*functional magnetic resonance imaging* - fMRI) mede indiretamente a atividade neural no cérebro detectando mudanças no fluxo do sangue devido à atividade aumentada dos neurônios em regiões do cérebro durante tarefas específicas (Figura 5.13). Quando os neurônios tornam-se ativos, eles consomem mais oxigênio, trazido ao cérebro pela corrente sanguínea. A atividade neural engatilha uma dilatação das capilaridades locais resultando em um aumento no fluxo de entrada de sangue altamente oxigenado que substitui o sangue pobre em oxigênio. Esta resposta hemodinâmica é comparativamente lenta - aparece várias centenas de milissegundos depois da atividade neural e tem picos em 3-6 segundos, antes de voltar à linha de base em outros 20 segundos.

Figura 5.13. Uma imagem fMRI com áreas em amarelo mostrando atividade aumentada [75].

A tomografia de emissão de positron (*positron emission tomography* - PET) é uma técnica mais antiga para medir a atividade do cérebro indiretamente através da detecção da atividade metabólica. A PET mede as emissões de substâncias químicas radioativamente rotuladas e metabolicamente ativas que foram injetadas no fluxo sanguíneo de transporte ao cérebro (Figura 5.14).

5.5.2. Gravação e estimulação

Apesar da maioria das BCIs atuais apenas gravarem a atividade neural para controlar dispositivos e prover realimentação visual ou tátil, alguns pesquisadores estão explorando a possibilidade de, simultaneamente, gravar sinais neurais e prover realimentação direta por meio da estimulação neural. Duas abordagens possíveis que estão sendo exploradas incluem usar *matrizes de microeletrodos* e chips implantáveis mais sofisticados, como o

Figura 5.14. Scan PET do cérebro humano [74].

Neurochip, que implementa processamento de sinais e outros algoritmos, processamento da atividade neural e envio de estimulação dentro do próprio chip ao invés de depender de um computador.

Como já foi dito, os microeletrodos usados para gravação da atividade de *spiking* podem também ser usados para enviar corrente despolarizadora ou hiperpolarizadora para excitar ou inibir neurônios. Portanto, em uma matriz multieletrodo, alguns eletrodos podem ser separados para gravação e outros podem ser usados para estimulação.

O Neurochip é um exemplo de um circuito integrado que grava um ou mais neurônios, realiza processamento de sinal útil e outras computações e, baseado nos resultados dessas computações, envia estimulação adequada a um ou mais neurônios [47]. O chip é portanto uma unidade auto-contida, permitindo ao sujeito implantado circular livremente e se comportar naturalmente. O chip alimentado por bateria tem uma matriz de doze eletrodos de microfio de tungstênio móveis (diâmetro de $50\ \mu m$; impedância de $0.5\ M\Omega$; espaço intereletrodo de $500\ \mu m$).

O chip contém um microprocessador que pode realizar o *spike sorting*⁴ em sinais de um conjunto de eletrodos e instruir um circuito estimulador a enviar pulsos elétricos via outro conjunto de eletrodos. Pequenos segmentos de sinais gravados e padrões de estimulação desejada podem ser armazenados na memória *on-chip*. O Neurochip tem sido usado em macacos para demonstrar que a ativação consistente de um grupo de neurônios em correlação com a ativação de um outro pode causar um fortalecimento das conexões entre os dois grupos de neurônios.

5.5.2.1. Gravações

Gravações de EEG no couro cabeludo são realizadas utilizando eletrodos de condutância elevadas colocados no topo da cabeça. Eletrodos são distribuídos em locais específicos, tipicamente utilizando o sistema 10-20, em que de 16-20 eletrodos estão separados por

⁴*Spike sorting* é o agrupamento de *spikes* em clusters baseado na similaridade de suas formas. Dado que, em princípio, cada neurônio tende a disparar *spikes* de um determinado formato, os clusters resultantes correspondem à atividade de diferentes neurônios. O resultado final é a determinação de qual *spike* corresponde a qual desses neurônios.

Figura 5.15. Sistema de EEG 10-20.

10-20% da distância total em torno da circunferência da cabeça (embora seja cada vez mais comum o uso de 32, 64, 128, ou 256 eletrodos) (Figura 5.15). Os eletrodos são colocados sobre a cabeça com gel a fim de aumentar a condutividade com o couro cabeludo. No início, os eletrodos eram colocados manualmente um por um, mas agora eles normalmente já vêm posicionados em um gorro, que pode ser facilmente encaixado em torno da cabeça do sujeito (veja a Figura 5.3). Isto é mais prático e menos demorado, considerando as possibilidades de equipamentos modernos, que permitem a gravação simultânea de mais de 200 canais [57].

A EEG pode ser gravada com referência a um eletrodo passivo comum - gravações monopolares (referenciais) - ou pode ser gravada diferencialmente entre pares de eletrodos contíguos - gravações bipolares. No último caso, existem várias maneiras de escolher os pares de eletrodos de acordo com montagens concebidas para visualizar a propagação de atividade em diferentes direções. Algumas montagens particulares podem ser muito úteis para visualizar as fontes de diferentes padrões de EEG.

Isto é o caso de pulsos cujas localizações, geralmente administrados por uma inversão de polaridade do sinal, podem ajudar no estudo de pacientes com epilepsia. Deve-se notar, no entanto, que a utilidade das diferentes montagens hoje em dia é limitada a uma visualização online dos dados (que costumavam ser armazenados em papel), uma vez que diferentes derivações podem ser calculadas *off-line* com o uso de computadores. Sinais de EEG são gravados com uma frequência de amostragem de 100 Hz ou superior. Sistemas de aquisição modernos podem lidar facilmente com altas taxas de amostragem, e é agora usual gravar EEGs com uma frequência de amostragem de 500 Hz ou maior para permitir o estudo de oscilações de alta frequência ou transições rápidas entre os diferentes eletrodos [57].

5.5.2.2. Artefatos

Devido à sua amplitude muito baixa, sinais de EEG são facilmente contaminados por fontes externas. Estes “artefatos,” inerentes de gravações de EEG do couro cabeludo, são produzidos por movimentos da cabeça, piscar dos olhos, eletrocardiograma, atividade

muscular, etc. Por exemplo, um artefato produzido pelo piscar pode parecer uma verdadeira atividade do cérebro para o olho ingênuo, mas um pesquisador especialista em EEG o reconhecerá facilmente como um artefato do piscar devido à sua morfologia e localização espacial nas posições frontais [57].

Piscar de olhos pode ser melhor identificado, colocando eletrodos perto dos olhos para medir eletrooculogramas. Outros tipos de artefatos são gerados por atividade muscular. Artefatos musculares podem, por exemplo, serem gerados por uma postura tensa, que normalmente está correlacionada com atividade de alta frequência. Estes artefatos podem ser eliminados, em princípio, por meio da utilização de filtros digitais padrões, mas, infelizmente, em alguns casos, isto não é possível porque coincidem com as frequências de interesse. Movimentos da cabeça estão correlacionados com atividade de frequência baixa, e neste caso, o EEG tipicamente mostra uma linha de base flutuante.

Esta atividade pode ser eliminada com um filtro passa-alta (normalmente fixado em 1 Hz), mas novamente, tal filtragem só é adequada quando frequências baixas não são de interesse. Um ponto importante é que os artefatos geralmente limitam a duração das gravações de EEG que podem ser consideradas como estacionárias (isto é, segmentos nos quais as características principais do sinal, tais como a sua média, variância, e espectro de potência não mudam). Com efeito, a duração relativamente curta de gravações de EEG estacionárias é um dos principais desafios para a sua análise [57].

O EEG do couro cabeludo pode ser gravado de forma não invasiva a um baixo custo relativo e tornou-se uma ferramenta de diagnóstico padrão na prática clínica. Em casos muito particulares, eletrodos são colocados dentro da cabeça para realizar gravações intracranianas. Isto é feito, por exemplo, em pacientes que sofrem de epilepsia refratária a medicamentos que são candidatos a cirurgia de epilepsia. O objetivo de gravações intracranianas em pacientes com epilepsia é localizar precisamente a área de início das crises de epilepsia, a fim de avaliar uma eventual ressecção cirúrgica do foco [57].

5.5.3. Potenciais evocados

Em muitos campos científicos, especialmente em física e engenharia, uma maneira muito útil de aprender sobre um sistema é estudar suas reações a perturbações. Na pesquisa do cérebro, é também uma estratégia comum para ver como os neurônios individuais ou grande conjunto de neurônios, conforme registro pela EEG, reagem a diferentes tipos de estímulos. *Potenciais evocados* (*evoked potentials* - EPs) são as alterações na atividade de EEG em curso, devido à estimulação. Eles também são usados como entradas bem definidas em estudos de ECoG. Eles são bloqueados no tempo para o estímulo e possuem um padrão característico de resposta que é mais ou menos reproduzível sob condições experimentais similares [22].

Os EPs são caracterizados pela sua polaridade e latência, por exemplo, *P100* significa uma deflexão positiva (*P* para positivo) que ocorre 100 ms após a estimulação. A gravação de EPs é feita da mesma maneira como o EEG, com o sistema de entrega do estímulo enviando disparadores para o sistema de aquisição, a fim de identificar os inícios e remissões do estímulo. Os EPs podem ser classificados como exógenos e endógenos. Exógenos são os obtidos pelas características físicas do estímulo externo, o qual é tipicamente visual, auditivo ou somatossensorial. EPs endógenos são extraídos por processos

cerebrais internos e respondem à significância do estímulo. EPs endógenos podem ser usados para estudar processos cognitivos.

Os EPs visuais são geralmente evocados por flashes de luz ou padrões visuais tais como um tabuleiro de xadrez. Há uma deflexão positiva a cerca de 100 ms após a apresentação do estímulo (P100), seguido por uma recuperação negativa em 200 ms (N200). Estes picos são mais bem definidos nos eletrodos occipitais, que são os mais próximos da área visual primária. O P100 também é observado nos eletrodos centrais e frontais mas não tão bem definidos e aparecendo mais tarde do que nos locais posteriores. EPs visuais podem ser utilizados na prática clínica para identificar lesões na via visual, tais como aqueles causados por neurite óptica e esclerose múltipla.

5.5.4. Potenciais relacionados a eventos (ERP)

Normalmente, o termo EP refere-se a respostas de EEG à estimulação sensorial. Sequências de estímulos podem ser organizadas em paradigmas e sujeitos podem ser convidados a executar diferentes tarefas. Potenciais relacionados a eventos (*event-related potentials* - ERPs) constituem uma categoria mais ampla de respostas que são desencadeadas por “eventos,” tais como o reconhecimento de um estímulo “alvo” ou a ausência de um estímulo em uma sequência (Figura 5.16).

Figura 5.16. Uma forma de onda mostrando vários componentes ERP, incluindo o N100 e o P300. Note que o ERP é plotado com voltagens negativas crescentes, uma prática comum na pesquisa. No eixo x tem-se o tempo depois do estímulo (em ms) e no eixo y tem-se o potencial (em μV) [70].

O método mais comum para provocar ERPs é usando o *paradigma oddball*. Dois estímulos diferentes são distribuídos pseudo-aleatoriamente em uma sequência: um deles aparecendo frequentemente (estímulo padrão) e o outro sendo um estímulo alvo aparecendo com menos frequência e de forma inesperada. Estímulos padrão e alvo podem ser tons de diferentes frequências, ou figuras de cores diferentes, formas diferentes, etc. Os sujeitos são normalmente solicitados a contar o número de aparições alvo em uma sessão ou a pressionar um botão sempre que um estímulo alvo aparece [57].

A resposta ao estímulo não-alvo é qualitativamente semelhante a resposta a EPs visuais (em que não havia nenhuma tarefa). Tal como no caso dos EPs visuais padrão, o complexo P100-N200 pode ser observado tanto com estimulação não-alvo quanto com estimulação alvo. Estes picos estão essencialmente relacionados com o processamento sensorial primário, devido ao fato de eles não dependerem da tarefa, eles têm uma latên-

cia relativamente curta (100 ms), e eles são melhores definidos na área visual primária (lobo occipital). A estimulação alvo levou a um componente marcado positivo, o P300, aparecendo entre 300 e 500 ms, e é mais marcado nos locais centrais e posteriores.

Embora a localização do P300 no couro cabeludo seja bem conhecida, a localização das fontes do P300 no cérebro ainda é controversa. Uma vez que o P300 é dependente de tarefa, como tem uma latência relativamente longa, ele é tradicionalmente relacionado com os processos cognitivos tais como comparação do sinal, reconhecimento, tomada de decisão, atenção e atualização de memória. Muitos pesquisadores utilizaram o P300 para estudar processos cognitivos. Respostas P300 anormais podem refletir patologias em que a cognição é prejudicada, como tem sido mostrado em depressão, esquizofrenia, demência e outras.

O P300 também pode ser induzido usando um paradigma *oddball* passivo (isto é, uma sequência *oddball* sem qualquer tarefa). Neste caso, uma resposta parecida com P300 aparece sobre a estimulação alvo, refletindo a novidade do estímulo, em vez da execução de uma certa tarefa. Esta resposta foi chamada de P3a. É mais precoce do que o P300 clássico (também chamado P3b) e maior em áreas frontais e centrais.

5.6. Processamento de Sinais

5.6.1. Análise no domínio da frequência: transformada de Fourier

Jean Baptiste Joseph Fourier (1768-1830), um brilhante matemático francês, realizou estudo sobre a condução de calor. Levou ele, no entanto, quase duas décadas para publicar este trabalho, principalmente devido à proposta de uma nova - e no momento controversa - maneira de decompor sinais periódicos em somas ponderadas de funções seno e cosseno. Esta decomposição, nos dias atuais conhecida como *séries de Fourier*, foi sua maior contribuição para a ciência, em grande parte, transcendendo a sua aplicação original para a condução de calor [22].

Seguindo as idéias de Fourier, sinais como os registrados a partir de eletrodos de superfície de EEG do couro cabeludo, podem ser representados no *domínio do tempo* ou, alternativamente, em termos da sua decomposição em senos e cossenos no *domínio da frequência*. Tome-se por exemplo o sinal oscilatório da Figura 5.17a e suponha que se queira transmiti-lo a outra pessoa. Pode-se, em princípio, ditar todos os pontos de tempo da senóide um por um, ou alternativamente pode-se apenas dizer que é uma senóide com uma frequência de 10 Hz (ou seja, um ciclo repetindo-se a cada 100 ms), conforme representado no gráfico da frequência do painel do lado inferior esquerdo. Essas duas visões parecem análogas, embora também seja possível dizer que a representação em frequência parece ser mais compacta e simples.

Tome agora o exemplo da Figura 5.17b do lado direito. É muito difícil conseguir uma compreensão deste sinal a partir da representação do tempo no desenho superior. No entanto, a representação de frequência no desenho inferior fornece uma boa ideia da sua natureza: é apenas a superposição de três senóides de frequências diferentes. Este exemplo simples ilustra a idéia de porque usar representações de frequência. Basicamente, tentou-se obter uma imagem mais simples de algumas das características básicas do sinal, que são geralmente não óbvias a partir de representações de tempo ruidosas e

Figura 5.17. (a) Um sinal senoidal no domínio do tempo (acima) e da frequência (abaixo). (b) Um sinal quase-periódico. Neste caso, a transformada de Fourier fornece uma representação mais simples. No eixo das ordenadas (y) estão representadas as amplitudes dos sinais. Adaptado de [23].

complexas [22].

A representação de frequência de um sinal é dada por sua transformada de Fourier (*Fourier transform* - FT), que tem inúmeras aplicações em diferentes disciplinas científicas. No caso específico de sinais de EEG, é de longe a ferramenta quantitativa mais utilizada, especialmente após a introdução de um algoritmo eficiente e rápido para calculá-la, o *Fast Fourier Transform* (FFT) [12].

5.6.2. Análise no domínio do tempo-frequência

Sabe-se que uma das principais limitações da FT é que ela não tem resolução de tempo. Para calcular a FT, supomos que o sinal é estacionário e, consequentemente, que a atividade em diferentes frequências é constante ao longo de todo o sinal. Em muitas ocasiões, no entanto, os sinais têm características variáveis no tempo que não podem ser resolvidas com a FT. Este é o caso da música, discurso, sons de animais, dados de radar, e muitos outros sinais. Para sinais de EEG, esta limitação é crítica quando analisamos os processos que mudam no tempo, tais como a resposta a um determinado estímulo ou o desenvolvimento de uma crise de epilepsia.

Intuitivamente, podemos superar a falta de resolução de tempo da FT cortando os dados em pedaços e, em seguida, calculando o espectro de potência para cada pedaço ou, ainda melhor, usando uma janela de evolução no tempo para se concentrar em diferentes segmentos de dados. Este procedimento chama-se transformada de Fourier de curta duração (*short-time Fourier transform* - STFT) ou FT de janelas. Se a janela utilizada é uma gaussiana, é chamada transformada de Gabor, em honra de Denis Gabor, físico húngaro que foi o primeiro que desenvolveu essas ideias para analisar as variações de frequên-

cia de sons. Com o STFT é possível acompanhar a evolução no tempo das frequências diferentes e a exigência de estacionaridade é satisfeita ao considerar que os sinais são quase estacionários dentro de cada janela. De acordo com o *princípio da incerteza de Heisenberg*, é possível conseguir resolução de tempo a partir da FT por janelamento do dado.

Há ainda um ponto crítico a ser discutido para a implementação da STFT. Temos de decidir como escolher o tamanho da janela, ou mais especificamente, a taxa de decaimento da função gaussiana. A má notícia é que isto não é tão simples e, novamente, um compromisso deve ser considerado. Se a janela é muito estreita, ela vai dar uma resolução de tempo boa, mas as frequências não serão bem resolvidas (a resolução de frequência é inversamente proporcional ao comprimento dos dados). Pelo contrário, se a janela é muito grande teremos uma resolução de frequência boa, mas a localização no tempo será perdida. Há um compromisso entre a frequência e a resolução de tempo.

Em analogia com o princípio da incerteza de Heisenberg da mecânica quântica (que estabelece que não é possível determinar com acurácia a posição e a velocidade de uma dada partícula ao mesmo tempo), isso é chamado de princípio da incerteza da análise do sinal: frequência e resolução de tempo não podem ser feitos arbitrariamente pequenos, ao mesmo tempo. Em outras palavras, as localizações exatas no tempo e na frequência são mutuamente exclusivas porque precisamos de vários pontos de dados para definir uma frequência [22].

5.6.3. Análise de Ondaletas (*wavelets*)

Mostrou-se que uma questão-chave com a transformada de Fourier de curta duração (STFT) é a escolha do comprimento da janela, tendo em conta a limitação básica imposta pelo princípio da incerteza de análise de sinais. Janelas curtas fornecem boa resolução de tempo (mas resolução de frequência ruim) e, inversamente, longas janelas fornecem boa resolução de frequência (mas resolução de tempo ruim).

No final de 1970, Jean Morlet, um geofísico que trabalhava para uma empresa petrolífera francesa, percebeu que a STFT não era adequada para o estudo de seus dados sísmicos. Ele observou que um bom compromisso entre resolução de tempo e de frequência não foi possível porque os padrões de alta frequência tinham uma duração mais curta em comparação com os de baixa frequência. Assim, uma única janela para todas as frequências não funcionaria. Sua solução foi bastante simples: ele apenas tomou diferentes tamanhos de janela para diferentes frequências, ou mais precisamente, ele tomou uma função cosseno limitada por uma gaussiana (uma função de Gabor) e comprimiu-a ou esticou-a no tempo para obter as diferentes frequências. Em seguida, em vez de sempre ter o mesmo tamanho da janela, ele tinha a mesma forma de onda em diferentes escalas, isto é, com um tamanho variável. Com este truque simples, ele criou a base das ondaletas (*wavelets*)! Em nossos dias, ondaletas são reconhecidas como uma ferramenta muito poderosa de decomposição de sinal com um grande número de aplicações em diferentes campos, incluindo a análise de sinais do cérebro [22].

5.6.4. Análise no domínio do tempo - filtragem bayesiana

Os métodos no domínio de tempo discutidos não mantêm explicitamente estimativas das propriedades do sinal computado no tempo. A manutenção de uma representação de incerteza pode ser importante em BCI pois ações potencialmente desastrosas baseadas em estimativas pobres podem ser evitadas se a quantidade de incerteza associada com uma estimativa é considerada antes de se chegar a uma decisão. Técnicas de filtragem bayesiana provêm uma metodologia estatisticamente válida para estimar as propriedades do sinal e suas incertezas. Técnicas de filtragem espacial consideram como entradas sinais do cérebro gravados de diferentes posições (ou canais) e os transformam de uma ou várias formas. Possíveis metas incluem melhorar a atividade local, reduzir ruído comum entre canais, diminuir a dimensionalidade dos dados, identificar fontes ocultas, ou achar projeções que maximizem a discriminação entre classes diferentes [22].

5.6.5. Redução de artefatos

Artefatos em BCI são sinais indesejáveis que originam de fora do cérebro. Por exemplo, nas BCIs baseadas em EEG, encontra-se o ruído de linha de energia de 50/60 Hz e artefatos causados por movimentos de músculos e olhos. Alguns desses artefatos podem ser permitidos ou mesmo explorados como sinais de controle para certas aplicações tal como jogos ou novos modelos de interação humano-computador. Entretanto uma verdadeira BCI deve possuir a habilidade de eliminar ou reduzir tais artefatos de tal forma que os sinais usados para controlar um dispositivo origemem somente do cérebro. Técnicas de processamento de sinal podem ser usadas para esse fim [22].

5.7. Aprendizado de Máquina

O aprendizado de máquina (*Machine Learning* - ML) tem um papel importante no desenvolvimento de BCIs pois provê técnicas que podem aprender a mapear a atividade neural para comandos de controle apropriados. Algoritmos de ML podem ser divididos em duas classes: aprendizado *supervisionado* e aprendizado *não supervisionado*. No *aprendizado supervisionado*, dados de treinamento consistem de um conjunto de entradas e saídas correspondentes. A meta é aprender a função subjacente a partir dos dados de treinamento tal que novas entradas de teste são mapeadas às saídas corretas.

Se as saídas são classes discretas, o problema é chamado *classificação*. Se as saídas são contínuas, o problema é equivalente à *regressão*. Dada a ênfase em descobrir uma função subjacente, o aprendizado supervisionado é também chamado de *aproximação de função*. O *aprendizado não supervisionado*, por outro lado, enfatiza a descoberta de estrutura estatística escondida em dados não rotulados: os dados de treinamento consistem de entradas que são tipicamente vetores de alta dimensão, e a meta é aprender um modelo estatístico que pode ser compacto ou útil para a análise subsequente.

5.7.1. Aprendizado supervisionado

Classificação é o problema de atribuir um de N rótulos a um novo sinal de entrada, fornecidos dados de treinamento rotulados de entradas conhecidas e seus rótulos de saída correspondentes. *Regressão* é o problema de mapear sinais de entrada a um sinal de saída contínuo. Muitas BCIs baseadas em EEG, ECoG e fMRI dependem da classificação para

gerar saídas de controle discretas (e.g., mover um cursor para cima ou para baixo). As BCIs baseadas em gravações neurais, por outro lado, têm predominantemente utilizado regressão para gerar sinais de saída contínuos, tais como sinais de posição e velocidade para um dispositivo protético. Em geral, a escolha de se usar classificação ou regressão dependerá do tipo do sinal do cérebro gravado e do tipo da aplicação controlada.

5.7.2. Classificação

5.7.2.1. Binária

A tarefa do classificador é atribuir rótulos de classe $y \in Y$ a um vetor de características p -dimensional x . O caso mais simples é quando $y = [-1, +1]$, isto é, discriminação entre duas classes (rotuladas -1 e $+1$). Este caso é chamado de *classificação binária*. O problema de classificação binária reduz-se a achar uma fronteira entre as duas classes baseado nos dados de treinamento rotulados - a meta é achar uma fronteira tal que novos dados possam ser classificados corretamente. Os métodos diferem em como esta fronteira é calculada a partir dos dados de treinamento.

As *redes neurais* são inspiradas na biologia e buscam reproduzir as capacidades adaptativas das redes no cérebro na classificação de dados de entrada de uma maneira robusta. Um importante exemplo é o *perceptron* e sua generalização, o perceptron multi-camadas. O perceptron de camada única computa um hiperplano conforme a Eq. (1), em que o vetor w representa os “pesos sinápticos” que conectam as entradas ao neurônio e $-w_0$ representa o limiar de disparo do neurônio.

$$w^T x + w_0 = 0 \quad (1)$$

A saída do perceptron é mostrada pela Eq. (2).

$$y = \text{sign}(w^T x + w_0) \quad (2)$$

A Eq. (2) tem uma interpretação “neural”: a saída do neurônio é baseada no cálculo de uma soma ponderada de suas entradas ($w^T x = \sum_i w_i x_i$) e na comparação desta soma com um limiar $-w_0$; se a soma ponderada é maior que (ou igual a) o limiar $-w_0$, a saída do neurônio é 1 (um *spike*), de outra forma a saída é 0.

O perceptron adapta seus parâmetros de uma maneira *online*: dada uma entrada x e uma saída desejada y^d , se o erro da saída ($y - y^d$) é positivo, os pesos para entradas positivas são diminuídos, os pesos para entradas negativas são aumentados e o limiar é aumentado, todos por uma pequena quantidade.

O efeito de rede desta regra de “aprendizado” é reduzir o erro da saída para entradas similares no futuro. Se o erro da saída é negativo, os pesos para entradas positivas são aumentados, os pesos para entradas negativas são diminuídos e o limiar é diminuído. Ainda que este algoritmo adaptativo inspirado nos neurônios seja simples e elegante, é aplicável apenas a problemas de classificação nos quais os dados são linearmente separáveis.

Perceptrons multi-camadas (MLP) foram propostos como uma generalização não

linear dos perceptrons para dar conta de problemas de classificação mais difíceis. Os MLPs usam uma não-linearidade sigmoideal (“limiar suave”) ao invés da não-linearidade de limiar degrau para suas unidades neurais (Eq. (3)).

$$y = \text{sigmoid}(w^T x + w_0) \quad (3)$$

A saída da função sigmoide é um número entre 0 e 1, com valores próximos de 0 indicando elemento da classe 1 e valores próximos de 1 indicando elemento da classe 2. A razão para a escolha da sigmoide é que se trata de função diferenciável, permitindo uma regra de aprendizado conhecida como *backpropagation*. Redes neurais baseadas em *backpropagation* são bem sucedidas em várias tarefas de classificação incluindo classificação de dados de BCI e são disponíveis em pacotes de software para classificação, como por exemplo o Weka⁵ e o Matlab⁶. Apesar de poderosas, essas redes neurais sofrem do problema do *overfitting* aos dados de treinamento, resultando em generalização pobre. Assim, a técnica mais recente das máquinas de vetor de suporte (*support vector machines* - SVM) são preferidas como algoritmos de classificação em muitas BCIs.

O perceptron seleciona um hiperplano $w^T x + w_0 = 0$ para separar duas classes. Este hiperplano é apenas um entre um número potencialmente infinito de hiperplanos separando as duas classes de entrada. Pode ser mostrado que entre tais hiperplanos, a melhor generalização é alcançada selecionando o hiperplano com a maior separação (“margem”) entre as duas classes separáveis. A SVM é um classificador que acha um hiperplano separador para o qual a margem entre as amostras das duas classes é maximizada. SVMs lineares têm sido usadas em várias aplicações de BCI.

5.7.2.2. Métodos *ensemble*

Métodos *ensemble* para classificação combinam as saídas de vários classificadores (que discordam entre si em algumas entradas de treinamento) para produzir um classificador final com performance de generalização melhor que qualquer um dos classificadores individuais. Os métodos *ensemble* mais populares, *bagging* e *boosting*, trabalham selecionando diferentes subconjuntos dos dados de treinamento para gerar diferentes classificadores e então combinar suas saídas usando alguma forma de eleição.

5.7.2.3. Classificação multi-classe

Os classificadores apresentados até agora foram projetados para classificar dados em uma de duas classes. Em aplicações BCI, o número de sinais de saída desejado é muitas vezes maior que dois, necessitando de métodos para classificação multi-classes. Há várias estratégias para aplicar classificadores binários ao problema multi-classe.

Uma estratégia para classificação multi-classe é treinar vários classificadores binários e usar eleição majoritária. Dadas N_Y classes, um total de $N_Y(N_Y - 1)/2$ classificadores

⁵<http://www.cs.waikato.ac.nz/ml/weka/>

⁶<http://www.mathworks.com/products/matlab/>

binários são treinados, um para cada combinação binária de classes. Para classificação, uma dada entrada é alimentada a cada um destes classificadores e a classe com o maior número de votos - a classe selecionada pelo maior número de classificadores - é selecionada como saída. A desvantagem desta abordagem é o número relativamente grande de classificadores que precisam ser treinados e usados durante a classificação.

5.7.2.4. Avaliação

Em aplicações BCI, como em outras aplicações dos classificadores, é importante avaliar a acurácia e a performance de generalização do classificador escolhido. A seguir são apresentadas algumas das técnicas de avaliação mais importantes.

Quando se avalia a performance, é útil calcular a matriz de “confusão” $M_{N_Y \times N_Y}$, em que N_Y denota o número de classes. As linhas de M representam os rótulos da classe verdadeira e as colunas representam a saída do classificador. O caso da classificação binária ($N_Y = 2$) é mostrada na Tabela 5.1. As quatro entradas na matriz correspondem a: o número de *verdadeiros positivos* (VP) ou classificações positivas corretas, o número de *falsos negativos* (FN) ou classificações positivas perdidas (erros tipo II), o número de *falsos positivos* (FP) ou classificações positivas incorretas (erros tipo I) e o número de *verdadeiros negativos* (VN) ou rejeições corretas. Os elementos da diagonal M_{ii} da matriz representam o número de amostras classificadas corretamente. Os elementos fora da diagonal M_{ij} mostram quantas amostras da classe i foram classificadas erradamente como classe j .

Tabela 5.1. Matriz de confusão para problemas de duas classes [57].

	Classificação	
	Positivo	Negativo
Classe verdadeira		
Positivo	verdadeiros positivos (VP)	falsos negativos (FN)
Negativo	falsos positivos (FP)	verdadeiros negativos (VN)

Quando se varia algum parâmetro do classificador (e.g., um limiar), obtém-se diferentes números de verdadeiros positivos e falsos positivos. Um gráfico da proporção de verdadeiros positivos versus a proporção de falsos positivos, quando algum parâmetro do classificador é variado, é conhecido como *curva ROC* (*receiver operating characteristic*), um termo com origem na teoria de detecção de sinal.

A *acurácia da classificação ACC* é definida como a razão entre as amostras corretamente classificadas e o número total de amostras. Pode ser derivada da matriz de confusão M como mostrado na Eq. (4).

$$ACC = \frac{VP + VN}{VP + FN + FP + VN} \quad (4)$$

Pode-se então definir a *taxa de erro* como $err = 1 - ACC$. Quando o número de exemplos para cada classe é o mesmo, o *nível aleatório* é $ACC_0 = 1/N_Y$ em que N_Y denota o número de classes.

Uma outra medida de performance útil é o *coeficiente kappa* (Eq. (5)).

$$\kappa = \frac{ACC - ACC_0}{1 - ACC_0} \quad (5)$$

Por definição, o coeficiente kappa é independente do número de amostras por classe e do número de classes. $\kappa = 0$ significa performance de nível aleatório e $\kappa = 1$ significa classificação perfeita. $\kappa < 0$ significa que a performance da classificação é pior que a aleatória.

Para comparar a performance de BCIs, é importante considerar tanto a acurácia quanto a velocidade de uma BCI. Como uma BCI pode ser considerada como um canal de comunicação, pode-se usar ideias da teoria da informação e quantificar a performance da BCI em termos de *taxa de bit* ou *taxa de transferência da informação* (ITR), que é a quantidade de informação comunicada por um sistema por unidade de tempo. Esta medida captura tanto a velocidade quanto a acurácia.

Suponha que uma BCI ofereça N seleções (ou classes) possíveis em cada teste e cada classe tenha a mesma probabilidade de ser aquela que o usuário deseja. Suponha também que a probabilidade P da classe desejada ser realmente selecionada é sempre a mesma (note que $P = ACC$). Cada uma das outras (não desejadas) classes tem a mesma probabilidade de ser selecionada (isto é, $(1 - P)/(N - 1)$).

Então, usando ideias da teoria da informação, pode-se expressar a ITR (ou taxa de bit) como na Eq. (6), medido em bits/teste (dividindo B pela duração do teste em minutos fornece a taxa em bits/min).

$$B = \log_2(N) + P \log_2(P) + (1 - P) \log_2(1 - P)/(N - 1) \quad (6)$$

Para se estimar a taxa de erro err os classificadores são testados nos *dados de teste* que são diferentes dos dados usados para treinar o classificador. Uma abordagem é particionar simplesmente um conjunto de dados de entrada fornecido em dois subconjuntos, um para treinamento e um para teste (o método *hold out*), mas esta estratégia é sensível à forma como os dados são divididos. Uma estratégia mais sofisticada é a *validação cruzada de K pastas*: o conjunto de dados é separado em K subconjuntos de tamanhos aproximadamente iguais, dos quais $K - 1$ são usados para treinar o classificador e o subconjunto remanescente é usado para teste. O classificador é treinado e testado K vezes, resultando em K diferentes taxas de erro err_k .

A taxa de erro total é calculada pela média dos err_k individuais (Eq. (7)).

$$err = \frac{1}{K} \sum_{k=1}^K err_k \quad (7)$$

Existem variações do procedimento acima. Por exemplo, validação cruzada *leave-one-out* é uma forma extrema da validação cruzada de K pastas em que K é feito igual ao número de amostras de treinamento. Em uma outra variação que procura minimizar os efeitos de determinadas partições dos dados, a validação cruzada de K pastas é repetida N

vezes, dando $N \cdot K$ taxas de erro individuais err_i , com a taxa de erro final sendo a média sobre estes $N \cdot K$ valores.

Em muitas aplicações, é comum separar o conjunto de dados de treinamento em três subconjuntos: um subconjunto de treinamento para achar os parâmetros do classificador, um subconjunto de validação para ajustar estes ou outros parâmetros do classificador e um subconjunto de teste para reportar a performance do classificador otimizado. Ainda que esses procedimentos sejam computacionalmente custosos, eles desempenham um papel importante no melhoramento da habilidade de generalização do classificador.

5.7.3. Regressão

Foi visto na seção anterior que a classificação envolve mapear entradas a uma de um número finito de classes. Isto pode ser considerado como um caso especial do problema de aproximação de função em que a saída é discreta. Quando a saída é contínua, isto é, um valor escalar real ou vetor, o problema é equivalente à *regressão*. Como foi no caso da classificação, é fornecido um conjunto de treinamento de N pares de vetores exemplo (u^m, d^m) , em que $m = 1, \dots, N$ e seria desejável aprender uma função que mapeia arbitrariamente vetores de entrada a saídas apropriadas. Discutir-se-á inicialmente a forma mais simples de regressão, a *regressão linear* antes de se estudar métodos de regressão não lineares e probabilísticos.

5.7.3.1. Regressão linear

A regressão linear assume que a função subjacente geradora dos dados é linear, isto é, o vetor de saída é uma função linear do vetor de entrada. Considere o caso especial em que a entrada u é um vetor K -dimensional (e.g., taxas de disparo de K neurônios) e a saída v é um valor escalar (e.g. posição final do efector). Então, a saída é dada pela função linear da Eq. (8), em que w é o vetor de “pesos” ou *filtro linear* que é necessário determinar a partir dos dados de treinamento.

$$v = \sum_{i=1}^K w_i u_i = w^T u \quad (8)$$

5.7.3.2. Redes neurais e *backpropagation*

As redes neurais têm sido algoritmos populares para aproximação de função não linear desde a (re-)descoberta do algoritmo de aprendizado *backpropagation* (BP). Vai-se rever redes neurais sigmóides multi-camadas para regressão não linear e derivar o algoritmo BP. Quando técnicas de classificação foram discutidas, foi apresentado o perceptron, um tipo de rede neural em que cada “neurônio” utiliza uma função de saída limiar em uma soma ponderada de suas entradas [30]. A função limiar é útil para classificação mas para a regressão não linear, uma escolha popular é a função de saída *sigmoide* (ou *logística*) (Eqs. (9) e (10)).

$$v = g(w^T u) \quad (9)$$

$$g(x) = \frac{1}{1 + e^{-\beta x}} \quad (10)$$

A função sigmoide pode ser vista como uma versão mais suave da função limiar: ela espreme suas entradas ao intervalo 0 a 1, com o parâmetro β controlando a inclinação da função (valores maiores de β empurram a sigmoide para perto de uma função limiar). A sigmoide é também facilmente diferenciável, o que se torna importante quando se deriva a regra de aprendizado BP.

Para a regressão não linear, são interessantes redes contendo múltiplas camadas de neurônios, em que a saída de uma camada é alimentada como entrada da próxima camada de neurônios. O tipo mais comum de uma rede multi-camadas é uma rede de três camadas contendo uma camada de entrada, uma camada “escondida” e uma camada de saída.

Pode ser mostrado que, pelo menos teoricamente, tais redes podem aproximar funções não lineares arbitrárias, desde que haja neurônios suficientes na camada escondida. Foca-se portanto em tais redes (com uma única camada escondida).

Suponha que se tenha uma rede de três camadas (uma escondida) de neurônios sigmoidais, com a matriz V representando os pesos da camada de entrada para a camada escondida e a matriz W representando os pesos da camada escondida para a camada de saída. A saída do i -ésimo neurônio na camada de saída pode ser descrita como na Eq. (11).

$$v_i = g\left(\sum_j W_{ji} g\left(\sum_k V_{kj} u_k\right)\right) \quad (11)$$

Como no caso da regressão linear, a meta é mais uma vez minimizar o erro entre o vetor saída desejada nos dados de treinamento e o vetor de saída real produzido pela rede. O algoritmo BP foi proposto como uma solução a este problema.

Pode ser visto que os erros de saída ($d_i - v_i$), em que d_i representa a saída desejada, influenciam a atualização da camada interna de pesos e são apropriadamente modulados por derivadas da função de ativação não linear (a sigmoide) em cada camada. Os erros são então “propagados de volta” para a camada mais baixa. Este procedimento de aprendizado pode ser generalizado para um número arbitrário de camadas, incluindo as redes “profundas” (*deep*) contendo um grande número de camadas escondidas, ainda que tais redes sejam propensas ao *overfitting* dos dados de treinamento, resultando em generalização pobre. A maioria das aplicações BCI tendem a usar redes com uma camada escondida tais como a descrita, com o número de neurônios na camada escondida determinado usando validação cruzada.

5.8. Aplicações

5.8.1. Respostas úteis do cérebro

Uma das propriedades mais importantes dos circuitos neurais é sua plasticidade, permitindo respostas dos neurônios para adaptação como uma função das entradas. Em muitos

casos, esta plasticidade é modulada pelas recompensas recebidas pelo animal. Um exemplo comportamental bem conhecido desta plasticidade é o *condicionamento pavloviano* (ou *clássico*): um cachorro que originalmente saliva em resposta a comida, começa a salivar em resposta a uma campainha depois que a campainha é emparelhada de forma consistente com o estímulo da comida. Neste exemplo, a campainha é chamada de estímulo condicionado e a salivação é a resposta condicionada [57].

Em contraste, no *condicionamento instrumental* (ou *operante*), o animal recebe uma recompensa apenas depois de completar uma ação apropriada, e.g., pressionar uma alavanca. Neste caso, depois da recompensa ter sido emparelhada com a ação de pressionar a alavanca, a ação de pressionar a alavanca torna-se a resposta condicionada.

Respostas condicionadas são também vistas em únicos neurônios e em redes. Em uma das primeiras demonstrações de BCI, Eberhard Fetz na Universidade de Washington utilizou a ideia de condicionamento para demonstrar que a atividade de um único neurônio no córtex motor do primata pode ser condicionado para controlar a agulha de um medidor analógico. O movimento da agulha era diretamente acoplado à taxa de disparo do neurônio: quando a agulha cruzava um limiar, o macaco era recompensado.

Depois de vários testes, o macaco aprendeu a consistentemente mover a agulha para passar o limiar aumentando a taxa de disparo do neurônio sob gravação. Este é um exemplo do condicionamento operante em que a ação (movimento da agulha) que produz recompensa é acoplada à atividade aumentada no neurônio sob gravação (a resposta condicionada).

Respostas condicionadas podem também ser obtidas em grandes populações de neurônios. Por exemplo, depois de várias sessões de treinamento, sujeitos humanos podem controlar a potência em bandas de frequência particulares em sinais de EEG gravados do couro cabeludo. Nestes experimentos, a potência é acoplada ao movimento de um cursor em uma tela de computador usando uma função de mapeamento fixo e a meta é mover o cursor em uma direção desejada para atingir um alvo.

O sujeito gradualmente aprende a controlar o movimento do cursor modulando a potência na(s) banda(s) de frequência usada(s) na função de mapeamento. Neste caso, o condicionamento ocorre no nível da população neural e a resposta condicionada envolve as atividades de grande número de neurônios sendo modulados em concerto para gerar o aumento ou diminuição apropriado na potência na banda de frequência desejada.

Em resumo, tanto as respostas de neurônio único quanto de redes de neurônios podem ser moduladas como uma consequência do acoplamento da atividade neural com ações externas (tais como movimentar o cursor) e recompensas que são contingentes à execução de ações apropriadas (atingir um alvo).

Os neurônios no córtex motor primário codificam para vários atributos de movimento tais como a direção do movimento de um membro (braço ou perna), velocidades, forças, etc. Em vários experimentos importantes, Georgopoulos e colegas [27] mostraram que o movimento é representado usando um código de população. Por exemplo, no caso da direção do movimento, os neurônios na população disparam de acordo com o quão perto sua direção preferida de movimento está em relação à direção real do movimento. A direção real do movimento pode ser predita, por exemplo, por uma combinação pon-

derada das direções preferidas dos neurônios, o peso para cada neurônio sendo a taxa de disparo do neurônio. Este método da decodificação da direção do movimento é chamado de decodificação do *vetor de população*.

O fato de que variáveis relacionadas a movimento podem ser extraídas das atividades de populações de neurônios foi um importante achado para a BCI porque permite supor que a mesma atividade motora da população poderia ser usada para controlar o movimento de membros artificiais e outros dispositivos. Algumas das demonstrações mais impressionantes de BCI em animais baseiam-se no uso de técnicas de regressão para mapear a atividade motora da população a sinais de controle apropriados para dispositivos protéticos.

Um terceiro tipo de resposta do cérebro que é muito usado para BCI em humanos é a atividade neural produzida quando um sujeito voluntariamente imagina fazendo um movimento particular (*imagética motora*). Imaginar um movimento produz atividade neural similar espaço-temporalmente à atividade gerada durante o movimento real, mas menor em magnitude. Vários algoritmos de aprendizado de máquina (tipicamente, classificadores) podem ser aplicados para discriminar entre dois ou mais tipos de movimentos imaginados, permitindo cada atividade imaginada ser mapeada a um sinal de controle particular (e.g., mover o cursor para cima). A resposta inicialmente fraca devido ao movimento imaginado torna-se mais robusta quando o sujeito recebe retroalimentação enquanto aprende a controlar o cursor. Em alguns sujeitos, a atividade imaginada durante o controle do cursor pode até exceder a atividade observada durante o movimento real.

Similar aos movimentos imaginados, pode-se pedir a um sujeito humano que realize uma tarefa cognitiva como uma aritmética mental ou a visualização de um rosto. Se as tarefas cognitivas forem suficientemente distintas, as áreas do cérebro que são ativadas também serão diferentes e a ativação resultante do cérebro, medida por exemplo pela EEG, pode ser discriminada usando um classificador treinado com um conjunto inicial de dados coletado do sujeito. Cada tarefa cognitiva é mapeada a um sinal de controle (e.g., a realização da aritmética mental é mapeada para mover o cursor para cima, etc.). A abordagem portanto é baseada fortemente em ser capaz de discriminar com confiança os padrões de atividade para tarefas cognitivas diferentes, fazendo a escolha das tarefas cognitivas uma decisão de projeto experimental importante e complicada.

Outra classe de sinais do cérebro útil para BCI é baseada na atividade estereotipada gerada pelo cérebro em resposta a tipos especiais de estímulos. Um exemplo particularmente importante é o sinal P300 (ou P3) observado em gravações de EEG, chamado assim porque é uma deflexão positiva no sinal de EEG que ocorre aproximadamente 300 ms depois do estímulo. Como já foi visto, o P300 é um exemplo de um “potencial relacionado a evento” (ERP) ou “potencial evocado” (EP) - ele é evocado pela ocorrência de um estímulo raro ou imprevisível. É geralmente observado mais fortemente no lobo parietal, ainda que alguns componentes também originam nos lobos temporal e frontal. Os mecanismos neurais exatos responsáveis pelo P300 ainda não estão claros: várias estruturas do cérebro, como córtex parietal, o giro cingulado e o córtex temporoparietal e estruturas límbicas (hipocampo, amígdala) têm sido implicados como substratos para o P300.

Outros tipos comuns de EP incluem o potencial visualmente evocado de estado estável (SSVEP), o N100 e o N400. O SSVEP é a resposta obtida em populações de

neurônios no córtex visual quando o sujeito está fixando em um estímulo visual (e.g., tabuleiro de xadrez) piscando em uma frequência particular (e.g., 15 Hz). O sinal do cérebro associado, gravado por exemplo, usando EEG, exibe picos no espectro de potência na frequência do estímulo e suas harmônicas. Se frequências diferentes estão associadas com escolhas diferentes, uma BCI pode decodificar a escolha do sujeito detectando onde os picos estão.

O N100 (ou N1) é um potencial negativo que ocorre aproximadamente 100 ms depois de um estímulo imprevisível e é tipicamente distribuído pelas regiões frontal e central da cabeça. É usualmente seguido por uma onda positiva (P200) resultando no “complexo N100-P200”. O N100 ocorre por exemplo em resposta a um barulho alto e repentino, mas não se o som é criado pelo sujeito.

O N400 é um outro exemplo de uma deflexão negativa no potencial que tem pico aproximadamente 400 ms depois de determinados tipos de entradas incongruentes mas potencialmente significativas, tal como palavras inapropriadas semanticamente ocorrendo em uma sentença durante a fala. É tipicamente distribuído nas posições central e parietal do couro cabeludo. O N400 é similar a um outro tipo de potencial chamado de *potencial de erro* (ErrP) evocado quando um erro é observado depois da realização de uma ação.

5.8.2. Aplicações médicas

5.8.2.1. Restauração

O campo da BCI originou do objetivo de ajudar pessoas paralisadas e deficientes. Portanto não é surpresa que algumas das maiores aplicações de BCIs sejam em tecnologia médica, particularmente restabelecendo função sensorial e motora.

Uma das BCIs mais usadas é o implante coclear para os surdos (Figura 5.18). O implante coclear é um exemplo de BCI para restauração sensorial, da mesma forma que implantes retinais desenvolvidos para os cegos.

Não há muita pesquisa nos outros dois tipos possíveis de BCIs puramente sensoriais, as BCIs para somatosensação e as BCIs para olfato e paladar. No caso do primeiro, a necessidade da BCI é minimizada porque normalmente é possível restaurar a sensação tátil por meio de enxerto de pele. Entretanto, há um interesse considerável em estimulação somatosensorial como um componente de BCIs bidirecionais para permitir que indivíduos paralisados e amputados possam, por exemplo, sentir objetos segurados ou tocados por dispositivos protéticos.

No caso de BCIs para olfato e paladar, têm havido esforços para construir “narizes artificiais” e chips que podem sentir vários tipos de odores, mas estes dispositivos são construídos mais para segurança e robótica e menos para BCIs. A falta de interesse em desenvolver BCIs para olfato e paladar é devida mais à falta de uma grande população de indivíduos necessitando de tais BCIs, comparado à população de pessoas com deficiência visual ou auditiva [57].

Uma outra grande motivação para pesquisa de BCI nas duas últimas décadas tem sido o objetivo de desenvolver dispositivos protéticos para indivíduos paralisados e amputados que podem ser controlados usando sinais neurais. Talvez o mais próximo de ser

Figura 5.18. Ilustração de um implante coclear. Adaptado de [7].

comercializado estão os braços protéticos que podem ser controlados por sinais de nervos intactos (BCI semi-invasiva). Mais adiante no futuro estão braços e mãos protéticos que podem ser controlados diretamente usando neurônios corticais - os primeiros protótipos de tais BCIs estão correntemente sendo testados em macacos e humanos (BCIs invasivas).

Provavelmente o mais desafiador sejam próteses de pernas controlados por sinais do cérebro. Neste caso, o sistema de BCI/prótese precisa ser capaz de manter a estabilidade e permitir ao usuário manter o equilíbrio enquanto obedece a comandos do cérebro e provê retroalimentação por meio da estimulação de neurônios somatosensoriais apropriadamente. Uma abordagem baseada em BCIs hierárquicas baseado em uma mistura de autonomia e controle do usuário pode prover a forma mais flexível de controlar próteses de membros inferiores.

Similarmente, a estimulação profunda do cérebro (DBS) tem sido usada não apenas para tratar os sintomas do mal de Parkinson mas também para aliviar a dor crônica e a depressão. Finalmente, BCIs que podem gravar memórias e estimular centros de memória apropriados do cérebro poderiam ajudar a combater o prejuízo da memória de doenças tais como a doença de Alzheimer, embora o desenvolvimento de tais BCIs exigirá uma compreensão mais profunda de como as memórias são criadas e armazenadas no cérebro do que o que se conhece hoje.

5.8.2.2. Reabilitação

Uma outra aplicação potencialmente significativa de BCIs é em reabilitar pacientes em recuperação de derrame, cirurgia ou outra condição neurológica. A BCI seria parte de um

sistema de retroalimentação fechado que converte sinais do cérebro em estímulo em uma tela de computador ou em movimentos de um dispositivo de reabilitação. Tal sistema de retroalimentação neural pode habilitar pacientes a aprender a gerar o tipo apropriado de atividade neural para acelerar sua reabilitação.

Uma grande motivação para o desenvolvimento de BCIs baseadas em EEG não invasivas tem sido a restauração da comunicação para pacientes paralisados mas conscientes sofrendo de doenças motoras progressivas tal como a esclerose lateral amiotrófica (ALS, também conhecida como mal de Lou Gehrig). Nos casos em que os pacientes são incapazes mesmo de piscar ou sugar um canudo para indicar uma resposta “sim” ou “não”, uma BCI torna-se o único modo possível de comunicação.

Uma abordagem para restaurar a comunicação é construir uma BCI para controlar um cursor em um sistema de menu, permitindo ao paciente selecionar uma opção de um conjunto de escolhas. Um sistema de menu permite a composição de sentenças longas ou sequências de comandos. O cursor em tal sistema pode ser controlado por exemplo, via controle voluntário dos potenciais oscilatórios ou potenciais corticais lentos (não invasivos) ou também por métodos invasivos [57].

Alternativamente, um método evocado por estímulo tal como o soletrador BCI P300 pode ser usado para selecionar letras para soletrar palavras. Tanto o soletrador quanto abordagens baseadas em cursor podem ser bem lentas e tediosas para o paciente. Uma BCI mais natural para comunicação implica o aproveitamento dos centros da fala do cérebro. Alguns resultados preliminares em decodificar fonemas a partir da atividade neural gravada da região da fala (área de Broca) do córtex cerebral foram publicados [6], mas um entendimento mais aprofundado do processamento da fala no cérebro é necessário antes de uma BCI ser desenvolvida para traduzir pensamentos linguísticos.

Pacientes paralisados são algumas vezes capazes de controlar uma *cadeira de rodas* usando partes de seu corpo que ainda estão sob controle voluntário. Outros podem ser capazes de usar a fala para emitir comandos a uma cadeira de rodas semi-autônoma. Pode-se controlar uma cadeira de rodas diretamente usando sinais do cérebro?

A abordagem mais simples é usar uma BCI para selecionar comandos de alto nível (e.g., ir para a cozinha, ir para o quarto, etc.) e dotar a cadeira de rodas com conhecimento e autonomia suficientes para ser capaz de executar estes comandos de uma maneira autônoma. Os comandos de alto nível podem ser selecionados usando uma BCI síncrona, tal como a BCI baseada no P300. Esta abordagem pode ser flexível e adaptativa às necessidades do usuário usando uma BCI hierárquica.

Uma abordagem diferente [24] baseia-se no conceito de *controle compartilhado* (Figura 5.19). Nesta abordagem, o usuário continuamente gera comandos para o robô que são então probabilisticamente combinados com comportamentos pré-programados. A cadeira de rodas tem sensores como o *scanner* na faixa do laser. Se a meta do usuário é se mover suavemente no ambiente, a informação dos sensores da cadeira de rodas pode ser usada para construir um “filtro contextual” na forma de uma distribuição de probabilidade $P_{Env}(C)$ sobre um conjunto de possíveis comandos de direção mental, e.g., $C = [esquerda, direita, frente]$. O sistema BCI baseada em EEG estima as probabilidades $P_{EEG}(C)$ para diferentes comandos mentais a partir dos sinais do cérebro do usuário.

Figura 5.19. Controle BCI de uma cadeira de rodas inteligente [76].

Ainda que os resultados preliminares sejam animadores, uma cadeira de rodas controlada por BCI prática para o uso do dia-a-dia continua uma promessa devido à falta de um sistema de gravação (EEG ou outra modalidade) confiável, fácil de usar e portátil, assim como a falta de cadeiras de rodas robóticas robustas, e semi-autônomas, que podem funcionar seguramente em ambientes humanos.

5.8.3. Outras aplicações

5.8.3.1. Navegação na web e em mundos virtuais

Tem havido um crescimento no número de aplicações não médicas da tecnologia BCI. Muitas destas aplicações foram impulsionadas por fatores comerciais, tais como o potencial para uma nova interface para jogos e entretenimento. A maioria destas aplicações ainda está em sua infância e sendo investigada em laboratórios de pesquisa, embora algumas tenham sido aplicadas a problemas do mundo real, tais como triagem de grandes quantidades de imagens e detecção de mentiras.

Um exemplo de uma interface web-browser controlada por BCI é Nessi (*Neural Signal Surfing Interface* [2]), que permite ao usuário selecionar qualquer *link* em uma página web e acessar serviços baseados em web. Nessi é um software independente de plataforma e código aberto que pode ser usado com diferentes tipos de BCI. Uma demonstração usa uma BCI de duas classes baseada em potenciais corticais lentos (SCP). Quadros vermelhos ou verdes são colocados em volta de *links* em uma página web: quadros vermelhos eram selecionados produzindo deslocamentos SCP negativos e quadros verdes eram selecionados por deslocamentos SCP positivos.

Retroalimentação era provida na forma de um cursor que era movido para cima para uma meta vermelha ou para baixo para uma meta verde usando a BCI baseada em

SCP. O usuário tinha apenas de observar a cor do quadro do *link* desejado para saber que tipo de resposta do cérebro produzir, podendo portanto sucessivamente o conjunto de itens selecionáveis via decisões binárias até que o *link* desejado fosse selecionado.

5.8.3.2. Avatares robóticos

Telepresença controlada pelo cérebro, ou a idéia de controlar um avatar robótico remoto diretamente com a mente humana, tem sido objeto de filmes de Hollywood, como *Avatar* e *Surrogates*, mas os avanços na robótica e tecnologia BCI estão trazendo a idéia para mais próximo da realidade. Já se discutiu os esforços de investigação em curso para construir BCIs que podem controlar cadeiras de rodas robóticas. Uma linha paralela de pesquisa tem como alvo o desenvolvimento de robôs de assistência e avatares que podem ser controlados remotamente por meio de sinais cerebrais. Além de telepresença, esses robôs podem ajudar as pessoas paralisadas ou com deficiência na realização de várias tarefas na vida do dia-a-dia, tais como a obtenção de um copo de água da cozinha ou a busca de um frasco no armário de remédios [57].

Uma abordagem para avatares robóticos tem se concentrado em sistemas BCI baseados em EEG para controle de robôs humanóides [1]. Em uma das primeiras manifestações de um “avatar” controlado pelo cérebro, uma BCI baseada em P300 foi utilizada para comandar um robô humanóide para ir para locais desejados e buscar objetos desejados [1]. O usuário tinha uma visão do olho do robô do ambiente, o que proporcionou uma experiência imersiva. O robô tinha a capacidade de mover-se de forma autônoma e pegar/liberar objetos. O robô também possuía alguns recursos de visão computacional, tais como ser capaz de segmentar objetos que ele viu em uma mesa e usar visão para navegar para um destino.

Esforços mais recentes têm focado em fazer a BCI mais adaptável às necessidades do usuário usando BCIs hierárquicas para aprender novos comandos para o robô. Futuros avatares robóticos controlados pelo cérebro podem permitir mais controle refinado, talvez com base em gravações invasivas, bem como retroalimentação mais rica do robô, incluindo retroalimentação auditiva e tátil e, finalmente estimulação direta de áreas sensoriais do cérebro com base nas leituras dos sensores do robô.

5.8.3.3. Busca de imagens em alta quantidade

O cérebro humano é extremamente habilidoso no processamento visual em relação aos atuais sistemas de visão computacional. Uma aplicação interessante de BCIs é aproveitar as capacidades de processamento de imagem do cérebro para uma rápida busca visual de grandes conjuntos de dados de imagem. A idéia, explorada por Sajda e colegas [62], é usar a análise de um único teste para rapidamente detectar assinaturas neurais correlacionadas com o reconhecimento visual. Suponha que o objetivo seja classificar imagens (por exemplo, imagens de satélite) de tal modo que as imagens com maior probabilidade de conter objetos de interesse (por exemplo, tanques) são colocadas no início da sequência de imagens para um exame mais aprofundado.

Gerson e colegas [28] desenvolveram uma BCI baseada em EEG em tempo real para triagem de tais imagens usando o paradigma da apresentação visual serial rápida (RSVP). A sua técnica, denominada *visão computacional corticalmente acoplada* (CCCV) baseia-se no paradigma *oddball* para provocar um P300: uma imagem alvo que ocorre em uma sequência de imagens distratoras não-alvo vai causar uma resposta P300.

Em cada teste, é apresentada ao sujeito, uma sequência contínua de 100 imagens, cada imagem durando 100 ms. A sequência continha 2 imagens alvo com 1 ou mais pessoas em uma cena natural. A aparição repentina de uma imagem alvo na sequência tipicamente provocou um P300, que foi detectado por um classificador. A saída do classificador foi usada para repriorizar a sequência de imagens, colocando as imagens alvo detectadas na frente da pilha de imagens.

5.8.3.4. Detecção de mentiras e aplicações na lei

Uma aplicação de BCIs que provocou um interesse (e polêmica) considerável em comunidades de justiça penal e lei é a detecção de mentira ou detecção de posse de conhecimento culpado. A técnica tradicional é o polígrafo, que mede as reações corporais de sujeitos, tais como alterações na pressão sanguínea, a condutividade da pele, e frequência cardíaca enquanto ele ou ela responde a uma série de perguntas durante um interrogatório. A premissa é que respostas enganosas irão produzir respostas fisiológicas diferentes daquelas associadas com respostas verdadeiras [57].

Embora a poligrafia seja usada por muitas agências de aplicação da lei, é geralmente considerada pouco confiável pela maioria dos cientistas porque mede a ansiedade, em vez do engano, e seus níveis de acurácia são considerados pouco melhores do que o acaso.

Para superar as deficiências do polígrafo, os pesquisadores de BCI têm explorado o uso de respostas do cérebro como um modo para detectar se um sujeito anteriormente encontrou ou possuiu conhecimento sobre uma pessoa específica, lugar ou objeto. O desafio é projetar uma BCI para a *detecção de memória* que poderia ser usada diretamente para interrogar os cérebros de suspeitos e testemunhas. O objetivo é encontrar prova neural, se existir, de reconhecimento de uma pessoa, lugar ou objeto vinculado a uma cena de crime.

Um dos primeiros exemplos de uma BCI “detectora de mentiras,” baseado no potencial relacionado a evento (ERP) P300 foi investigado por Farwell e Donchin [13]. Neste paradigma, o sujeito é solicitado a discriminar entre alvos predeterminados e estímulos irrelevantes. Incorporado entre os estímulos irrelevantes, está um conjunto de itens de diagnóstico chamado de “sondas”, que são indistinguíveis a partir de itens irrelevantes se o sujeito não possuir conhecimento culpado. Para os indivíduos que possuem conhecimento culpado, as sondas são percebidas de forma diferente dos itens irrelevantes e são susceptíveis de provocar um P300, o qual pode ser detectado por uma BCI.

5.8.3.5. Monitoramento de alerta

Uma aplicação potencialmente importante de BCIs é a monitoração do estado de alerta dos seres humanos durante a execução de tarefas críticas, mas potencialmente monótonas, como direção de veículos ou vigilância. Muitos acidentes catastróficos são causados anualmente por condutores que estão cansados, sonolentos, ou até mesmo dormindo ao volante. Esses acidentes podem ser evitados monitorando os sinais do cérebro para qualquer transição de um estado de alerta e de vigília para um estado que indica falta de atenção. Embora os estados de sono ou sonolência possam ser detectados pelo monitoramento do fechamento das pálpebras, tal detecção pode ocorrer tarde demais para evitar um acidente [57].

Detecção baseada em cérebro de alerta diminuída também tem aplicações na educação e aprendizagem em que tal detecção poderia ser usada para medir o grau em que um estudante está envolvido durante uma aula.

Os pesquisadores têm procurado achar correlatos de uma diminuição da atenção e alerta em sinais cerebrais, especialmente EEG. Conhece-se, por algum tempo, que um aumento na potência em certas bandas de frequência (tais como alfa, 8-13 Hz) em correlatos de EEG com uma diminuição na concentração, conforme medido por taxas de erro mais elevadas na detecção de tarefas [57].

5.8.3.6. Educação e aprendizado

Já foi discutido como técnicas de BCIs não invasivas são úteis para medir o nível de alerta e a carga cognitiva durante a realização de uma tarefa. Ideias similares podem ser aplicadas para avaliar o grau de envolvimento, atenção e carga cognitiva de um estudante ouvindo uma palestra ou fazendo um exercício. Por exemplo, a empresa NeuroSky desenvolveu um aplicativo BCI que tenta medir o nível de atenção do usuário durante um exercício de matemática. A BCI é baseada no *headset* da NeuroSky, o MindWave, que mede EEG a partir de um eletrodo seco frontal [57].

Em um estudo recente, Szafir e Mutlu [65] também usam um eletrodo frontal na posição Fp1 no sistema 10-20 para monitorar o nível de atenção de um aluno enquanto o aluno ouvia um conto popular japonês sendo recitado por um robô humanóide. Durante os 10 minutos da história sendo contada pelo robô, sempre que o sistema detectava (a partir do sinal de EEG) que o nível de atenção do aluno caía, o robô levantava a sua voz ou executava movimentos do braço para recuperar a atenção do aluno. Os pesquisadores descobriram que os alunos que ouviam a história do robô, cujo comportamento era contingente à BCI de detecção de atenção, eram muito melhores nas respostas a perguntas sobre o conto popular, respondendo uma média de 9 das 14 perguntas corretamente, em comparação com os alunos para quem o robô não exibiu comportamento contingente à atenção.

Os primeiros resultados discutidos acima, se verificados em estudos aprofundados subsequentes, indicam que as BCIs poderiam potencialmente fornecer retroalimentação valiosa para educadores, bem como para alunos, permitindo medidas adequadas a serem tomadas para estratégias educacionais, paradigmas de interação e lições de acordo com o

estado de atenção e necessidades correntes de cada estudante. Ser capaz de detectar um envolvimento do aluno ou um nível de atenção pode ser especialmente útil para esforços educacionais *on-line* (tais como os buscados por Khan Academy, Coursera, EdX, e Udacity) em que não há nenhum professor humano para medir o envolvimento do aluno quando o aluno está assistindo material apresentado em um vídeo *on-line*.

Os alunos podem ainda usar a BCI como um dispositivo de apoio para melhorar a sua concentração e performance. A BCI pode também ser útil para ajudar os alunos com transtornos de déficit de atenção ao apanhar lapsos de atenção e redirecionar o foco. Assim que avanços na neurociência fornecem uma compreensão mais aprofundada dos mecanismos envolvidos na aprendizagem e compreensão, pode-se esperar novas BCIs a ser desenvolvidas que aproveitem esses avanços e acelerem a aprendizagem, adaptando-se ao estilo e velocidade de aprendizado de cada estudante. Os professores e os pais poderiam potencialmente determinar o grau em que um aluno aprendeu um conceito particular diretamente a partir de mudanças em sinais do cérebro, fornecendo uma alternativa aos testes padronizados para medir a competência e a aprendizagem [57].

5.8.3.7. Segurança, identificação e autenticação

As BCIs estão começando a ser aplicadas a problemas de segurança tal como a identificação biométrica para a recuperação de informações de bancos de dados e autenticação para controle de acesso (e.g., para segurança de aeroporto, login de conta, ou banco eletrônico). Como um exemplo, a atividade do ritmo alfa distintivo de um sinal de EEG individual tem sido proposta como uma assinatura biométrica para identificação. Em um estudo [55], sujeitos foram solicitados a relaxar e fechar os olhos enquanto o EEG era registrado a partir de eletrodos O2 e Cz no sistema 10-20. O sinal bipolar obtido da diferença entre O2 e Cz foi filtrado por passagem de banda na banda de frequência 7.5-12.5 Hz (banda alfa) usando FFT e FFT inversa [57].

Enquanto a identificação envolve reconhecer uma pessoa de um grande grupo de indivíduos, o problema de autenticação envolve a verificação se a pessoa que alega uma identidade é realmente essa pessoa ou um impostor. Pesquisadores estão começando a explorar a utilização de BCIs baseadas em EEG para autenticação. Em um estudo realizado por Marcel e Millan [45], os indivíduos foram convidados a executar uma de 3 tarefas mentais (imaginação de movimentos da mão esquerda ou direita e geração de palavra). Os sinais de EEG foram espacialmente filtrados usando um filtro laplaciano e características espectrais de potência na banda 8-32 Hz foram extraídas usando a FFT. Essas características foram utilizadas para construir um modelo probabilístico dos dados [57].

5.8.3.8. Amplificação física com exoesqueletos

Muitos vilões das histórias em quadrinhos querem amplificar o poder do corpo humano para alcançar força sobre-humana (por exemplo, Dr. Octopus em *Homem-Aranha*). Exoesqueletos motorizados oferecem os meios para atingir amplificação do corpo humano além do que a evolução nos dotou. Enquanto os pesquisadores têm explorado os mecanismos de controle para exoesqueletos com base em sinais de movimentos auto-gerados ou

sinais musculares (EMG), os pesquisadores de BCI começaram recentemente a explorar a utilização de sinais cerebrais para controlar diretamente um exoesqueleto (Figura 5.20).

Figura 5.20. Exoesqueleto das forças armadas americanas [72].

Como exemplo, o projeto europeu Mindwalker procura usar sinais de EEG gravados a partir de eletrodos secos de design personalizado e redes neurais recorrentes para controlar um exoesqueleto robótico anexado às pernas do sujeito. O duplo objetivo do projeto é habilitar pessoas com lesões na medula espinhal a alcançar mobilidade e a ajudar na recuperação de astronautas depois de uma missão prolongada no espaço.

Uma série de empresas como a Cyberdyne, EKSO Bionics, e Raytheon têm desenvolvido exoesqueletos motorizados que amplificam a força dos usuários, permitindo-lhes levantar e transportar até 200 libras de peso (90.7 Kg) com pouco ou nenhum esforço. No futuro, exoesqueletos de corpo inteiro poderiam ser utilizados por equipes de salvamento, bombeiros, e soldados para se mover mais rápido, saltar mais alto, carregar cargas mais pesadas, e executar outras proezas físicas que não podem ser executadas por um organismo humano normal. Estes exoesqueletos poderiam potencialmente ser controlados por sinais cerebrais, e a retroalimentação do exoesqueleto poderia ser utilizada para estimular diretamente centros somatossensoriais apropriados no cérebro para permitir controle preciso, na medida em que o exoesqueleto possa ficar incorporado como parte do mapa do corpo no cérebro do usuário [57].

5.8.3.9. Amplificação mnemônica e cognitiva

O enredo do filme *Johnny Mnemonic* gira em torno do protagonista agindo como um mensageiro com dados secretos implantados em seu cérebro. Outros roteiros de ficção

científica têm contado com máquinas que podem injetar seletivamente ou apagar memórias. Essas habilidades ainda têm de ser demonstradas em uma BCI, mas os pesquisadores começaram recentemente a explorar a possibilidade de restauração da memória e ampliação das funções cognitivas via gravação e estimulação neurais.

Embora ainda a serem testados em seres humanos, os implantes de memória oferecem um raio de esperança para aqueles que sofrem de doença de Alzheimer, amnésia, e outros distúrbios de memória devastadores. Além disso, a capacidade de armazenar e amplificar certas memórias abre a porta para novas formas de valorização da memória e amplificação cognitiva para indivíduos sãos. Por exemplo, memórias podem ser armazenadas *off-line* (por exemplo, na “nuvem”) e recuperadas quando necessárias, por meio de implantes sem fio. Embora seres humanos hoje rotineiramente usem a internet, livros, smartphones, computadores e outros dispositivos como armazenamentos de memória externa, os implantes de memória fariam acesso a tais informações essencialmente de forma suave, permitindo armazenamento e recuperação apenas por meio do pensamento [57].

5.8.3.10. Jogos e entretenimento

Muitos paradigmas BCI tradicionais (por exemplo, controle de cursor) têm um gostinho de jogo. Para aplicações médicas, como a seleção de menu ou reabilitação com base em retroalimentação neural, usar um paradigma de interação tipo-jogo ajuda na manutenção do interesse do paciente. Esses aplicativos não foram projetados com fins de entretenimento em mente, mas o jogo para os indivíduos sãos não deixa de ser uma das áreas de BCI de aplicações não-médicas que cresce com mais rapidez. Uma das razões para este crescimento é o enorme mercado que existe atualmente para *video-games*, diminuindo o mercado para aplicações médicas de BCIs [57].

Uma segunda razão é que ao contrário de aplicações médicas, como cadeiras de rodas ou próteses controladas por BCI, o desempenho deficiente de uma BCI em um jogo pode incomodar um usuário mas normalmente não causa danos corporais ou prejuízo para o usuário ou indivíduos nas proximidades, diminuindo assim as preocupações de responsabilidade. Finalmente, as BCIs podem ser utilizadas em jogos como uma interface que melhora outras interfaces mais tradicionais, como *joysticks*, *gamepads*, sistemas de reconhecimento de gestos, e assim por diante. Assim, ao contrário de aplicações médicas das BCIs, tais como sistemas de comunicação para pacientes *locked-in*, as BCIs para jogos podem depender ativamente de uma mistura de sinais cerebrais (por exemplo, sinais de EEG), sinais musculares (EMG), e movimentos de mão/corpo para alcançar um novo modo de interação humano-computador [57].

Em um dos primeiros estudos a explorar esta direção, Cheung e colegas [10] demonstraram que os sujeitos poderiam controlar o movimento bidimensional de um cursor usando um *joystick* simultaneamente com imagética motora de mão em uma BCI baseada em EEG. Sujeitos aprenderam a usar imagética para controlar o movimento de cima para baixo do cursor e simultaneamente utilizar o *joystick* para o controle do movimento esquerda-direita do cursor. Estes resultados sugerem que pode ser possível utilizar BCIs para aumentar a capacidade motora normal em indivíduos sãos.

Um grande número de jogos controlados pelo cérebro foi introduzido ao longo da

última década. Brainball foi um jogo BCI em que os usuários aprenderam a controlar o seu nível de relaxamento, controlando seu ritmo alfa. MindGame é um jogo mais recente baseado no P300, que envolve o movimento de um personagem em um jogo tridimensional de tabuleiro. Outros aplicativos de jogos têm contado com SSVEP e imagética motora (por exemplo, o BCI-PacMac), bem como navegação virtual baseada em EEG [63].

Uma demonstração interessante de controle em tempo real de um dispositivo de jogos físico envolveu uma máquina de pinball controlada por BCI, em que o *paddle* era controlado por uma BCI de 2 classes baseada em imagética (por exemplo, imagética motora de mão esquerda e direita). Os parâmetros BCI estavam sintonizados individualmente para cada usuário. Os pesquisadores relataram que o jogo era percebido como altamente imersivo e motivador.

Houve também uma versão controlada por BCI do popular videogame Tetris [5]. O jogo de BCI baseada em EEG baseia-se em um conjunto “natural” de controles: o jogador usa imagética motora de mão esquerda ou direita para mover uma peça Tetris caindo para a esquerda ou a direita respectivamente, e rotação mental para girar a peça no sentido horário e imagética motora do pé para soltar a peça. Um classificador de 4 classes (3 comandos de imagética motora e rotação mental) foi treinado em uma fase de calibração *off-line* e, em seguida, aplicado *on-line* durante a fase do jogo para conseguir o controle de uma peça caindo [57].

Vários sistemas comerciais apareceram recentemente no mercado que tentam medir sinais tipo EEG do couro cabeludo. Estes sistemas normalmente usam um pequeno número de eletrodos secos (em contraste aos eletrodos de EEG tradicionais “molhados” que exigem gel para fazer contato com o couro cabeludo). As medições feitas por estes eletrodos secos são usadas para controlar objetos em uma tela de computador ou objetos reais tal como uma bola. Exemplos incluem sistemas fabricados pela Emotiv (*headset* EPOC) e Neurosky (*headset* Mindwave), e brinquedos como o Mindflex da Mattel.

Estes sistemas novos são muito mais baratos do que sistemas de EEG baseados em gel tradicionais usados na pesquisa e clínicas e eles são mais fáceis de usar e operar. No entanto, um problema deste novo sistema é que não há nenhuma garantia de que estão capturando os verdadeiros sinais de EEG. Em ambientes não controlados, tais sistemas podem capturar uma mistura de atividade EEG e EMG causada por ativação muscular da face e do pescoço, movimentos dos olhos, mudanças na resistência da pele, ou em alguns casos, mesmo ruído elétrico. Por outro lado, como mencionado acima, o uso de um EEG/EMG híbrido ou outro tipo de sinal voluntariamente gerado pode ser bom para aplicações de jogos, se constituir em um novo e potencial modo de entretenimento de controle em um jogo.

5.8.4. Pesquisa desenvolvida no laboratório BioCom da USP

No laboratório de Computação Bio-inspirada (BioCom) da Universidade de São Paulo (USP), campus de São Carlos, existe um grupo de neurodinâmica computacional, no qual se inserem vários projetos relacionados às BCI. Alunos pesquisam temas, que vão desde reconhecimento de faces até BCI de imagética motora, usando os conjuntos-K de Freeman. Outros alunos pesquisam a interpretação de sinais de EEG utilizando diversas técnicas, desde algoritmos tradicionais de aprendizado de máquina até redes complexas,

Figura 5.21. Vários canais de EEG com *spikes* de 3 Hz num sujeito com epilepsia. O EEG mostra atividade anormal a partir da metade do quadro [71].

para prevenção de doenças, como a epilepsia. Este grupo conta com o apoio de pesquisadores da Faculdade de Medicina da USP de Ribeirão Preto, que fornecem bases de dados de EEG de epilepsia. Além dessas, bases de dados disponíveis publicamente, como as das *BCI competitions*⁷, são utilizadas. A seguir, alguns dos trabalhos do grupo de neurodinâmica computacional desenvolvidos no BioCom:

Redes complexas para análise de sinais de epilepsia: Como a epilepsia é uma condição com alta incidência é natural tentar utilizar redes complexas para detectar sinais da epilepsia. Pretende-se converter sinais de EEG (Figura 5.21) em redes complexas e utilizar as medidas de caracterização das redes para detectar crises.

BCI baseadas em sinais eletrofisiológicos para o tratamento de epilepsias: Uma das possíveis aplicações de BCI é voltada ao monitoramento das atividades cerebrais de pacientes com epilepsias, visando a detecção de atividades convulsivas. A forma mais comum para analisar a atividade cerebral é por meio de sinais de EEG. Utilização dos conjuntos-K de Freeman.

Preenchimento automático de laudos médicos por meio do processamento de EEG utilizando aprendizado de máquina: O objetivo desse trabalho é desenvolver um método computacional para o preenchimento automático de laudos médicos de forma padronizada a partir do processamento de exames de EEG utilizando redes neurais artificiais [50].

Aplicações de BCI em robótica: Durante muito tempo apenas o uso de técnicas cirúrgicas foram utilizadas para controle de próteses e braços robóticos. Novos estudos mostram que a EEG pode ser utilizada para esse propósito. Desta forma, propõe-se a investigação de formas de aprendizado que, com as informações obtidas pela EEG, possam permitir o controle de algum dispositivo robótico.

Desenvolvimento de um modelo computacional para apoio ao diagnóstico de transtornos psicóticos: O diagnóstico não envolve apenas decidir o que é verdade sobre um paciente, mas também os dados que são necessários para determinar o que é verdadeiro. O objetivo do projeto é por meio da identificação e exploração de diferenças nas

⁷<http://www.bbc.de/competition/>

características estruturais e funcionais do cérebro desenvolver um modelo computacional capaz de apresentar apoio à decisão de diagnóstico para esquizofrenia, transtorno bipolar e transtorno depressivo.

Conjuntos-K de redes neurais e sua aplicação na classificação de imagética motora: A imagética motora deixa um rastro no sinal da EEG que torna possível a identificação e classificação dos diferentes movimentos motores [52]. Um simulador para os conjuntos-K foi construído em Java e está disponível publicamente [53].

Reconhecimento de faces utilizando um modelo conexionista baseado em populações de neurônios: Reconhecimento de faces consiste em, a partir de uma imagem, identificar ou verificar um ou mais indivíduos através de um banco de dados de faces utilizando os conjuntos-K [9].

5.9. Conclusão

Este curso apresentou os conceitos básicos de Interfaces Cérebro-Computador (BCI), desde a neurociência básica, focando em populações de neurônios, até a plasticidade sináptica. Foram discutidos conceitos relacionados à neurodinâmica, apresentando os conjuntos-K de Freeman, modelo de rede neural biologicamente plausível [59], que se baseia na população de neurônios e não no neurônio individual. Apresentou-se elementos das BCI, como formas de registro de sinais do cérebro, dando ênfase à eletroencefalografia, técnica não-invasiva muito usada em pesquisa com sujeitos normais. Discutiu-se também conceitos de processamento de sinais e de aprendizado de máquina. Por fim, apresentou-se diversas aplicações de BCI, em áreas médicas e não médicas.

Agradecimento

O autor agradece aos revisores anônimos da versão preliminar deste texto, que com seus comentários construtivos, possibilitaram uma versão final muito mais aprimorada. Quaisquer erros remanescentes são de inteira responsabilidade do autor.

Referências

- [1] Bell, C. J., Shenoy, P., Chalodhorn, R., and Rao, R. P. N. (2008) “Control of a humanoid robot by a non-invasive brain-computer interface in humans.” *J Neural Eng.* 5(2):214–20.
- [2] Bensch, M., Karim, A. A., Mellinger, J., Hinterberger, T., Tangermann, M., Bogdan, M., Rosenstiel, W., and Birbaumer, N. (2007) “Nessi: An EEG-Controlled Web Browser for Severely Paralyzed Patients.” *Comput Intell Neurosci.* 2007(Art ID 71863), 5 pp.
- [3] Berger, T. W., Hampson, R. E., Song, D., Goonawardena, A., Marmarelis, V. Z., and Deadwyler, S. A. (2011) “A cortical neural prosthesis for restoring and enhancing memory.” *J. Neural Eng.* 8 046017 (11pp).
- [4] Bernstein, J. (1902) “Untersuchungen zur Thermodynamik der bioelektrischen Ströme”. *J. Pflügers Arch. Ges. Physiol.* 92:521–562.
- [5] Blankertz, B., Tangermann, M., Vidaurre, C., Fazli, S., Sannelli, C., Haufe, S., Maeder, C., Ramsey, L., Sturm, I., Curio, G., and Müller, K.-R. (2010) “The Berlin brain-computer interface: non-medical uses of BCI technology.” *Frontiers on Neurosc.* Dec, 4(Art 198).

- [6] Blakely, T., Miller, K. J., Rao, R. P. N., Holmes, M. D., and Ojemann J. G. (2008) "Localization and classification of phonemes using high spatial resolution electrocorticography (ECoG) grids." *Conf Proc IEEE Eng Med Biol Soc*, 2008:4964–67.
- [7] Blausen gallery 2014. Illustration of a cochlear implant: Blausen.com staff. Wikiversity Journal of Medicine. DOI:10.15347/wjm/2014.010. ISSN 20018762. - Own work
- [8] Brunner P. and Schalk, G. (2009) "Brain-Computer Interaction," In: D. D. Schmorow et al. (Eds.): *Augmented Cognition*, HCII 2009, LNAI 5638:719–723, 2009. Springer-Verlag Berlin Heidelberg.
- [9] Carlos Junior, L. F. M. and Rosa, J. L. G. (2014), "Face Recognition through a Chaotic Neural Network Model," *Proceedings of the IJCNN 2014 Intl Joint Conf on Neural Networks*, IEEE World Cong on Comput Intell (IEEE WCCI), Beijing, China, July 6-11, 2014:859-863.
- [10] Cheung, W., Sarma, D., Scherer, R., and Rao, R. P. N. (2012) "Simultaneous brain-computer interfacing and motor control: expanding the reach of non-invasive BCIs." *Conf Proc IEEE Eng Med Biol Soc*. 2012:6715–8.
- [11] Cole, K. S. and Curtis, H. J. (1939) "Electric Impedance of the Squid Giant Axon during Activity", *Gen. Physiol.* 22:649–670.
- [12] Cooley, J. W. and Tukey, J. W. (1965) "An algorithm for the machine calculation of complex Fourier series." *Math Comput* 19:297–301.
- [13] Farwell, L. A. and Donchin, E. (1991) "The truth will out: interrogative polygraphy ("Lie Detection") with event-related brain potentials", *Psychophys*, 28(5):531–547.
- [14] Fatourech, M., Bashashati, A., Ward, R. K., and Birch, G. E. (2007) "EMG and EOG artifacts in brain computer interface systems: A survey." *Clin Neurophys* 118(3):480–494.
- [15] Nicolas Ferrando, Lois Lammerhuber (credit) (2009) Brain Computer Interface / g-tech medical engineering, <https://www.flickr.com/photos/arselectronica/4306147303>, Taken on May 27, 2009.
- [16] Freeman, W. J. (1975) *Mass action in the nervous system - Examination of the Neurophysiological Basis of Adaptive Behavior through the EEG*, Academic Press, New York San Francisco London.
- [17] Freeman, W. J. (1991) "The physiology of perception," *Scientific American*, 264:78.
- [18] Freeman, W. J. (1999) *How Brains Make Up Their Minds*, Weidenfeld & Nicolson, London.
- [19] Freeman, W. J. (2000) *Mesoscopic Brain Dynamics*, Springer-Verlag London Limited.
- [20] Freeman, W. J. and Erwin, H. (2008) "Freeman K-set," *Scholarpedia* 3(2):3238. http://www.scholarpedia.org/article/Freeman_K-set.
- [21] Freeman, W. J. and Kozma, R. (2011) "Neuropercolation + Neurodynamics: Dynamical Memory Neural Networks in Biological Systems and Computer Embodiments," Tutorial 6, *IEEE IJCNN 2011 - Intl. Joint Conf. on Neural Networks*, San Jose, CA, July 31.

- [22] Freeman, W. J. and Quian-Quiroga, R. (2013) *Imaging Brain Function With EEG - Advanced Temporal and Spatial Analysis of Electroencephalographic Signals*. Springer.
- [23] Freeman, W. J. and Quian-Quiroga, R. (2013) *Imaging Brain Function With EEG - Advanced Temporal and Spatial Analysis of Electroencephalographic Signals*. Springer. Chapter 2 - Frequency Analysis, available from https://www.researchgate.net/279353557_fig1_Figure-1-1-a-A-sinusoidal-signal-in-the-time-upper-plot-and-frequency-bottom-plot.
- [24] Galán, F., Nuttin, M., Lew, E., Ferrez, P. W., Vanacker, G., Philips, J., and Millán, J. del R. (2008) "A brain-actuated wheelchair: Asynchronous and non-invasive Brain-computer interfaces for continuous control of robots." *Clin Neurophys*, 119(9):2159–2169.
- [25] Hugo Gamboa (author) (2005) One second of EEG signal. http://commons.wikimedia.org/wiki/File:Eeg_raw.svg. Dez 2005.
- [26] Gao, S., Wang, Y., Gao, X., and Hong, B. (2014) "Visual and Auditory Brain-Computer Interfaces," *IEEE Trans on Biom Eng*, 61(5):1436–1447.
- [27] Georgopoulos, A. P., Kettner, R. E., and Schwartz, A. B. (1988) "Primate motor cortex and free arm movements to visual targets in three-dimensional space. II. Coding of the direction of movement by a neuronal population." *J of Neurosc* 8(8):2928–37.
- [28] Gerson, A. D., Parra, L. C., and Sajda, P. (2006) "Cortically Coupled Computer Vision for Rapid Image Search," *IEEE Tr. on Neural Systems and Rehab. Eng.*, 14(2):174–179.
- [29] Häuser, M. (2000) "The Hodgkin-Huxley theory of the action potential." *Nature - neuroscience supplement*, 3, November:1165.
- [30] Haykin, S. (2009) *Neural Networks and Learning Machines*. 3rd. Ed. Pearson.
- [31] Hodgkin, A. L. and Huxley, A. F. (1939) "Action potentials recorded from inside a nerve fibre." *Nature* 144:710–11.
- [32] Hodgkin, A. L. and Huxley, A. F. (1952) "A quantitative description of membrane current and its application to conduction and excitation in nerve," *J. Physiol.* 117:500–544.
- [33] Hodgkin, A. L. and Katz, B. (1949) "The effect of sodium ions on the electrical activity of the giant axon of the squid." *J. Physiol. (Lond.)* 108:37–77.
- [34] Hopfield, J. J. (1982) "Neural networks and physical systems with emergent collective computational abilities." *Proc National Academy of Sciences of the USA*, 79(8):2554–2558.
- [35] Kaneko, K. and Tsuda, I. (2001) *Complex Systems: Chaos and Beyond. A Constructive Approach with Applications in Life Sciences*, Springer, Berlin NY.
- [36] Katchalsky, A. K., Rowland, V., and Blumenthal, R. (1974) *Dynamic patterns of brain cell assemblies*, MIT Press.
- [37] Kozma, R. (2007) "Neuropercolation," *Scholarpedia* 2(8):1360. <http://www.scholarpedia.org/article/Neuropercolation>.
- [38] Kozma, R., Aghazarian, H., Huntsberger, T., Tunstel, E., and Freeman, W. J. (2007) "Computational aspects of cognition and consciousness in intelligent devices," *IEEE Comput Intell Mag*, Aug:53–64.

- [39] Kozma, R. and Freeman, W. J. (2001) “Chaotic Resonance - Methods and Applications for Robust Classification of Noisy and Variable Patterns,” *Int. J. Bifurcation & Chaos*, 11(6):1607–1629.
- [40] Kozma, R. and Freeman, W. J. (2003) “Basic Principles of the KIV Model and its application to the Navigation Problem,” *J of Integrative Neurosc*, 2(1):125–146.
- [41] Kozma, R. and Freeman, W. J. (2009) “The KIV Model of Intentional Dynamics and Decision Making,” *Neural Networks*, 22(3):277–285.
- [42] Kozma, R., Rosa, J. L. G., and Piazzentin, D. R. M. (2013), “Cognitive Clustering Algorithm for Efficient Cybersecurity Applications,” *Proc IJCNN 2013 Intl Joint Conf on Neural Networks*, Dallas, TX, Aug 4-9, 2013, 471–478.
- [43] Kuffler, S. W., Nicholls, J. G., and Martin, A. R. (1984) *From Neuron to Brain: A Cellular Approach to the Function of the Nervous System*, 2nd. Edition, Sinauer Associates Inc. Sunderland, MA.
- [44] Lopes da Silva, F. H. and Pijn, J. P. (2003) “EEG and MEG Analysis,” In: M. A. Arbib (Ed.), *The Handbook of Brain Theory and Neural Networks*, 2nd. edition, A Bradford Book. The MIT Press, 387–391.
- [45] Marcel, S. and Millán, J. del R. (2007) “Person authentication using brainwaves (EEG) and maximum a posteriori model adaptation.” *IEEE Trans Pattern Anal Mach Intell.*; 29(4):743–52.
- [46] Matthews, F., Pearlmutter, B. A., Ward, T. E., Soraghan, C., and Markham, C. (2008) “Hemodynamics for Brain-Computer Interfaces,” *IEEE Signal Proc Mag*, 25(1):87–94.
- [47] Mavooria, J., Jackson, A., Diorio, C., and Fetz, E. (2005) “An autonomous implantable computer for neural recording and stimulation in unrestrained primates.” *J of Neurosc Methods* 148:71–77.
- [48] McCulloch, W. S. and Pitts, W. (1943) “A logical calculus of the ideas immanent in nervous activity.” *Bull of Math Biophysics*, 5:115-133.
- [49] Millán, J. del R. (2003) “Brain-Computer Interfaces,” In: M. A. Arbib (Ed.), *The Handbook of Brain Theory and Neural Networks*, 2nd. ed, A Bradford Book. The MIT Press, 178–181.
- [50] Oliva, J. T. and Rosa, J. L. G. (2016), “Predictive Models for Differentiation between Normal and Abnormal EEG through Cross-Correlation and Machine Learning Techniques,” Springer LNCS SOTA (State-of-the-Art) Vol on *Machine Learning for Health Informatics*, 2016.
- [51] Oppenheim, A. V. and Schaffer, R. W. (1975). *Digital Signal Processing*. Prentice Hall.
- [52] Piazzentin, D. R. M. and Rosa, J. L. G. (2014), “Motor imagery classification for Brain-Computer Interfaces through a chaotic neural network,” *Proc IJCNN 2014 Intl Joint Conf on Neural Networks*, IEEE World Cong on Comput Intell (IEEE WCCI), Beijing, China, July 6-11, 2014:4103-4108.
- [53] Piazzentin, D. R. M. and Rosa, J. L. G. (2015), “A simulator for Freeman K-sets in Java,” *Proc IJCNN 2015 Intl Joint Conf on Neural Networks*, Killarney, Ireland, July 12-17, 2015:1–8.

- [54] Postelnicu, C. C., Talabă, D., and Toma, M. I. (2010) “Brain Computer Interfaces for Medical Applications”, *Bull of the Transylvania Univ of Brasov*, vol. 3 (52), Series I: Eng Sciences. 99–106.
- [55] Poulos, M., Rangoussi, M., Chrissicopoulos, V., and Evangelou, A. (1999) “Person identification based on parametric processing on the EEG.” In: *Proc. of the Sixth Intl. Conf. on Electronics, Curcuits and Systems (ICECS99)*, Pafos, Cyprus; 1:283–86.
- [56] Rabinovich, M. I., Huerta, R., Varona, P., and Afraimovich, V. S. (2008) “Transient cognitive dynamics, metastability, and decision making,” *PLoS comput biology*, vol. 4(5), e1000072.
- [57] Rao, R. P. N. (2013) *Brain-Computer Interfacing - An Introduction*, Cambridge Univ Press.
- [58] Rosa, J. L. G. (2011) *Fundamentos da Inteligência Artificial*, Editora LTC.
- [59] Rosa, J. L. G. (2013), “Biologically Plausible Artificial Neural Networks” (chapter 2) in Kenji Suzuki (ed.), *Artificial Neural Networks - Architectures and Applications*, ISBN 978-953-51-0935-8, Pub: InTech.
- [60] Rosa, J. L. G. and Piazzentin, D. R. M. (2016), “A New Cognitive Filtering Approach based on Freeman K3 Neural Network,” *Applied Intelligence* 2016, Springer. DOI 10.1007/s10489-016-0772-4. 20 pages. First online: 09 March 2016 <http://link.springer.com/article/10.1007%2Fs10489-016-0772-4>.
- [61] Saa, A. (2004) “O Modelo de Hodgkin-Huxley”. vigo.ime.unicamp.br/~fisimat/2004-I-NC-aula7.pdf.
- [62] Sajda, P., Pohlmeier, E., Wang, J., Parra, L. C., Christoforou, C., Dmochowski, J., Hanna, B., Bahlmann, C., Singh, M. K., and Chang, S.-F. (2010) “In a Blink of an Eye and a Switch of a Transistor: Cortically Coupled Computer Vision.” *Proc of the IEEE*, 98(3): 462–478.
- [63] Scherer, R., Lee, F., Schlögl, A., Leeb, R., Bischof, H., and Pfurtscheller, G. (2008) “Towards self-paced brain-computer communication: Navigation through virtual worlds.” *IEEE Trans Biomed Eng*, 55(2):675–82.
- [64] Stam, C. J., Breakspear, M., van Cappellen van Walsum, A. M., and van Dijk, B. W. (2003) “Nonlinear synchronization in EEG and whole-head recordings of healthy subjects,” *Hum Brain Mapp*, 19:63–78.
- [65] Szafir, D. and Mutlu, B. (2012) “Pay attention! Designing adaptive agents that monitor and improve user engagement.” In: *Proc. ACM SIGCHI Conf. on Human Factors in Comp. Systems* (CHI 2012). 11–20.
- [66] Vidal, J. J. (1973) “Toward direct brain-computer communication,” *Annu. Rev. Biophys. Bioeng.*, 2:157–180.
- [67] Vidal, J. J. (1977) “Real-time detection of brain events in EEG,” *Proc. IEEE*, 65:633–664.
- [68] By Original by en:User:Chris 73, updated by en:User:Diberri, converted to SVG by tiZom [CC BY-SA 3.0 (<http://creativecommons.org/licenses/by-sa/3.0>)], via Wikimedia Commons. https://commons.wikimedia.org/wiki/File%3AAction_potential_basic_shape.svg.

- [69] By Richard A. Normann (US Patent #5,215,088) [Public domain], via Wikimedia Commons. https://commons.wikimedia.org/wiki/File:Utah_array_pat5215088.jpg
- [70] By Mononomic (talk) 16:12, 21 December 2008 (UTC) (en::File:Constudevent.gif) [GFDL (<http://www.gnu.org/copyleft/fdl.html>) or CC-BY-SA-3.0 (<http://creativecommons.org/licenses/by-sa/3.0/>)], via Wikimedia Commons. <https://commons.wikimedia.org/wiki/File%3AComponentsofERP.svg>.
- [71] Uploaded from the German Wikipedia, uploaded into the German Wikipedia by Der Lange 11/6/2005, created by himself. <http://commons.wikimedia.org/w/index.php?title=File:Spike-waves.png&action=edit§ion=2>.
- [72] By Daren Reehl (<http://www.army.mil/-images/2007/01/07/1718/>) [Public domain or Public domain], via Wikimedia Commons. https://commons.wikimedia.org/wiki/File%3AUS_Army_powered_armor.jpg.
- [73] By Unknown NIMH author [Public domain], via Wikimedia Commons. https://commons.wikimedia.org/wiki/File%3ANIMH_MEG.jpg.
- [74] By Jens Maus (<http://jens-maus.de/>) (Own work) [Public domain], via Wikimedia Commons. <https://commons.wikimedia.org/wiki/File%3APET-image.jpg>.
- [75] By OpenStax College [CC BY 3.0 (<http://creativecommons.org/licenses/by/3.0/>)], via Wikimedia Commons. https://commons.wikimedia.org/wiki/File%3A1206_FMRI.jpg.
- [76] Nissan and EPFL to Push Development For Thought Controlled Vehicles. <https://thinktechuk.wordpress.com/category/bci-wheelchairs/>.
- [77] Author: User:XaosBits at English Wikipedia (2006) Description: Van de Pol phase portrait. Created with Mathematica and touched up with Illustrator. Permission: (Reusing this file) This image is licensed under the Creative Commons Attribution License v. 2.5.
- [78] Author: Zawersh at English Wikipedia (2006) Description: A Hopfield net with four nodes. Permission is granted to copy, distribute and/or modify this document under the terms of the GNU Free Documentation License, Version 1.2.