



**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO**

THIAGO BULHÕES DA SILVA COSTA

**DESENVOLVIMENTO DE INTERFACE CÉREBRO-COMPUTADOR BASEADA
EM POTENCIAIS EVOCADOS VISUALMENTE EM REGIME ESTACIONÁRIO**

**CAMPINAS
2015**



THIAGO BULHÕES DA SILVA COSTA

**DESENVOLVIMENTO DE INTERFACE CÉREBRO-COMPUTADOR BASEADA
EM POTENCIAIS EVOCADOS VISUALMENTE EM REGIME ESTACIONÁRIO**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas para obtenção do título de Mestre em Engenharia Elétrica, na área de Engenharia de Computação.

Orientador: Prof. Dr. Romis Ribeiro de Faissol Attux

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO
DEFENDIDA PELO ALUNO THIAGO BULHÕES DA SILVA COSTA
E ORIENTADO PELO PROF. DR. ROMIS RIBEIRO DE FAISSOL ATTUX

**CAMPINAS
2015**

Agência(s) de fomento e nº(s) de processo(s): CAPES

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Elizangela Aparecida dos Santos Souza - CRB 8/8098

C823d Costa, Thiago Bulhões da Silva, 1984-
Desenvolvimento de interface cérebro-computador baseada em potenciais evocados visualmente em regime estacionário / Thiago Bulhões da Silva Costa. – Campinas, SP : [s.n.], 2015.

Orientador: Romis Ribeiro de Faissol Attux.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Interface cérebro-computador. 2. Potenciais evocados. 3. Eletroencefalografia. 4. Aprendizagem de máquina. 5. Reconhecimento de padrões. I. Attux, Romis Ribeiro de Faissol, 1978-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Development of brain-computer interface based on steady-state visually evoked potentials

Palavras-chave em inglês:

Brain-computer interface

Evoked potentials

Electroencephalography

Machine learning

Pattern recognition

Área de concentração: Engenharia de Computação

Titulação: Mestre em Engenharia Elétrica

Banca examinadora:

Romis Ribeiro de Faissol Attux [Orientador]

Gabriela Castellano

Ricardo Suyama

Data de defesa: 30-10-2015

Programa de Pós-Graduação: Engenharia Elétrica

COMISSÃO JULGADORA – DISSERTAÇÃO DE MESTRADO

Candidato: Thiago Bulhões da Silva Costa RA: 064699

Data da Defesa: 30/10/2015

Título da Dissertação: “Desenvolvimento de Interface Cérebro-Computador Baseada em Potenciais Evocados Visualmente em Regime Estacionário”.

Prof. Dr. Romis Ribeiro de Faissol Attux (Presidente, FEEC/UNICAMP)

Profa. Dra. Gabriela Castellano (IFGW/UNICAMP)

Prof. Dr. Ricardo Suyama (CECS/UFABC)

A ata de defesa, com as respectivas assinaturas dos membros da Comissão Julgadora, encontra-se no processo de vida acadêmico do aluno.

A meu pai, Élvio, dedico este estudo.

Agradecimentos

Segue uma lista (em ordem alfabética) com as pessoas que direta ou indiretamente contribuíram com a presente dissertação. Achei difícil pormenorizar como cada uma delas participou desse processo, mas considere importante elencá-las ainda assim. Em alguns casos, como os nomes seriam muitos, preferi agrupá-los sob um mesmo epíteto.

Alfredo Almodovar

Amigos do DSPCom

Amílcar José da Veiga D'Angelis (*in memoriam*)

Anaí Arias

Angela Luna Hernandez

Camilo Kolomi

Cláudia Bulhões da Silva Costa

Colegas da ETECAP

Colegas da Unicamp

Denis Gustavo Fantinato

Diego de Oliveira

Diogo Coutinho Soriano

Diogo dos Santos

Eduardo Vasconcelos

Eleri Cardozo

Élvio da Silva Costa (*in memoriam*)

Eric Rohmer

Família

Fernanda Piccolo

Filipe Ieda Fazanaro

Gabriela Castellano

Galera do Samba e do Futebol

Gilberto Machel

Giovane de Oliveira

Guilherme Paschoal Lima

Harlei Miguel de Arruda Leite

Henrique Fubá Araujo
Iolanda Corazza da Rosa
João Lemes da Rosa
João Marcos Travassos Romano
Juliana Santos
Juracilda Veiga
Leandro Mattos
Leila Pruencio
Levy Boccato
Lilian da Rosa (especialmente)
Luisa Fernanda Suarez Uribe
Maria Cláudia Bulhões da Silva Costa
Murilo Bellezoni Loiola
Nadia Reciola
Rafael Ferrari
Rafael Silveira Porto
Raphael Antunes de Andrade
Renato da Rocha Lopes
Ricardo da Silva Souza
Ricardo Suyama
Romis Attux
Sara Regina Meira Almeida
Sarah Negreiros de Carvalho
Thais Fogliarini
Tiago Corazza da Rosa
Vinícius Andrade
Wilmar D'Angelis

Se, por desventura, eu tenha esquecido algum nome, peço desculpas pelo aparente descaso. Na verdade, a seção “Agradecimentos” foi elaborada às pressas, uma vez que o prazo de entrega do documento final estava acabando.

Também agradeço a Capes, o CNPq, a Finep e a FAPESP, por concederem o financiamento para o desenvolvimento desta pesquisa, e a Unicamp, por conceder a infraestrutura.

*As coisas na natureza
Evoluem ao sentido
Que certo tempo implacável
Determina com critério*

*Uma folha nasce, cresce e se torna
Vítima do vento, lamento ao chão*

*Um esquisito mistério
De outro tempo retornável
Leva ao contrário sentido
Das coisas na natureza*

*O folhame, do vão destino infame
Decresce ao broto que de jovem nasce*

*Porém se a vida, tão simples poesia
(En)quanto escrita fosse tanto (des) dita
O tempo não mais poderia ser*

RESUMO

O presente estudo aborda o desenvolvimento e a sistematização de uma interface cérebro-computador, baseada em potenciais evocados visualmente em regime estacionário, para funcionar acoplada à execução de tarefas. Esse sistema de comunicação, com o uso de sinais provenientes de eletroencefalografia, foi criado para vir a integrar uma versão preliminar de um controlador compartilhado destinado à navegação de uma cadeira de rodas. Em princípio, quando um indivíduo foca o olhar em estímulos visuais periódicos, certos potenciais evocados podem ser detectados entre a atividade natural do cérebro, especialmente na região occipital. Se identificados de forma suficientemente precisa, então, esses potenciais poderiam ser associados aos comandos de acionamento da referida cadeira. Para atingir esse propósito, a interface foi estruturada em cinco módulos: o de estimulação, responsável por gerar e exibir os estímulos visuais repetitivos; o de aquisição, dedicado à captura e ao armazenamento dos dados eletroencefalográficos; o de processamento, que realiza a remoção de artefatos, a extração de características e a formatação das mesmas; o de treinamento, que executa a seleção de atributos e que calcula as projeções de um classificador linear para identificar as manifestações cerebrais relacionados aos estímulos; e, por fim, o de comunicação e controle, que (com o uso do mencionado classificador) detecta os potenciais evocados e, a partir disso, gera e envia um sinal de controle para a aplicação. Além desses módulos, entre estes também foi proposto um protocolo de operação, dividido em etapa de treinamento e etapa de identificação em tempo de execução. Ao longo do desenvolvimento da interface cérebro-computador, o funcionamento dos módulos foi validado com sinais adquiridos de dez voluntários saudáveis e uma versão funcional desse sistema foi testada com três deles, como forma de verificar a factibilidade de integração da interface com o controlador da cadeira de rodas.

Palavras-chave: Interface Cérebro-Computador, Potenciais Evocados, Eletroencefalografia, Aprendizagem de Máquina, Reconhecimento de Padrões.

ABSTRACT

This study addresses the development and systematization of a brain-computer interface, based on steady-state visually evoked potentials, to operate in the context of the enforcement of certain tasks. This communication system, which uses electroencephalographic records, has been created to become part of a preliminary version of a shared controller destined to run an assistive wheelchair. At first, when a person focuses his/her gaze on repetitive visual stimuli, certain evoked potentials can be detected among the natural brain activity, particularly on the occipital region. If they are identified with sufficient precision, then these potentials could be associated with the drive commands of the aforementioned wheelchair. To achieve this purpose, the interface has been structured into five modules: stimulation, responsible for generating and displaying the stimuli; acquisition, dedicated to capturing and storing the electroencephalographic data; processing, which accomplishes artifact removal, the extraction of characteristics and the formatting thereof; training, which performs the feature selection and estimates the projections of a linear classifier in order to identify the brain activities related to the stimuli; and, lastly, communication and control, which (using the previous classifier) detects the evoked potentials and, from there, generates and sends a control signal to the application. In addition to these modules, between them, an operating protocol has also been proposed, divided into training and online identification stages. Along with the brain-computer interface development, the operation of the modules has been validated with acquired signals of ten health volunteers and a functional version of this system has been tested with three of them, in order to verify the feasibility of integrating the interface with the wheelchair controller.

Keywords: *Brain-Computer Interface, Evoked Potentials, Electroencephalography, Machine Learning, Pattern Recognition.*

Lista de Ilustrações

Figura 1.1: Esquemático de uma BCI genérica.....	41
Figura 1.2: Exemplos de SSVEPs em 10, 12 e 15 Hz. Os espectros foram extraídos de sinais (registrados em Oz) coletados com um voluntário saudável. A taxa de amostragem foi 256 Hz e as sessões duraram 12 segundos para cada estímulo.	47
Figura 2.1: Exemplo de interface montada com quatro LEDs para estimulação de SSVEPs.	65
Figura 2.2: Exemplos de estampas para composição de estímulos padronizados.	65
Figura 3.1: Instantâneo da tela de exibição do RVS em formato de figura simples, com as proporções (embora menores) mantidas. O estímulo da esquerda piscava em 12 Hz e o da direita em 15 Hz. Propositadamente, a imagem mostra as estampas contrárias.	102
Figura 3.2: Instantâneo da tela de exibição do RVS em formato de padrão reverso 1, com as mesmas convenções da Figura 3.1.	103
Figura 3.3: Instantâneo da tela de exibição do RVS em formato de padrão reverso 2, com as mesmas convenções da Figura 3.1.	103
Figura 3.4: Montagem dos eletrodos para aquisição de SSVEPs.	106
Figura 3.5: Para janelas de 3 segundos de dados registrados no eletrodo Oz, os gráficos comparam os sinais no tempo (parte superior) e os espectros (parte inferior), antes (à esquerda) e depois (à direita) da filtragem espacial CAR, nas situações em que um voluntário fixava a visão em figuras simples de 12 Hz e de 15 Hz e quando o mesmo repousava.....	119
Figura 3.6: Os gráficos comparam os sinais no tempo e os espectros nas situações em que um voluntário fixava a visão em padrões reversos 1 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são as mesmas da Figura 3.5.....	120
Figura 3.7: Os gráficos comparam os sinais no tempo e os espectros nas situações em que um voluntário fixava a visão em padrões reversos 2 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são as mesmas da Figura 3.5.....	121
Figura 3.8: Para dados registrados no eletrodo Oz, antes (à esquerda) e depois (à direita) da filtragem espacial CAR, os gráficos comparam os espectros resultantes de janelas com ½, 1, 2 e 3 segundos (de cima para baixo, respectivamente), para as situações em que um voluntário fixava a visão em figuras simples de 12 Hz e de 15 Hz e quando o mesmo repousava.....	122
Figura 3.9: Os gráficos comparam os espectros resultantes de janelas com ½, 1, 2 e 3 segundos, para as situações em que um voluntário fixava a visão em padrões reverso 1 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são idênticas as	

da Figura 3.8.	123
Figura 3.10: Os gráficos comparam os espectros resultantes de janelas com $\frac{1}{2}$, 1, 2 e 3 segundos, para as situações em que um voluntário fixava a visão em padrões reverso 2 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são idênticas as da Figura 3.8.	124
Figura 3.11: Para várias extrações em janelas de 3 segundos de dados registrados no eletrodo Oz, os gráficos comparam os espaços de atributos referentes ao conteúdo espectral do 1.º (parte superior) e do 2.º (parte inferior) harmônicos, antes (à esquerda) e depois (à direita) da filtragem espacial CAR, nas situações em que um voluntário fixava a visão em figuras simples de 12 Hz e de 15 Hz e quando o mesmo repousava.	125
Figura 3.12: Os gráficos comparam os espaços de atributos referentes aos conteúdos espectrais do 1.º e do 2.º harmônicos nas situações em que um voluntário fixava a visão em padrões reversos 1 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são idênticas as da Figura 3.11.	126
Figura 3.13: Os gráficos comparam os espaços de atributos referentes aos conteúdos espectrais do 1.º e do 2.º harmônicos nas situações em que um voluntário fixava a visão em padrões reversos 2 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são idênticas as da Figura 3.11.	126
Figura 3.14: Para atributos extraídos dos dois primeiros harmônicos (pontos vermelhos) e da frequência principal apenas (pontos azuis), os gráficos comparam, para um usuário sadio, as evoluções do desempenho de classificação (LSM) conforme se acrescenta os eletrodos ordenados de acordo com o coeficiente de Pearson. O estímulo em questão foi a figura simples.	132
Figura 3.15: Para atributos extraídos dos dois primeiros harmônicos (pontos vermelhos) e da frequência principal apenas (pontos azuis), os gráficos comparam, para um usuário sadio, as evoluções do desempenho de classificação (LSM) conforme se acrescenta os eletrodos ordenados de acordo com o coeficiente de Pearson. O estímulo em questão foi o padrão reverso 1.	133
Figura 3.16: Para atributos extraídos dos dois primeiros harmônicos (pontos vermelhos) e da frequência principal apenas (pontos azuis), os gráficos comparam, para um usuário sadio, as evoluções do desempenho de classificação (LSM) conforme se acrescenta os eletrodos ordenados de acordo com o coeficiente de Pearson. O estímulo em questão foi o padrão reverso 2.	134

Lista de Tabelas

Tabela 3.1: Algoritmo da função de exibição dos RVSS.	101
Tabela 3.2: Algoritmo da função de subdivisão dos dados.	113
Tabela 3.3: Algoritmo da função CAR.	114
Tabela 3.4: Algoritmo da função TWAR.	115
Tabela 3.5: Algoritmo da função de extração por FFT.	116
Tabela 3.6: Algoritmo da função de extração por periodograma de Welch.	116
Tabela 3.7: Algoritmo da função para organização dos atributos.	117
Tabela 3.8: Algoritmo da função do índice de relevância por Pearson.	128
Tabela 3.9: Algoritmo da função do índice de relevância por Fisher.	129
Tabela 3.10: Algoritmo da função de cálculo dos coeficientes do LSM.	129
Tabela 3.11: Algoritmo da função de cálculo dos coeficientes do FLD.	130
Tabela 3.12: Algoritmo da função de classificação por LSM.	130
Tabela 3.13: Algoritmo da função de classificação por FLD.	131
Tabela 3.14: Algoritmo da função de tomada de decisão.	131
Tabela 3.15: Desempenho de classificação do par Pearson-LSM.	139
Tabela 3.16: Desempenho de classificação do par Fisher-FLD.	140
Tabela 3.17: Desempenho de classificação para 4 estados.	141

SUMÁRIO

INTRODUÇÃO.....	16
1 INTERFACES CÉREBRO-COMPUTADOR	27
1.1 TECNOLOGIAS ASSISTIVAS	31
1.2 TIPOS DE INTERFACES CÉREBRO-COMPUTADOR	36
1.2.1 SMR-BCI ou Imagística Motora	41
1.2.2 P300-BCI.....	43
1.2.3 SSVEP-BCI	45
1.2.4 Desempenho e Comparação de BCIs	48
1.3 DESENVOLVIMENTO DE BCIs.....	51
1.3.1 BCI2000 e OpenViBE.....	53
1.3.2 MATLAB e BioSig	55
1.3.3 SSVEP-BCI em MATLAB.....	57
2 ESTIMULAÇÃO, AQUISIÇÃO E PROCESSAMENTO DE SSVEPs	61
2.1 GERAÇÃO DE SSVEPs	62
2.1.1 Estímulos Luminosos, Figuras Simples e Padrões Reversos	64
2.2 REGISTRO DE SINAIS ENCEFÁLICOS	67
2.2.1 Eletroencefalografia	68
2.3 REMOÇÃO DE ARTEFATOS	72
2.3.1 Filtragem Temporal	73
2.3.2 Filtragem Espacial (CAR e TWAR)	75
2.4 EXTRAÇÃO DE CARACTERÍSTICAS.....	76
2.4.1 Transformada Rápida de Fourier e Periodograma de Welch	79
2.5 ESTRATÉGIAS DE CLASSIFICAÇÃO.....	82
2.5.1 Classificadores Lineares	83
2.5.1.1 Método dos Mínimos Quadrados.....	86
2.5.1.2 Discriminante Linear de Fisher	87
2.6 SELEÇÃO DE ATRIBUTOS.....	91
2.6.1 Filtros de Seleção.....	92
2.7 VALIDAÇÃO E DESEMPENHO	94
2.7.1 Métodos de Validação.....	94
3 DESENVOLVIMENTO DE SSVEP-BCI	98

3.1 ESTIMULAÇÃO.	99
3.1.1 Módulo de Estimulação.....	100
3.1.2 Funcionamento do Módulo de Estimulação	102
3.2 AQUISIÇÃO	104
3.2.1 Módulo de Aquisição: Estrutura e Funcionamento	107
3.3 PROCESSAMENTO.....	112
3.3.1 Módulo de Processamento	113
3.3.2 Funcionamento do Módulo de Processamento.....	118
3.4 TREINAMENTO	127
3.4.1 Módulo de Treinamento	127
3.4.2 Funcionamento do Módulo de Treinamento	132
3.5 COMUNICAÇÃO E CONTROLE	135
3.5.1 Módulo de Comunicação e Controle: Estrutura e Funcionamento	136
3.6 INTEGRAÇÃO DO SISTEMA.....	136
3.6.1 Integração dos Módulos e Funcionamento do Sistema	137
3.7 AVALIAÇÃO DO SISTEMA.....	138
CONCLUSÕES E PERSPECTIVAS	143
REFERÊNCIAS	145
ANEXO – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO	156

INTRODUÇÃO

A natureza elétrica da atividade cerebral de alguns animais vivos foi elucidada primeiramente por Richard Caton, em 1875.¹ Em sua publicação, ele reportou as fracas alterações de corrente, supostamente oriundas do cérebro, registradas por meio de duas configurações experimentais distintas: a fixação de dois eletrodos unipolares na superfície externa do córtex (substância cinzenta); ou a colocação de um eletrodo no interior do mesmo e de outro acima do crânio. As medidas foram realizadas através da ampliação ótica do menisco de um galvanômetro de Thompson. Com o uso deste dispositivo e dos arranjos de eletrodos propostos, Caton, ao longo de sua carreira, identificou o aumento dessa corrente durante o sono e certas modificações na sua linha de base não relacionadas aos ritmos cardíaco ou respiratório e, além disso, observou o enfraquecimento desse sinal diante da exposição à anóxia e anestesia, bem como o seu completo desaparecimento alguns instantes após a morte. Ele também descobriu intensas variações dessa corrente cerebral, provocadas a partir de incitação visual com luz brilhante, e mudanças de potencial evocadas por estimulação sensorial. Apesar de todas essas contribuições notáveis, Richard Caton, logo depois de falecer em 1926, foi enaltecido mais pelo seu título de *Lord Mayor* de Liverpool, adquirido em 1907, do que por seus estudos eletrofisiológicos, que atraíram pouco a atenção da comunidade científica britânica da época. O periódico *The Lancet*, em seu obituário, não mencionou as descobertas de Caton para a eletrofisiologia e o BMJ – do inglês *British Medical Journal* – comentou que ele só contribuiu de forma original, no início da década de setenta, para a localização dos movimentos no cérebro² – do original *localization of movements in the cerebrum*.³

O pioneirismo de seu trabalho foi reconhecido somente alguns anos depois, quando Hans Berger, em 1929, publicou uma nova técnica para a gravação de sinais elétricos do cérebro humano, a Eletroencefalografia (EEG) – termo cunhado pelo próprio pesquisador.⁴ Embora esta já fosse utilizada desde 1924, foi apenas em 1929 que ele divulgou o primeiro de uma série de 23 artigos sobre o seu uso e, nele, mencionou as valiosas contribuições de Richard Caton para o seu desenvolvimento. Berger, em seus estudos iniciais, logo após se tornar Professor de Neurologia e Psiquiatria da Universidade de Jena, Alemanha, em 1919, esforçou-se em descobrir as bases neurofisiológicas do fenômeno psíquico. Porém, desapontado com as recorrentes tentativas frustrantes, voltou o seu interesse para a investigação da atividade elétrico-encefálica. A partir disso, ao longo de suas publicações, ele caracterizou os padrões de onda alfa e beta e, também, descreveu alterações no registro eletroencefalográfico associadas

ao esforço mental, a algumas doenças neurológicas e à exposição a intensidades luminosas diversificadas. Inclusive, as oscilações de potencial em torno de 10 Hz – observadas no córtex visual (ritmo alfa-occipital), suscitadas quando um indivíduo permanecia parado e de olhos fechados, e suprimidas quando o mesmo ocupava totalmente sua atenção com alguma tarefa – foram, de início, denominadas por Ritmo de Berger, em sua homenagem.⁵ Entretanto, como Richard Caton, Hans Berger, durante a sua carreira, não foi reconhecido em seu próprio país por seus feitos na área de eletrofisiologia do sistema nervoso, em parte devido a sua oposição ao regime Nazista e em parte devido à incredulidade e ao ceticismo com que as instituições médicas e científicas alemãs desse período receberam o seu trabalho. Depois de sua aposentadoria, em 1938, ele se tornou um homem cada vez mais depressivo e se suicidou em 1941.⁶

De certa forma, esses dois cientistas, com os arcabouços de suas pesquisas, estabeleceram uma nova perspectiva metodológica para os diversos estudos neurocientíficos vindouros. Em 1932, Herbert Jasper leu as publicações de Hans Berger, ficou entusiasmado com as descobertas do mesmo, e assim decidiu reproduzi-las em seu laboratório, no Hospital Bradley, adjacente ao campus da Universidade Brown, em Rhode Island. Com a ajuda de Howard Andrews, quem construiu o aparelho de EEG para as pesquisas, e de Leonard Carmichael, um de seus colegas de trabalho, Jasper confirmou vários dos achados de Berger e, em 1935, foi coautor, em conjunto com o Carmichael, do primeiro artigo norte-americano sobre eletroencefalografia.⁷ Durante os anos de 1930, Jasper não ignorou a turbulência política e fez considerações a respeito da perseguição dos Nazistas a Hans Berger e do seu ulterior suicídio.⁸ Já na década seguinte, em 1947, no 1.º Congresso Internacional de EEG em Londres, foi discutida a necessidade de uma padronização para o posicionamento dos eletrodos no escalpo, pois isso permitiria, de forma satisfatória, a divulgação de resultados na literatura e, por conseguinte, facilitaria a comparação de registros obtidos em diferentes laboratórios. Devido ao seu prestígio, Herbert Jasper foi o escolhido para realizar essa tarefa. Em 1949, no 2.º Congresso, em Paris, ele então propôs, de acordo com seus estudos, sua famosa recomendação intitulada sistema de eletrodos 10-20 da Federação Internacional, cujos detalhes foram posteriormente publicados no relatório da Comissão dos Métodos de Exame Clínico em Eletroencefalografia, em 1958.⁹

Com a criação e a gradual sistematização da técnica de EEG, entre uma vasta porção de estudos eletrofisiológicos do cérebro, não demorou a surgirem trabalhos que relatassem modificações de potencial no córtex visual em resposta à estimulação com fontes de luz. Em 1934, um pouco antes das primeiras publicações de Herbert Jasper sobre eletroencefalografia, Edgar Adrian e Brian Matthews, também inspirados pelo legado de Hans Berger, já

havia descrito a existência de ondas rítmicas, induzidas por estímulos luminosos repetitivos, distintas da até então conhecida manifestação em torno de 10 Hz (Ritmo de Berger). Eles haviam notado que as frequências de incitação e de evocação eram iguais e que esses potenciais occipitais eram observados mais facilmente, devido à proeminência de suas amplitudes, quando gerados na faixa de 10 a 20 Hz.¹⁰ Na sequência, vários pesquisadores então começaram a estudar as respostas elétricas do córtex visual na situação em que os olhos eram expostos tanto à luz estroboscópica quanto a clarões repentinos e individualizados. A partir disso, eles rapidamente notaram que, como reação à primeira forma de iluminação, ocorriam ondulações similares às obtidas por Adrian e Matthews e que, como reação à segunda, irrompia uma sucessão de picos positivos e negativos com latências mínimas de 100 milissegundos.¹¹ Eles também logo perceberam que a detecção desses potenciais evocados estava sujeita ao efeito de mascaramento provocado pelo ruído de EEG e pela atividade cerebral intrínseca. Diante desse efeito, a primeira solução para minimizá-lo foi sugerida, em 1954, por George Dawson. A sua técnica envolvia a superposição de um grande número de registros e possibilitava assim salientar deflexões, mesmo que diminutas, de relativa constância temporal.¹² Contudo, foi apenas em 1966, com o artigo de David Regan, que apareceu uma proposta evidente para a diferenciação (do que ele identificou como ser) das respostas transitória-inicial e estacionária-média causadas por estimulação visual.¹³ Regan desenvolveu um experimento em que cinco voluntários foram submetidos a estímulos luminosos de variadas frequências, moduladas com funções senoidais precisas, e ele caracterizou e formalizou, com esse arranjo, a existência desses dois tipos de potenciais evocados visualmente.¹⁴

Na década de sessenta, outro fenômeno eletroencefalográfico despertou o interesse de cientistas. No ano de 1965, alguns trabalhos, dentre os quais se destaca o artigo de Samuel Sutton, Margery Braren e Joseph Zubin, reportaram a presença de um componente positivo tardio – do original, *late positive component* – entre uma série de potenciais evocados por estímulos sonoros ou visuais. De acordo com tais autores, durante a percepção de uma estimulação previamente indicada, essa forma de onda, embora despertada sensorialmente, mostrava diferenças em seu aspecto como função do grau de incerteza e como função da antecipação correta do indivíduo e, em condições ideais, alcançava um pico de amplitude em aproximadamente 300 milissegundos. Por essas constatações, Sutton, Braren e Zubin supuseram que essa deflexão positiva estava relacionada mais com as reações psicológicas do voluntário do que com as características físicas da incitação e, por isso, propuseram que o referido potencial evocado deveria ser classificado como endógeno.¹⁵ Nos cinco anos subsequentes, por consequência desses achados iniciais, as propriedades essenciais dessa ondulação foram reporta-

das:¹⁶ em 1967, Samuel Sutton e Joseph Zubin, nessa ocasião em coautoria com a Patricia Tueting, confirmaram essa hipótese da endogenia através de um experimento que revelou, na circunstância em que a estimulação também era omitida, a aparição do componente positivo tardio nos casos em que essa omissão permanecia informativa;¹⁷ no mesmo ano, Emanuel Donchin e L. Cohen verificaram que a manifestação dele estava associada à atenção seletiva, ou seja, com a capacidade de se concentrar em uma tarefa individual;¹⁸ em 1968, Walter Ritter, Herbert Vaughan, e Louis Costa denominaram-no P3 porque ele era a terceira onda positiva da sequência de potenciais irrompidos;¹⁹ em 1969, para auxiliar a sua evocação, os mencionados Ritter e Vaughan usaram, pela primeira vez, o paradigma atualmente conhecido como *Oddball* – a detecção de estímulos específicos interpostos aleatoriamente em meio a outras estimulações que aparecem mais vezes;²⁰ em 1970, os mesmos pesquisadores descreveram, de forma preliminar, como o P3 se distribuía pelos córtices parietal e central;²¹ e, por fim, ainda nesse ano, D. Smith, Emanuel Donchin, L. Cohen e A. Starr designaram-no P300 (sua nomeação mais popular hoje em dia) para enfatizar a sua positividade e a sua latência.²²

Nas décadas posteriores às publicações seminais de Richard Caton e de Hans Berger, além das investigações acerca dos potenciais evocados, o estudo de ritmos cerebrais se tornou igualmente convencional. Em 1943, F. Golla, E. Hutton e William Grey Walter estabeleceram três categorias para o ritmo alfa-occipital – M (mínimo), R (responsivo) e P (persistente) – com base na observação do registro eletroencefalográfico de 60 indivíduos enquanto duas tarefas simultâneas por estes eram efetuadas: a imagística mental e a permanência dos olhos abertos (ou fechados).²³ Esse artigo influenciou explicitamente os trabalhos de outros acadêmicos, como o de Philip Short de 1953. Este cientista, por sua vez, adotou a sugerida classificação para avaliar o comportamento do ritmo alfa durante a fixação do pensamento em expressões verbais relacionadas com ações motoras (“caminhar”, por exemplo) – denominada imagística verbal-motora, do original *verbal-motor imagery*.²⁴ Em contrapartida, essa taxionomia M-R-P também foi considerada altamente controversa e, por conta disso, foi motivo de grande debate nesse período.²⁵ Curiosamente, embora esses pesquisadores fossem os primeiros a correlacionar tais processos cognitivos com certos ritmos eletro-encefálicos, já existiam trabalhos, anteriores à invenção de Hans Berger, que reportavam a importância da imagística mental como ferramenta para estudos de psicologia e de comportamento: um dos primeiros,²⁶ de Charles Fox, data de 1914!

Por outro lado, mas em paralelo a essa vertente de estudos, Herbert Jasper e Wilder Penfield, em 1949, registraram – nesse caso com o uso de eletrocorticografia – determinadas manifestações elétricas em concomitância com a execução de deslocamentos e toques dos

dedos de uma mesma mão. Eles verificaram a presença do ritmo alfa em regiões sensório-motoras (portanto, comprovaram sua aparição para além do córtex visual) e, além disso, perceberam, no giro pré-central, o bloqueio do ritmo beta (interpretado como uma espécie de dessincronização reguladora de potenciais) ligeiramente antes do início de movimentos voluntários como o descrito há pouco.²⁷ Nota-se que, por esse tempo, os cientistas ainda não separavam com muita clareza os vários tipos de ondas cerebrais até então encontrados e, independentemente da sua localização cortical, estes eram comumente diferenciados apenas por suas faixas de frequência – alfa, de 8 a 12 Hz, e beta, de 18 a 30 Hz.²⁸ Como que em resposta a isso, Henri Gastaut, em 1952, diferenciou com nitidez o ritmo alfa-central (μ) – ou Rolândico, em referência à área de Rolando na qual foi observado – do clássico alfa-occipital.²⁹ Com o tempo, foram constatadas evidências de que o primeiro ritmo passava por atenuação, ou total supressão, durante a realização de movimentos coordenados, de que era bem pouco influenciado por estimulação visual e de que, por tais indícios, devia ser distinguido espacialmente e funcionalmente do segundo.³⁰

Esses e muitos outros estudos correlatos, embora mais preocupados com as naturezas fisiológica e psicológica de tais fenômenos elétrico-neurais, também promoveram as circunstâncias ideais ao advento das Interfaces Cérebro-Computador (BCIs, do inglês *Brain-Computer Interfaces*) baseadas nos ritmos e potenciais eletroencefalográficos descobertos até aquele momento. Nesse sentido, foi Jacques Vidal, em 1973, que, com sua célebre publicação, primeiro tentou avaliar a factibilidade e a praticidade em utilizar essas manifestações eletroencefálicas para estabelecer um meio de comunicação entre o homem e a máquina e, ao mesmo tempo, em desenvolver, com esse sistema, uma nova ferramenta para o estudo das atividades neurofisiológicas que governam a produção e o controle dos eventos cerebrais externamente observáveis.³¹ Para isso, ele instituiu a expressão idiomática “Interface Cérebro-Computador” e formulou e discutiu conceitualmente a significação dela. Vidal, embora engenheiro eletricista de formação, mas sempre muito interessado nos desafios à compreensão do sistema nervoso, em 1970, havia passado um ano sabático no Instituto de Pesquisas do Cérebro, vinculado à Universidade da Califórnia, Los Angeles, para estudar o sistema vestibular de mamíferos.³² É provável que esse vínculo com o Instituto, do qual ele depois até se tornaria membro permanente, tenha influenciado fortemente seus trabalhos inaugurais sobre BCIs durante a década de setenta. Enfim, em 1977, Jacques Vidal, em outro notável trabalho acadêmico, divulgou os resultados sobre o desempenho de uma interface cérebro-computador com modo de operação em tempo real. Ele utilizou, como forma de estimulação visual, a incidência de súbitos clarões de luz de xenônio – 30 microssegundos de duração – na figura de um

quadrilátero, similar a um tabuleiro de xadrez com padrões reversos em vermelho e preto, contra um tênue fundo amarelo. Se um indivíduo fixasse o olhar próximo a qualquer um dos vértices dessa imagem (geralmente indicados por círculos diminutos), o estímulo repentino atingiria específicas áreas da parafóvea e, por consequência, desencadearia um distinto potencial evocado. Com esse arranjo e com o auxílio das técnicas disponíveis de processamento de sinal digital e de reconhecimento de padrões, Vidal conseguiu, com taxas de acerto de 90% em média, que seus voluntários controlassem a movimentação bidimensional de um pequeno objeto triangular – inicialmente no centro de um labirinto – e que eles, a partir desse manejo, conduzissem-no para a saída do proposto desafio.³³

Esse feito de Jacques Vidal logo despertou o interesse da comunidade científica internacional e contribuiu para o aparecimento de BCIs fundamentadas em outras manifestações cerebrais. Anos mais tarde, em 1988, com os desdobramentos das pesquisas voltadas à viabilização desses sistemas, Lawrence Farwell e Emanuel Donchin testaram uma interface cérebro-computador baseada na detecção de P300. Quatro voluntários saudáveis foram apresentados a uma matriz – de seis linhas por seis colunas – cujas células dispunham as letras do alfabeto e as abreviações dos comandos de controle. Em intervalos sucessivos, alguma das linhas ou das colunas reluzia por um período de 100 milissegundos, o que produzia brilhos intermitentes. Então, os sujeitos foram instruídos a prestar atenção no caractere que eles desejassem comunicar e, ao mesmo tempo, contar mentalmente o número de vezes que o mesmo piscava. Com esse método e com um algoritmo de detecção em tempo real, Farwell e Donchin permitiram que os tais voluntários conseguissem exprimir a palavra “*BRAIN*”.³⁴ Logo depois, em 1991, Jonathan Wolpaw, Dennis McFarland, Gregory Neat e Catherine Forneris demonstraram que indivíduos podiam aprender, rapidamente e convenientemente, a aumentar ou a diminuir a amplitude de seus ritmos mu em resposta à escolha mental de dois respectivos alvos, um no topo e o outro na base de uma tela de vídeo. Essa evidência mostrou que, com o critério apropriado para converter essa diferença de magnitude em movimentos unidimensionais de um cursor, dispositivos externos podiam ser controlados com alto grau de acurácia.³⁵ No ano seguinte, Erich Sutter, por sua vez, reportou o uso do fraco sinal elétrico proveniente do córtex occipital para conceber um sistema de comunicação no qual um usuário precisaria simplesmente olhar diretamente para estímulos visuais. Devido a uma ampliação cortical relacionada à grande quantidade de neurônios occipitais responsáveis pelo processamento do centro do campo visual (de maior acuidade, inclusive), Sutter percebeu que era possível determinar a estimulação escolhida a partir da intensidade da resposta gerada, uma vez que quanto mais próximo desse centro a incitação atingisse mais pronunciado seria o potencial evocado.³⁶

Não obstante, convém salientar que parte desse estudo fora previamente publicado em 1982, pelo mesmo autor, nos anais de um simpósio.³⁷ Enfim, em 1999, Ming Cheng e Shangkai Gao, em um resumo de conferência, anunciaram o desenvolvimento de uma interface cérebro-computador baseada na detecção de Potenciais Evocados Visualmente em Regime Estacionário (SSVEPs, do inglês *Steady-State Visually Evoked Potentials*), suscitados quando os voluntários fixavam a visão em algum dos quatro blocos cintilantes arranjados nas extremidades de um monitor. Em princípio, o sistema possibilitava que as pessoas movimentassem um cursor nas direções indicadas pelos estímulos repetitivos.³⁸ No referido texto sinóptico, essa interface fora apenas descrita de forma sucinta. Entretanto, um artigo divulgado posteriormente, em 2002, pelos mesmos pesquisadores, e nesse caso em conjunto com Xiaorong Gao, forneceu mais detalhes sobre as técnicas e as estratégias utilizadas para projetá-la.³⁹ Notadamente, todas essas publicações destacam a importância das aplicações de BCIs para pacientes com algum tipo de deficiência motora.

Em decorrência desses e de vários outros trabalhos acadêmicos que surgiram desde a publicação seminal de Jacques Vidal, o volume e o andamento das pesquisas em BCI, respectivamente, multiplicou-se e acelerou com o tempo. Em 1995, não havia mais do que seis grupos científicos trabalhando com esse ramo. Em 1999, por sua vez, ano em que foi proposto o 1.º Encontro Internacional de Tecnologia de BCI (Albany, New York), já havia mais de vinte. Assim, com o propósito de organizar as ideias, o referido Encontro revisou e definiu algumas das características essenciais pertinentes à área. Ficou estabelecido, por exemplo, que uma interface cérebro-computador seria qualquer sistema de comunicação que não dependesse das tradicionais vias biológicas de saída para os nervos periféricos e os músculos. Essa definição, de certa forma, foi o reflexo de uma das principais razões para o seu desenvolvimento – a criação de soluções de interação que provejam assistência para pessoas totalmente paralisadas ou parcialmente prejudicadas por doenças neuromusculares severas. O Encontro também formalizou os três constituintes básicos de uma BCI: a entrada, que depende das características da atividade cerebral monitorada e das técnicas para aquisição da mesma; a saída, que está sujeita ao tipo de aplicação; e o módulo de processamento, um conjunto de métodos e algoritmos que possibilita a conversão dos sinais de entrada em sinais de saída. Como as BCIs diferem largamente quanto à composição de suas partes, logo se percebeu que era impraticável compará-las por meio direto. Devido a esse motivo, o Encontro ainda propôs como alternativa a adoção da unidade de medida padrão para sistemas de comunicação: a taxa de transferência de informação – *bit rate*, como conhecida em inglês – que mensura o montante de informação efetivamente comunicada por unidade de tempo.⁴⁰

Desde então, alguns centros e grupos de pesquisa se tornaram referências importantes. O Centro Wadsworth (Albany, Estados Unidos da América – EUA), por exemplo, devido às suas investigações realizadas ao longo das décadas de oitenta e noventa, ficou conhecido por mostrar a viabilidade de controlar os ritmos eletroencefalográficos alfa e beta, provenientes da área sensório-motora, para movimentar um cursor. Um dos principais objetivos do Centro sempre foi o desenvolvimento de BCIs, para uso diário, adequadas a pessoas com incapacidades motoras.⁴¹ Entre 1991 e 2000, as interfaces cérebro-computador do Projeto de Graz (Graz, Áustria), outro exemplo, também foram baseadas em ritmos sensório-motores e especialmente dedicadas aos pacientes com disfunções neuromusculares. Porém, diferentemente de Wadsworth, a estratégia de Graz foi a utilização de tarefas mentais – como imaginar os movimentos das mãos e dos pés – para a obtenção de respostas eletro-corticais suscetíveis à classificação. Para alcançar essa meta, uma das contribuições centrais do Projeto (hoje largamente empregada em BCIs de imagística motora) foi a caracterização e a quantificação das chamadas sincronização e dessincronização (de potenciais cerebrais) relacionadas a evento.⁴² Já o Grupo de Tübingen (Tübingen, Alemanha) criou uma interface, denominada Dispositivo de Tradução de Pensamento (TTD, do inglês *Thought Translation Device*), e reportada na *Nature* em 1999, para treinar dois pacientes com paralisia a autorregular seus potenciais corticais. Com o uso do TTD, ambos puderam posteriormente usar um programa de suporte à linguagem que permitia a seleção de letras, de palavras e de pictogramas.⁴³ Esses paradigmas em que só o indivíduo devia aprender a controlar espontaneamente alguma atividade cerebral ficaram conhecidos como abordagens clássicas. Em contrapartida, já no século vinte e um, à maneira do Grupo de Berlin (Berlin, Alemanha), as interfaces deviam, por meio de métodos de aprendizagem de máquina, assimilar algumas das especificidades eletro-encefálicas de todo voluntário novo, ou seja, parte do esforço de adaptação tinha que ser atribuída ao computador. Consolidada nessa filosofia, uma das conquistas do Grupo foi a redução no tempo de treinamento entre o usuário e o sistema – antes, de vários dias ou semanas para, então, alguns minutos ou poucas horas, a depender das idiossincrasias de cada pessoa.⁴⁴ O Instituto de Pesquisa IDIAP (Martigny, Suíça), um último exemplo, como o Grupo de Berlim, também seguiu pelas concepções de aprendizagem de máquina para reduzir o tempo de treino. Além disso, o Instituto promoveu pesquisas com BCIs assíncronas. Os primeiros sistemas eram baseados apenas em protocolos síncronos nos quais qualquer operação devia ocorrer em períodos fixos bem definidos, geralmente intervalados por imagens ou sons externos que sugestionavam ao usuário o início de cada nova sessão. Esse procedimento facilitava a análise do sinal de EEG, pois o início de manifestações cerebrais – fosse por evocação ou por imaginação –

ficava bem determinado; entretanto, ao mesmo tempo retardava a execução e impossibilitava o pleno controle de tarefas. Por conta disso, o Instituto IDIAP, focado em superar essas restrições, voltou-se à elaboração de BCIs com protocolos assíncronos, em que os indivíduos poderiam – pelo menos em princípio – tomar uma decisão a qualquer momento.⁴⁵

Na Universidade Estadual de Campinas (Unicamp), o ramo de interfaces cérebro-computador somente teve origem em 2010, com o início do projeto Desenvolvimento de Tecnologias da Informação para Neurologia (DESTINE), custeado pela Financiadora de Estudos e Projetos (Finep), e cuja principal meta era a criação de uma cadeira de rodas controlada por alguma dessas interfaces e voltada a indivíduos que sofreram Acidente Vascular Cerebral (AVC). Em 2013, um dos desdobramentos desse projeto foi a dissertação de mestrado da Luisa Uribe, que reuniu os primeiros estudos, feitos nessa Universidade, sobre BCI com SSVEPs.⁴⁶ Uma de suas contribuições foi reforçar a importância do uso de técnicas para escolher, por meio de alguma métrica de seleção, os eletrodos mais informativos. Esse fato influenciou fortemente a concretização do presente trabalho, que também se apoiou em tais métodos de escolha. No mesmo ano, ainda ocorreu a fundação do Instituto Brasileiro de Neurociência e Neurotecnologia (BRAINN, do inglês *Brazilian Institute for Neuroscience and Neurotechnology*), enquadrado em uma linha de financiamento para novos Centros de Pesquisa, Difusão e Inovação (CEPID), com o apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP). Por conseguinte, o BRAINN também impulsionou as pesquisas de BCIs na Unicamp, com o propósito de conceber tecnologias para melhorar a qualidade de vida das pessoas com Epilepsia, AVC e demais doenças neurológicas prevalentes.⁴⁷

Dentro desse contexto, o objetivo central desta pesquisa foi o desenvolvimento de uma interface-cérebro computador que pudesse, adiante, integrar o sistema de navegação de uma cadeira de rodas. Esta seria direcionada, sobretudo, a pacientes que apresentassem as suas funções motoras comprometidas, mas que, contudo, mantivessem as suas funções cognitivas preservadas. Nesse sentido, a BCI precisava fornecer um canal de comunicação alternativo que, de acordo com a intenção de um usuário, produzisse os sinais básicos para, idealmente, auxiliar no controle dos movimentos da mencionada cadeira. Para justificar as escolhas convenientes e apresentar os resultados do trabalho, a dissertação foi dividida em, além desta introdução e uma sessão de desfecho, três capítulos. O primeiro deles, “Interfaces Cérebro-Computador”, contextualiza e define formalmente as BCIs, justifica a opção pelos SSVEPs, dentre os paradigmas possíveis, e delimita os módulos necessários para a sua elaboração. Já o segundo capítulo, “Estimulação, Aquisição e Processamento de SSVEPs”, fornece as técnicas usadas para a geração e para a mensuração dos potenciais evocados visualmente

em regime estacionário e trata dos métodos de processamento de sinais digitais e dos métodos de reconhecimento de padrões e de aprendizagem de máquina, utilizados tanto para a identificação dos referidos potenciais quanto para a avaliação do desempenho do sistema. Por sua vez, o terceiro capítulo, “Desenvolvimento de SSVEP-BCI”, expõe e discute, em detalhes, os cinco módulos utilizados para a estruturação da interface e um protocolo de operação entre eles, bem como os resultados obtidos com o funcionamento dela. Por fim, a última seção, “Conclusões e Perspectivas”, sintetiza as principais contribuições deste estudo e conjectura alguns caminhos para investigações futuras.

¹ Richard Caton. Electrical currents of the brain. *The Journal of Nervous and Mental Disease*, v. 2, n. 4, p. 610, 1875.

² Lindsay F. Haas. Hans Berger (1873-1941), Richard Caton (1842-1926), and electroencephalography. *Journal of Neurology, Neurosurgery & Psychiatry*, v. 74, n. 1, p. 9, 2003.

³ Obituary. Richard Caton, C.B.E., M.D., F.R.C.P. *The British Medical Journal*, v. 1, n. 1, p. 71, 1926.

⁴ Hans Berger. Über das elektrenkephalogramm des menschen. *European Archives of Psychiatry and Clinical Neuroscience*, v. 87, n. 1, p. 527, 1929.

⁵ Edgar D. Adrian, Brian H. C. Matthews. The Berger rhythm: potential changes from the occipital lobes in man. *Brain*, v. 57, n. 4, p. 355-356, 1934.

⁶ Lindsay F. Haas. Op. cit., p. 9, 2003.

⁷ Herbert H. Jasper, Leonard Carmichael. Electrical potentials from the intact human brain. *Science*, v. 81, n. 1, p. 51-53, 1935.

⁸ Frederick Andermann. Herbert Henri Jasper 1906-1999. *Epilepsia*, v. 41, n. 1, p. 114-115, 2000.

⁹ Herbert H. Jasper. The ten-twenty electrode system of the International Federation. *Electroencephalography and Clinical Neurophysiology*, v. 10, n. 1, p. 371-375, 1958.

¹⁰ Edgar D. Adrian, Brian H. C. Matthews. Op. cit., p. 377-381, 1934.

¹¹ V. J. Walter, William Grey Walter. The central effects of rhythmic sensory stimulation. *Electroencephalography and Clinical Neurophysiology*, v. 1, n. 1, p. 57-59, 1949.

¹² George D. Dawson. A summation technique for the detection of small evoked potentials. *Electroencephalography and Clinical Neurophysiology*, v. 6, n. 1, p. 65-69, 1954.

¹³ David Regan. Some characteristics of average steady-state and transient responses evoked by modulated light. *Electroencephalography and Clinical Neurophysiology*, v. 20, n. 3, p. 244-246, 1966.

¹⁴ Vialatte François-Benoît et al. Steady-state visually evoked potentials: focus on essential paradigms and future perspectives. *Progress in Neurobiology*, v. 90, n. 4, p. 420-422, 2010.

¹⁵ Samuel Sutton, Margery Braren, Joseph Zubin. Evoked-potential correlates of stimulus uncertainty. *Science*, v. 150, n. 1, p. 1187-1188, 1965.

¹⁶ Terence W. Picton. The P300 wave of the human event-related potential. *Journal of Clinical Neurophysiology*, v. 9, n. 4, p. 456-457, 1992.

¹⁷ Samuel Sutton, Patricia Tueting, Joseph Zubin. Information delivery and the sensory evoked potential. *Science*, v. 155, n. 1, p. 1439, 1967.

¹⁸ Emanuel Donchin, L. Cohen. Averaged evoked potentials and intramodality selective attention. *Electroencephalography and Clinical Neurophysiology*, v. 22, n. 6, p. 544-545, 1967.

¹⁹ Walter Ritter, Herbert G. Vaughan, Louis D. Costa. Orienting and habituation to auditory stimuli: a study of short terms changes in average evoked responses. *Electroencephalography and Clinical Neurophysiology*, v. 25, n. 6, p. 552, 1968.

²⁰ Walter Ritter, Herbert G. Vaughan. Averaged evoked responses in vigilance and discrimination: a reassessment. *Science*, v. 164, n. 1, p. 326, 1969.

²¹ Herbert G. Vaughan, Walter Ritter. The sources of auditory evoked responses recorded from the human scalp. *Electroencephalography and Clinical Neurophysiology*, v. 28, n. 4, p. 362-366, 1970.

²² D. B. D. Smith et al. Auditory averaged evoked potentials in man during selective binaural listening. *Electroencephalography and Clinical Neurophysiology*, v. 28, n. 2, p. 146, 1970.

²³ F. Golla, E. L. Hutton, William Grey Walter. The objective study of mental imagery. I. Physiological concomitants. *Journal of Mental Science*, v. 89, n. 1, p. 216, 1943.

²⁴ Philip L. Short. The objective study of mental imagery. *British Journal of Psychology*, v. 44, n. 1, p. 39-41, 1953.

- ²⁵ Kenneth H. Slatter. Alpha rhythms and mental imagery. *Electroencephalography and Clinical Neurophysiology*, v. 12, n. 4, p. 851, 1960.
- ²⁶ Charles Fox. The conditions which arouse mental images in thought. *British Journal of Psychology*, v. 6, n. 3-4, p. 420-431, 1914.
- ²⁷ Herbert H. Jasper, Wilder Penfield. Electrocorticograms in man: effect of the voluntary movement upon the electrical activity of the precentral gyrus. *Archiv für Psychiatrie und Nervenkrankheiten*, v. 183, n. 1, p. 171-173, 1949.
- ²⁸ Herbert H. Jasper, Wilder Penfield. Op. cit., p. 163, 1949.
- ²⁹ Henri J. Gastaut. Etude électrocorticographique de la réactivité des rythmes rolandiques. *Revue Neurologique*, v. 87, n. 2, p. 176-182, 1952.
- ³⁰ William N. Kuhlman. Functional topography of the human mu rhythm. *Electroencephalography and Clinical Neurophysiology*, v. 44, n. 1, p. 83, 1978.
- ³¹ Jacques J. Vidal. Toward direct brain-computer communication. *Annual Review of Biophysics and Bioengineering*, v. 2, n. 1, p. 157-158, 1973.
- ³² Jacques J. Vidal. Jacques J. VIDAL. *Jacques Vidal Private Page*. Disponível em: <<http://www.cs.ucla.edu/~vidal/vidal.html>>. Acesso em: 30 mar. 2014.
- ³³ Jacques J. Vidal. Real-time detection of brain events in EEG. *Proceedings of the IEEE*, v. 65, n. 5, p. 637-640, 1977.
- ³⁴ Lawrence A. Farwell, Emanuel Donchin. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology*, v. 70, n. 6, p. 512, 1988.
- ³⁵ Jonathan R. Wolpaw et al. An EEG-based brain-computer interface for cursor control. *Electroencephalography and Clinical Neurophysiology*, v. 78, n. 3, p. 257, 1991.
- ³⁶ Erich E. Sutter. The brain response interface: communication through visually-induced electrical brain responses. *Journal of Microcomputer Applications*, v. 15, n. 1, p. 32-35, 1992.
- ³⁷ Erich E. Sutter. *The visual evoked response as a communication channel*. Proceedings of the IEEE Symposium on Biosensors. Los Angeles: [s.n.]. 1984. p. 95-100.
- ³⁸ Ming Cheng, Shangkai Gao. *An EEG-based cursor control system*. Proceedings of The First Joint BMES/EMBS Conference. Atlanta: [s.n.]. 1999. p. 669.
- ³⁹ Ming Cheng, Xiaorong Gao, Shangkai Gao. Design and implementation of a brain-computer interface with high transfer rates. *IEEE Transactions on Biomedical Engineering*, v. 49, n. 10, p. 1181-1186, 2002.
- ⁴⁰ Jonathan R. Wolpaw et al. Brain-computer interface technology: a review of the first international meeting. *IEEE Transactions on Rehabilitation Engineering*, v. 8, n. 2, p. 164-173, 2000.
- ⁴¹ Jonathan R. Wolpaw, Dennis J. Mcfarland, Theresa M. Vaughan. Brain-computer interface research at the Wadsworth Center. *IEEE Transactions on Rehabilitation Engineering*, v. 8, n. 2, p. 224-225, 2000.
- ⁴² Gert Pfurtscheller et al. Current trends in Graz brain-computer interface (BCI) research. *IEEE Transactions on Rehabilitation Engineering*, v. 8, n. 2, p. 216, 2000.
- ⁴³ Niels Birbaumer et al. A spelling device for the paralysed. *Nature*, v. 398, n. 1, p. 297-298, 1999.
- ⁴⁴ Benjamin Blankertz et al. The non-invasive Berlin brain-computer interface: fast acquisition of effective performance in untrained subjects. *NeuroImage*, v. 37, n. 2, p. 539-550, 2007.
- ⁴⁵ José del R. Millán, Pierre W. Ferrez, Anna Buttfeld. The IDIAP brain-computer interface: an asynchronous multiclass approach. In: Guido Dornhege et al. *Toward Brain-Computer Interfacing*. 1. ed. Cambridge: The MIT Press, 2007. p. 103-105.
- ⁴⁶ Luisa F. S. Uribe. *Desenvolvimento de uma interface homem-máquina baseada em potenciais evocados visuais em regime estacionário*. Dissertação (Mestrado em Engenharia Elétrica). Faculdade de Engenharia Elétrica e de Computação. Universidade Estadual de Campinas. Campinas. 2013.
- ⁴⁷ Instituto de Pesquisa sobre Neurociências e Neurotecnologia. *CEPID Centros de Pesquisa, Inovação e Difusão*. Disponível em: <<http://cepid.fapesp.br/centro/11/>>. Acesso em: 21 abr. 2015.

1 INTERFACES CÉREBRO-COMPUTADOR

Atualmente, as interfaces cérebro-computador, perante a perspectiva do uso por indivíduos saudáveis, apresentam uma série de desvantagens se comparadas com outros dispositivos de comunicação usuais, como o teclado e o mouse, com os quais um usuário, por meio de acionamento mecânico, envia os sinais e os comandos desejados. Mesmo as mais rápidas e práticas delas são bem lentas e menos acuradas; requerem vários fios e equipamentos caros; precisam de um tempo de montagem e preparação; por vezes, envolvem a adaptação e o treinamento de quem as utiliza; e quase sempre param de funcionar em ambientes ruidosos. Por todas essas qualificações, as BCIs mais parecem artefatos exóticos e intimidantes do que aparelhagens que possam eventualmente ajudar as pessoas no dia a dia. Ou seja, por esse ponto de vista simplificado, incorre-se no erro de que elas só propiciem a transmissão das mesmas mensagens que outros meios disponíveis, mais rápidos e fáceis de usar, já permitem. Contudo, a despeito de todas as dificuldades técnicas que as permeiam, as interfaces cérebro-computador têm potencial para fornecer uma via de comunicação complementar. Algumas companhias, por exemplo, começaram a investir na criação de ambientes virtuais controláveis por operação simultânea tanto de acionadores manuais quanto de comandos neurais. Esses sistemas híbridos, por sua vez, hoje se aplicam no desenvolvimento de plataformas para as futuras gerações de jogos de computador, pois têm a capacidade de proporcionar a um usuário uma experiência nova e desafiante, características particularmente atrativas a esse ramo de entretenimento. Outro exemplo de possível aplicação é o reconhecimento de estados mentais. Algumas BCIs são particularmente apropriadas à avaliação do grau de atenção, frustração, agilidade, compreensão, exaustão, empenho, entre outros, de indivíduos durante a execução de tarefas específicas. Por conseguinte, essas informações podem ser utilizadas para a elaboração de interfaces computacionais adaptativas capazes de responder de acordo com a condição emocional de cada um deles. Hoje, sistemas como esses estão em teste para o uso corporativo, militar e governamental. Enfim, embora as BCIs estejam distantes de se tornarem produtos largamente comercializáveis como são o teclado e o mouse, para os entusiastas da área, já existe o grande desafio de pensar a integração delas com as técnicas convencionais de comunicação, de forma a aproveitar as características mais oportunas de ambas, para a confecção dos dispositivos de uso comum que estão por vir.¹

No entanto, como enfatizado ao longo da exposição na “Introdução”, as principais motivações para o desenvolvimento das interfaces cérebro-computador estão indissociavel-

mente ligadas às suas aplicações médicas, devido às várias alterações patológicas clássicas que acometem o sistema nervoso. Uma destas, a Esclerose Lateral Amiotrófica – ALS, do inglês *Amyotrophic Lateral Sclerosis* – é uma doença em que ocorre a degeneração progressiva dos neurônios motores superiores e inferiores, os quais controlam os movimentos voluntários dos músculos. Ela geralmente incide sobre indivíduos em fase adulta, sobretudo idosos, mas há registros de pessoas inclusive na faixa dos vinte anos que a desenvolveram. As causas hereditárias da ALS são as únicas bem conhecidas e são responsáveis por aproximadamente 5 a 10% dos casos; o restante destes é de origem desconhecida ou ainda está em estudo. A palavra “Amiotrófica” faz menção à atrofia e à fraqueza muscular, bem como à fasciculação – sintomas característicos de disfunções nos neurônios motores inferiores. Por sua vez, a expressão “Esclerose Lateral” se refere ao endurecimento patológico na coluna lateral da medula espinhal, na qual ocorre gliose seguida de degeneração do trato corticoespinhal, cujas evidências diretas são os reflexos hiperativos dos tendões, os sinais de Hoffmann e Babinski e os espasmos clônicos – sintomas, por outro lado, característicos de disfunções nos neurônios motores superiores. Se o primeiro grupo de indicações clínicas surge isoladamente, a enfermidade é chamada atrofia muscular espinhal progressiva e, caso apenas o segundo conjunto se manifeste, a condição é denominada esclerose lateral primária. Essas síndromes são consideradas variantes da ALS. Isso porque, mesmo que em vida somente uma das duas sintomatologias fique evidente nos pacientes, ambas apresentam anormalidades, constatadas após autópsias, nas duas mencionadas categorias de células neuronais. Em indivíduos com ALS típica, as manifestações iniciais são comumente a fraqueza nas mãos e nas pernas ou a fala arrastada e a disfagia; contudo, com o tempo aparecem quase todos os demais sintomas. Embora essa doença não comprometa as funções cognitivas dos enfermos, ela é progressiva e a expectativa de vida deles é cerca de três a cinco anos.²

Outra desordem do sistema nervoso que merece destaque é a Lesão da Medula Espinhal (SCI, do inglês *Spinal-Cord Injury*). Em geral, ela decorre de traumatismo mecânico provocado por forças de tração ou compressão intensas, as quais, quando atuam sobre a coluna vertebral, impelem em direção ao tecido medular os fragmentos de vértebras, de discos intervertebrais e de ligamentos. As intercorrências primárias abrangem o seguinte desencadeamento: vasos sanguíneos são rompidos, axônios interrompidos e membranas de corpos neuronais partidas; instantaneamente, hemorragias ocorrem na substância cinzenta e se espalham de forma radial e axial; em minutos, a medula espinhal se dilata e preenche, nas proximidades do ferimento, toda a cavidade do canal medular; isquemia secundária advém desse aumento de volume quando o mesmo excede a pressão venosa; a autorregulação do fluxo sanguíneo

cessa e o choque neurogênico acarreta hipotensão sistêmica, o que agrava a isquemia; esta, então, dispara reações fisiológicas em cascata que levam à danificação ou morte de células na vizinhança da lesão. Após esse quadro inicial, ocorrem intercorrências secundárias: a hipoperfusão que primeiro se desenvolve na substância cinzenta se estende em torno da substância branca; isso, por sua vez, reduz ou bloqueia completamente a propagação de potenciais de ação ao longo dos axônios, o que contribui, enfim, para a perda de sensibilidade acompanhada de paralisia motora. As principais causas de SCI decorrente de trauma mecânico são largamente documentadas e incluem acidentes automotivos, violência, quedas e atividades recreativas. Por outro lado, há casos de lesão da medula espinhal provocados por situações não traumáticas, embora a predominância destes seja pouco conhecida devido a suas razões heterogêneas e devido à escassez de registros que os contabilizam. Algumas dessas circunstâncias estão associadas a questões congênitas e de desenvolvimento, a doenças neurodegenerativas, a problemas genéticos e metabólicos, a moléstias infecciosas, a eventos isquêmicos e inflamatórios, a sequelas pós-feridas, a agentes toxicológicos e, também, a tumores. Por conta dessa diversidade de origens, para cada uma destas a fisiopatologia primária da SCP tem sua especificidade; entretanto, todas se desdobram em intercorrências secundárias semelhantes e, com isso, podem igualmente ocasionar a paraplegia ou a tetraplegia.³

Um último exemplo de alteração patológica do sistema nervoso é o Acidente Vascular Cerebral (AVC), que, de forma ampla, é tido como uma síndrome abrupta com sinais clínicos relacionados a distúrbios locais (ou globais) de funções cerebrais – cujos sintomas duram no mínimo 24 horas ou conduzem, dentro desse período, à morte – sem outro motivo aparente que não seja o de origem vascular. Essa definição inclui a hemorragia subaracnóidea, mas exclui o ataque isquêmico transitório, o hematoma subdural e o sangramento ou infarto, no cérebro, causados por infecções ou tumores.⁴ A incidência de AVC sobre uma população não apresenta justificativas diretas, mas ela está fortemente atrelada a fatores de risco como a hipertensão, o fumo, o colesterol alto, a diabetes, entre outros. Em geral, o acidente vascular cerebral interrompe o fornecimento de nutrientes para o tecido – usualmente por conta do rompimento ou da obstrução de vasos sanguíneos – e é respectivamente dividido em duas categorias: o hemorrágico e o isquêmico. O primeiro é desencadeado sobretudo por microangiopatia hipertensiva, que provoca o aneurisma e a subsequente ruptura de pequenos ductos. Como exemplo desse mecanismo, a hemorragia subaracnóidea, que representa 5% de todos os casos de AVC, ocorre quando aneurismas saciformes se rompem no interior do espaço subaracnóideo. O segundo, por sua vez, soma 80% das ocorrências e é subdividido de acordo com as origens da obliteração – como a aterosclerose, a embolia cardíaca, a oclusão de vênulas,

arteríolas e capilares e outras manifestações bem determinadas – ou é classificado em causas não reconhecidas. Como existem esses vários tipos de AVC e estes podem acometer diferentes sítios encefálicos, os sintomas são muito diversos e dependentes das funções que a região atingida exercia.⁵ Por exemplo, quando um acidente vascular acontece no tronco cerebral e se estende principalmente à ponte basal, o dano pode evoluir para um quadro clínico grave denominado Síndrome do Encarceramento (LiS, do inglês *Locked-in Syndrome*).⁶

A LiS não é especificamente uma doença ou lesão, e sim um transtorno neurológico extremo provocado por infarto, hemorragia ou trauma, na parte ventral da ponte. Além de AVC (isquêmico ou hemorrágico) e traumatismo mecânico, outras possíveis causas estão associadas com intercorrências tumorais, metabólicas, infecciosas e desmielinizantes. A síndrome do encarceramento foi definida, em 1966, como a manifestação concomitante de tetraplegia, de paralisia dos nervos cranianos inferiores e de mutismo, com a preservação da consciência e de apenas dois conjuntos de movimentos: o abrir e fechar das pálpebras e o desvio ocular ascendente e descendente. Em 1986, para esclarecer que o mutismo também implica a falta de vontade de falar (o que não é o caso dos pacientes com LiS), a síndrome foi redefinida como a manifestação conjunta de tetraplegia e de anartria (incapacidade de articular palavras), com a preservação da consciência. Embora esta seja conservada, a atenção, a função executiva, a habilidade intelectual, a percepção e as memórias visuais e verbais podem ser afetadas; em contrapartida, há relatos de pacientes em que a avaliação neurofisiológica comprovou a manutenção das referidas capacidades cognitivas. Especificamente, a anartria acontece devido à paralisia bilateral dos nervos facial, glossofaríngeo e laríngeo, que também leva à disfagia e à impossibilidade (ou dificuldade) de realizar expressões faciais. É comum a perda do controle no direcionamento horizontal do olhar; não obstante, é usual a manutenção tanto dos movimentos das pálpebras superiores quanto do deslocamento vertical da visão.⁷ Com base nessas sintomatologias e na definição proposta, a LiS é convencionalmente separada em três classes: a clássica, em que ocorre a tetraplegia e a anartria com a preservação da consciência, do pestanejo e do desvio ocular para cima e para baixo; a incompleta, em que se mantêm os mesmos critérios anteriores com a adição de algum movimento voluntário remanescente diferente dos já mencionados; e a total, em que se constata a imobilidade completa e a incapacidade de se comunicar. Os pacientes classificados nas duas primeiras condições são capazes de expressar ideias e opiniões complexas através de piscadelas em código Morse, por exemplo.⁸ Porém, os enclausurados da terceira categoria ainda não dispõem de alternativas, apenas de esperanças em um futuro no qual as interfaces cérebro-computador, entre outras tecnologias, quiçá, consigam quebrar esse claustro.⁹

De modo geral, as alterações patológicas exemplificadas prejudicam o funcionamento de vias aferentes e eferentes responsáveis pela comunicação entre o sistema nervoso e a musculatura e, com isso, ocasionam a paralisação e a posterior atrofia de membros e articulações. Essa redução, ou mesmo supressão, das habilidades motoras degrada consideravelmente a qualidade de vida desses doentes e, por conta disso, motiva grande parte das pesquisas na área de reabilitação. Ou seja, quaisquer indivíduos que estejam gravemente incapacitados por alguns dos distúrbios relatados – ou por muitos outros que também conduzem a estados clínicos semelhantes – podem se beneficiar das interfaces cérebro-computador. Para ajudar a avaliar a importância e a utilidade dessa tecnologia para esses pacientes, existe uma classificação que leva mais em conta a extensão das deficiências do que propriamente a etiologia das mesmas.¹⁰ Dentro dessa ótica, esses potenciais usuários de BCIs são arranjados em três grupos: (1) pessoas que não têm qualquer controle neuromuscular aparente e que, portanto, estão totalmente encarceradas; (2) pessoas que mantêm somente uma capacidade muito limitada desse controle, como o movimento dos olhos ou a ligeira contração de algum músculo; e (3) pessoas que apresentam parte substancial do comando da musculatura e que podem prontamente utilizar outros dispositivos de assistência para a comunicação baseados nos movimentos ainda presentes. Para os debilitados da primeira categoria, que é a minoria, até agora não está claro o quanto as BCIs de fato podem servi-los, embora sejam os que delas mais precisem. Os da segunda, que numericamente excedem os anteriores, são os usuários prospectivos inerentes por ordem de prioridade, pois eles têm dificuldades, ou não são capazes, de utilizar as tecnologias de assistência convencionais. Por fim, para os da terceira, que são a grande maioria, as BCIs existentes têm pouco a oferecer, posto que os atuais limites destas impedem-nas de superar as vantagens dos aparelhos de ajuda já disponíveis. No entanto, com o rápido avanço nas pesquisas, espera-se que esse último grupo logo esteja contemplado.¹¹

1.1 TECNOLOGIAS ASSISTIVAS

Dentro da atual fronteira científica, é impraticável (muito difícil) a regeneração neuronal em pacientes afetados por doenças (ALS etc.) e traumas (SCI, AVC etc.) do sistema nervoso e, por conta disso, é inviável a fidedigna restauração de seus movimentos biologicamente naturais. Embora algumas estratégias de recuperação sejam promissoras, os métodos mais efetivos não reestabelecem essas funções sequer aproximadamente. Diante dessa realidade, há muito interesse no desenvolvimento de interfaces cérebro-computador que contribuam para a melhora da qualidade de vida de tais pessoas. As BCIs podem ajudar ao menos de

duas maneiras: através de reabilitação neurológica ou através de reabilitação assistiva. A primeira forma é desafiante e só recentemente começou a ser explorada. Ela objetiva fazer uso de protocolos de BCI para aumentar o controle volitivo da musculatura comprometida. A evidência mais aceita dessa reaprendizagem é a plasticidade cerebral dependente de atividade (ADBP, do inglês *activity-dependent brain plasticity*). Essa plasticidade representa modificações sistêmicas de sinapses, neurônios e circuitos neuronais de acordo com ações e tarefas realizadas com frequência. Em indivíduos saudáveis, ela leva ao controle especializado da musculatura, ou seja, permite-lhes a aprender e aperfeiçoar novas ações e movimentos. Por outro lado, em pacientes debilitados por lesões ou doenças do sistema nervoso, essa plasticidade pode influenciá-los positivamente, quando restaura funções motoras perdidas, ou negativamente, quando solidifica ou até mesmo exacerba funções motoras anormais. Assim, para que essa restauração tenha sucesso, as intervenções com BCI que induzem a ADBP, antes de serem colocadas em prática, devem ser apropriadamente estudadas e reconhecidas. Já a segunda forma, a reabilitação assistiva, é a mais difundida entre os pesquisadores da área. Ela objetiva fazer uso de sinais encefálicos, de máquinas e de técnicas computacionais, para substituir os comandos neuromusculares naturais, ou seja, dentro dessa proposta, a interação com o ambiente passa a ocorrer através do controle cerebral de dispositivos artificiais.¹²

Esse último método de reabilitação integra um conjunto maior de estratégias reunidas sob a designação “Tecnologia Assistiva” (AT, do inglês, *Assistive Technology*). Essa expressão qualifica os aparelhos e as técnicas que fornecem algum auxílio para pessoas com déficits em funções físicas, mentais ou emocionais. Esses indivíduos precisam de ATs como meio alternativo para executar ações, tarefas e atividades. Há um elevado número de dispositivos que se inserem nessa categorização. Cadeiras de rodas, andadores, bengalas, órteses e próteses, que ajudam na mobilidade, são acessórios já bem conhecidos. Aparelhos auditivos, vocalizadores, telefones para surdos e lupas eletrônicas, que nesse caso dão suporte à comunicação e à informação, são outros instrumentos existentes. Além de mecanismos como os mencionados, “tecnologia assistiva” abrange as técnicas com que determinados equipamentos são programados e controlados para prover algum suporte. Por exemplo, computadores pessoais, com a instalação de programas e de adaptações, podem se tornar tradutores e sintetizadores de voz. Em contrapartida, também existe a perspectiva da construção de ambientes desimpedidos às pessoas com deficiências. Por conseguinte, essa questão de acessibilidade costuma envolver a reorganização, a reestruturação ou até mesmo a reedificação de instalações prediais e residenciais, de sistemas de transporte e de locais recreativos, justamente para melhor acomodar as ATs e, assim, tornar esses espaços mais convenientes aos usuários delas. Portanto, o

desenvolvimento de tecnologias assistivas e o projeto de ambientes acessíveis são interdependentes: um cadeirante, por exemplo, não tem autonomia para entrar em um prédio que só oferece acesso por escadas; e os painéis de informações de centros comerciais, outro exemplo, deveriam ser adequados para cegos que, por conta própria, desejem saber a localização de uma loja. Enfim, todas as áreas repletas desses obstáculos desencorajam os indivíduos com algum déficit físico, mental ou emocional de circularem e agirem espontaneamente nelas.¹³

Diante desse contexto, uma BCI, cuja proposta é, sobretudo, fornecer alternativas de comunicação para pacientes com doenças ou lesões neuromusculares, enquadra-se como um caso especial de AT pertencente à grande área de Tecnologias de Informação e Comunicação (ICTs, do inglês *Information and Communication Technologies*). Uma ICT-AT, por sua vez, é classificada de acordo com a definição 22 da ISO 9999:2007, que estabelece o seguinte:

Produtos de apoio para comunicação e informação – dispositivos para ajudar a pessoa a receber, enviar, produzir e/ou processar informação em diferentes formatos. Estão incluídos, p. ex., dispositivos para ver, ouvir, ler, escrever, telefonar, sinalizar, avisar e tecnologia de informação.¹⁴

Mas, como dito há pouco, embora uma grande variedade de tecnologias assistivas esteja disponível, nem sempre isso implica em garantia de acesso, porque afinal este não depende apenas dos produtos, e sim da compatibilidade entre os mesmos e o ambiente. Por isso, as aparelhagens com tecnologia de BCI, para que sejam funcionais, devem atentar para esse detalhe, ao menos no tocante aos espaços residenciais. Além desse aspecto, as BCIs devem satisfazer outros critérios básicos para alcançar o estado da arte em ITC-ATs. Por exemplo, a interface padrão dos computadores pessoais é extremamente flexível; porém, esta característica, que por um lado tem suas serventias, pode impor barreiras para as pessoas que estejam debilitadas: vários ícones pequenos, múltiplas janelas e áreas de trabalho, funções como arrastar e soltar – e assim por diante – são exemplos de supostas funcionalidades que muitas vezes confundem e dificultam tais usuários. Uma abordagem comum, nesse caso, é a inclusão de ampliadores de tela ou sintetizadores de voz, que auxiliam na identificação dos recursos do sistema; entretanto, essas soluções, embora forneçam considerável benefício para usufrutuários específicos, não alteram as principais restrições da interface em si. O desafio, então, é projetar programas computacionais com aparência gráfica e modalidade de operação e interação adequadas, e se preciso customizadas, aos indivíduos com algum tipo de deficiência. As BCIs, de certa forma, também precisam acatar fundamentos similares para atender à vasta demanda dos usuários clínicos.¹⁵

Um primeiro exemplo de pesquisa guiada por esses princípios é a incorporação de uma interface cérebro-computador ao QualiWORLD, um programa computacional já projetado em conformidade com a regulamentação de ITC-ATs. Ele dispõe de funções prontas para a comunicação – um navegador de internet e um processador de texto para geração de discurso e o envio de mensagens eletrônicas – funções para o entretenimento – um tocador de música e vídeo, um visualizador de imagens e alguns jogos de computador – e funções para o controle de ambiente – um acionador que liga e desliga a televisão (ou outros aparelhos semelhantes). O QualiWORLD pode ser controlado por uma grande variedade de sinais de entrada – desde um mouse até a digitalização de gestos faciais – e, com isso, possibilita que, em diferentes estágios de doenças degenerativas, usuários clínicos o utilizem apenas com uma mudança na captação das decisões deles. Devido a essas funcionalidades, o referido estudo se propôs a projetar uma BCI baseada em P300 para enviar comandos ao QualiWORLD. Para isso, a interface deste foi parcialmente sobreposta por um arranjo de pontos de estimulação que suscitasse esse potencial evocado e que, ao mesmo tempo, facilitasse o acesso aos ícones e atalhos do sistema, ao invés da clássica matriz de caracteres cintilantes. Em experiências de integração como essa, a eficácia, a eficiência e a satisfação de usufrutuários devem ser avaliadas durante a execução de tarefas rotineiras, como a escrita de um texto, o envio de uma mensagem eletrônica ou a navegação na rede de computadores. A eficácia faz menção ao quão preciso e completo os voluntários cumprem as ações propostas, a eficiência leva em conta o esforço e o tempo gastos por eles na realização das mesmas, e a satisfação, por fim, representa o conforto aparente e a aceitabilidade. O ideal é que esses indicativos sejam estimados tanto para novos usuários quanto para indivíduos com larga experiência no uso de ATs. Por assim dizer, é imprescindível que uma BCI, antes de ser amplamente difundida em produtos de ICT-ATs, satisfaça rigorosamente critérios de apreciação como esses.¹⁶

Nessa mesma linha de pesquisa, outro exemplo promissor com BCIs é o treinamento de pessoas para operar um protótipo de controlador de ambiente. Este program foi pensado, sobretudo, para pacientes que apresentam deficiências neuromusculares graves e que, inclusive, têm dificuldades em utilizar as ATs convencionais – geralmente requerentes de algum controle parcial da musculatura. Há uma série de requisitos que precisaram ser atendidos para elaboração de tal sistema e um deles foi adequar a BCI para funcionar em conjunto com periféricos de entrada (mouse, manche, *eye tracking*, assistente de reconhecimento de voz, entre outros). Essa diversificação na captação de sinais compôs uma única plataforma de comunicação para guiar pequenos dispositivos robóticos e interagir com aparelhos de uso diário. Em princípio, as justificativas para uma múltipla capacidade de acesso são duas: (1)

ampliar a escala de usuários ao mesmo tempo em que se garanta uma personalização sistemática para lidar com vários níveis de déficits e (2), conforme a evolução das doenças degenerativas, rastrear um aumento ou decréscimo das habilidades motoras remanescentes de forma que isso indique a necessidade de uma adaptação para funcionar com a atividade muscular residual. Essa flexibilidade possibilita que um paciente se familiarize mais facilmente com a plataforma de comunicação e, quando lhe for conveniente ou impelido pela enfermidade, migre paulatinamente para um controle por BCI. Outros requisitos satisfeitos foram (1) a utilização de um sistema inteligente que permitisse os robôs seguirem caminhos complexos acionados por um conjunto de instruções simples e (2) a transmissão de um fluxo de informações entre o usuário e o aparelho eletrônico controlável, para que ambos recebessem atualizações de estado durante a execução de uma tarefa. Apesar de tudo, para se juntar as demais soluções de ICT-ATs, controladores de ambiente como esse também devem passar por testes de eficácia, eficiência e satisfação antes que sejam disponibilizados para usuários finais.¹⁷

Um último exemplo de pesquisa com BCIs para aplicação em tecnologias assistivas é a cadeira de rodas com controle compartilhado. De acordo com os desenvolvedores, essa cadeira foi equipada com sensores que registravam informações do ambiente. Esses dados, por sua vez, eram enviados para filtros de contexto que monitoravam o funcionamento da BCI por meio da comparação direta entre o estado mental detectado e a factibilidade de execução da ação correspondente. Além disso, para gerar deslocamentos seguros e suaves, o sistema de navegação sempre avaliava o estado físico da cadeira antes de mapear os comandos de alto nível nas instruções motoras apropriadas (velocidades de translação e rotação, por exemplo). Disposta com tais recursos, essa cadeira de rodas inteligente, se o desempenho do usuário caísse, responsabilizava-se por mais funções de direcionamento ou, caso contrário, interferia cada vez menos. Ou seja, idealmente, um sistema compartilhado necessita se adaptar constantemente para inferir o nível de assistência que deve ser fornecido: desde assumir completamente a navegação, se preciso, para evitar colisões com obstáculos, até não ativar qualquer medida de segurança enquanto a cadeira for guiada com confiança. Em geral, sistemas como esse são primeiro testados com realidade virtual e só depois com um equipamento real de fato, principalmente porque a experiência pode envolver voluntários debilitados, como tetraplégicos e paraplégicos.¹⁸ A realidade virtual provê um ambiente de simulação para situações que envolvam riscos ou alto custo. Em particular, a área de reabilitação assistiva pode fazer uso dessa tecnologia para o treinamento de dispositivos robóticos, como a cadeira de rodas compartilhada. Nesse caso, o participante é personificado por um avatar e, com isso, treina, por alguma estratégia de BCI, a locomoção do veículo em um ambiente simulado –

com ruas, caminhos, pessoas e obstáculos virtuais. Para um cadeirante, isso serve de contato inicial com o sistema de navegação antes de assumir o controle físico do equipamento.¹⁹

1.2 TIPOS DE INTERFACES CÉREBRO-COMPUTADOR

Conceitualmente, uma Interface Cérebro-Computador (BCI, do inglês *Brain-Computer Interface*) é qualquer sistema unidirecional de comunicação e controle em que a informação seja transduzida, decodificada e transmitida, sem o uso das vias neuromusculares de saída, de alguma atividade fisiológico-encefálica (origem) para uma máquina executora (destino). Assim, a BCI proporciona aos seus usuários uma nova experiência de atuação no ambiente porque substitui os nervos e os músculos, bem como os movimentos que estes produzem, por sinais cerebrais e por equipamentos e programas de computador que traduzem tais sinais em comandos e ações artificiais. Porém, para que isso ocorra satisfatoriamente, a BCI requisita algum tipo de realimentação. Notadamente, a diligência neuromuscular padrão inevitavelmente depende desse artifício para realizar tarefas. Por exemplo, na produção da fala ou no passo da caminhada, tal igual em aptidões mais sofisticadas como o canto e a dança, o cérebro sempre faz ajustes sequenciais – durante essas e toda a sua vasta gama de produções sensoriais, motoras e cognitivas – de acordo com os resultados intermediários e finais obtidos com essas mesmas produções. Inclusive, quando uma criança logo cedo apresenta deficiência nos circuitos de retroalimentação neural, a perícia motora dela não se desenvolve adequadamente e, em contrapartida, quando um indivíduo já formado apresenta perda ou regressão desses mecanismos, a perícia motora dele se deteriora gradualmente.²⁰ Então, como proposta de substituição das referidas vias neuromusculares, o funcionamento da BCI também depende de realimentação e, baseada nesta, depende da ininterrupta adaptação cerebral. Diante disso, a operacionalização bem sucedida dessa interface requer que os seus usuários desenvolvam e mantenham uma habilidade pouco comum: controlar a manifestação de específicos sinais fisiológicos oriundos do cérebro; e requer que os seus algoritmos e dispositivos adaptativos convertam corretamente a intenção dessas pessoas em ações apropriadas.²¹

A enunciação comumente aceita para definir essas interfaces estabelece o não uso dos circuitos neuronais de saída para a musculatura. Entretanto, a própria necessidade de realimentação sugere que essa definição não restringe o uso dos circuitos de entrada. Com base nisso, tais sistemas de comunicação são separados em duas categorias básicas: BCI dependente, em que a geração da atividade cerebral detectável deriva essencialmente de estimulação das vias neuromusculares de entrada, e BCI independente, em que a geração dessa atividade

não deriva necessariamente de estimulação das mesmas vias. A primeira categoria é basicamente uma forma alternativa de identificar mensagens que chegam ao sistema nervoso central pelos circuitos de acesso e, por isso, demanda a articulação dos músculos envolvidos no controle do transdutor biológico em que ocorre a incitação. Já foi abordado anteriormente que os estímulos visuais, por exemplo, suscitam potenciais evocados visualmente, mensuráveis no córtex occipital. Na maior parte das vezes, isso requer que um indivíduo olhe fixamente para tais estímulos, ou seja, isso pressupõe que ele apresente o comando da musculatura responsável por efetuar o direcionamento do campo visual. Logo, em parte, esse tipo de BCI também depende de vias eferentes – nesse caso para promover a geração do sinal encefálico e não para realizar a comunicação do mesmo. Por contraste, para desencadear eventos observáveis em regiões do cérebro, a segunda categoria não envolve a transmissão de mensagens externas e, por isso, não requer diretamente os circuitos aferentes. Como exemplo, também foi visto em discussões precedentes que significativas alterações nas amplitudes dos ritmos alfa e beta podem ocorrer apenas através da capacidade individual de imaginar (e não executar de fato) um movimento. É conveniente frisar que essa estratégia, em princípio, independe dos nervos periféricos e dos músculos, mas que só produz bons resultados com treinamento e uso de realimentação. Dessa forma, as vias neuromusculares de ingresso são necessárias para, no mínimo, reforçar a resposta de uma determinada manifestação encefálica.²²

Seja a BCI dependente ou independente, como todo sistema de comunicação e controle, ela apresenta ao menos três constituintes básicos: uma entrada e uma saída de sinais e, entre estas, um módulo para o processamento dos mesmos.²³ O primeiro desses componentes é formado por um (ou mais) dentre os vários métodos de monitoramento e aquisição de atividades cerebrais e, de acordo com estes, é o responsável pelo emprego de outra distinção taxionômica: BCI invasiva, em que os sensores são introduzidos no crânio, ou BCI não invasiva, em que os sensores são mantidos fora da cabeça. Da categoria invasiva, a entrada de sinais é usualmente estabelecida com as técnicas de medida a seguir: a Eletrocorticografia (ECoG), que usa uma grade (tira) de eletrodos epidurais ou subdurais para registrar as manifestações elétricas do córtex; e Eletrodos Intra-Corticais (EICs), que possibilitam a captura de potenciais de ação na vizinhança de neurônios individualizados ou agregados. Ambas as formas de detecção permitem a obtenção de medidas com alta qualidade; no entanto, requerem procedimentos cirúrgicos (trepanação e dissecação, por exemplo) e, devido a isso, envolvem questões acerca da durabilidade dos implantes e acerca da proteção contra possíveis infecções. Da categoria não invasiva, por outro lado, a entrada típica é implementada com as técnicas adiante: a Eletroencefalografia (EEG), que mensura – com eletrodos sobre o escalpo – a ativi-

dade elétrica de grandes populações neuronais; a Magnetoencefalografia (MEG), que mede o campo magnético gerado pelas correntes desses mesmos contingentes de neurônios; a Imagem de Ressonância Magnética Funcional (fMRI, do inglês *Functional Magnetic Resonance Imaging*) e a Espectroscopia de Infravermelho Próximo (NIRS, do inglês *Near Infrared Spectroscopy*), as quais – mesmo que por processos físicos diferentes – possibilitam a avaliação de respostas hemodinâmicas associadas ao metabolismo cerebral; e, por fim, a Tomografia por Emissão de Póstron (PET, do inglês *Positron Emission Tomography*), que detecta pares de raios gama produzidos por radionuclídeos emissores de pósitrons – incorporados, nesse caso, ao sistema nervoso através de moléculas biologicamente ativas (marcadores). Em geral, como MEG, fMRI e PET dependem de aparelhagens custosas e fixas ao laboratório, as três são normalmente empregadas em investigações básicas sobre a localização de funções e disfunções encefálicas e, por isso, são adequadas aos projetos de BCI para uso exploratório; enquanto EEG e NIRS, técnicas portáteis e menos dispendiosas (se comparadas às três antecedentes), são convenientes aos projetos de BCI para uso, além de exploratório, prático.²⁴ Dentre todos os métodos vistos, a eletroencefalografia, por satisfazer inteiramente os dois quesitos anteriores e por fazer parte da categoria não invasiva, tornou-se, pelo que se consta, o modo mais difundido para a elaboração da entrada de uma interface cérebro-computador.

O módulo de processamento de sinais, por sua vez, é composto por um conjunto de etapas computacionais em que os dados brutos, provenientes de técnicas de medida como as mencionadas, essencialmente passam por uma redução de dimensionalidade: de espaços de entrada multidimensionais (registros íntegros) para espaços de saída geralmente bi, tri ou tetradimensionais (comandos de máquinas). De certa forma, as primeiras BCIs se baseavam em modos de operação por condicionamento, em que se fixava um algoritmo de tradução para processar os registros encefálicos e, de acordo com o resultado deste, gerava-se um sinal de realimentação visual. Os usuários eram simplesmente instruídos a olhá-lo e a encontrar uma maneira de controlá-lo voluntariamente. Tal estratégia surpreendentemente surtia algum efeito através de reforço com estímulos de recompensa. No entanto, em sistemas como esse, a capacidade de adaptação do voluntário era crucial, o que geralmente se alcançava com treinamento extensivo. Só depois surgiu a ideia de empregar algoritmos flexíveis para que parte da tarefa de assimilação fosse transferida para o computador. Com o uso de técnicas de aprendizado de máquina, alguns parâmetros do processamento se tornaram ajustáveis conforme as especificidades da atividade cerebral de cada usuário. Para conseguir esse feito, utilizam-se métodos de extração e seleção de características e, para o reconhecimento destas, métodos de classificação, ambos configuráveis de acordo o tipo de BCI empregado.²⁵ Geralmente, o algoritmo de

processamento (seja ele condicionante ou adaptativo) pode atuar em dados prontamente adquiridos para avaliação imediata ou em dados que foram armazenados para perscrutação. Nesse sentido, o instante em que esse processamento ocorre origina outra taxonomia usual da área: BCI *online*, em que o sistema está conectado com alguma aplicação, e BCI *offline*, em que o sistema está desconectado de qualquer aplicação. O primeiro caso é decisivo para as ações práticas e é programado para responder de forma conveniente e previsível em um período diminuto logo após a aquisição (há prazos envolvidos). Já o segundo, como não existe a restrição temporal, costuma não ser rápido e é comumente adotado para confirmar os resultados de uma execução *online* ou para realizar investigações minuciosas com o registro. Porventura, isso posteriormente ajuda a descobrir informações pertinentes que contribuem para a sugestão de novas formas e etapas de processamento.

Por último, a saída de sinais é quem envia os comandos para realizar tarefas diversas – como a seleção de caracteres e ícones e a movimentação de um cursor – ou para manipular órteses e próteses-neurais que se conectam ao corpo e que restauram, pelo menos em parte, a mobilidade de membros comprometidos.²⁶ Como já abordado na seção anterior, outra possibilidade é que a saída esteja vinculada ao sistema de navegação de uma cadeira de rodas com controle (para decidir as direções de percurso) compartilhado. Em situações como essa, a ação não é necessariamente o reflexo da decisão tomada pela BCI; como a interface integra, nesse caso, um sistema mais amplo, a saída de sinais representa mais uma sugestão do que uma resolução. Em casos de erros extremos, por exemplo, o controle compartilhado pode ignorar completamente a escolha da interface. Embora exista essa possibilidade de equívoco, ainda assim a saída está diretamente relacionada com a atuação e, por isso, tem um papel importante para a geração de retroalimentação em BCIs *online*, ou seja, ela pode alimentar mecanismos de retorno que produzam indicações da efetividade com que as tarefas são executadas. De certa forma, talvez isso seja particularmente importante para os processos compartilhados, porque os resultados da BCI podem não ficar evidentes, devido às correções e compensações que o sistema integrado realiza, e, por isso mesmo, seja providencial que a saída forneça ao menos um sinal de controle para informar as decisões incorretas aos usuários porque estes geralmente se esforçam e se adaptam com os erros para aprender a controlar melhor o dispositivo em questão.

Embora uma BCI seja sistematicamente constituída por essas três partes (a entrada, o módulo de processamento de sinais e a saída), para caracterizá-la por completo e necessário ainda definir um último elemento (não constitutivo, mas imprescindível): o protocolo de operação. De forma genérica, este abarca os procedimentos para o início e o término das aq

sições, determina se a comunicação é contínua ou descontínua, se a mesma é desencadeada pelo usuário ou pelo sistema, estipula a sequência e a velocidade de interação entre os mesmos, indica o momento que a realimentação deve ser fornecida, entre outras possíveis determinações. Os protocolos utilizados em BCIs não são necessariamente adequados para integrar um dispositivo que sirva às necessidades de pessoas com deficiências porque os mesmos são normalmente idealizados para fins de estudo e não para fins práticos. Por exemplo, em geral o acionamento e o desligamento do sistema (bem como os objetivos a serem cumpridos: escrever mensagens, guiar dispositivos robóticos, ou tarefas similares) são controlados (sugeridos) pelos pesquisadores e não pelos usuários. São raros os experimentos em que um voluntário tenha autonomia para proceder livremente durante a execução de uma ação com a interface. Essa restrição ocorre porque assim é mais conveniente para estimar a velocidade de comunicação e o desempenho da BCI. Contudo, essa diferença de escopos entre os procedimentos de estudo e (o que deveriam ser) procedimentos fidedignos com as ações verdadeiras pode supostamente trazer dificuldades ao longo da transição dos resultados científicos para as aplicações reais.²⁷ A despeito disso, o protocolo de operação também leva a outra caracterização taxionômica usual: BCI síncrona, em que as decisões do indivíduo estão amarradas ao processamento da interface, e BCI assíncrona, em que as decisões do mesmo são tomadas, em princípio, a qualquer instante. Os primeiros protocolos a surgirem eram preferencialmente síncronos porque, dessa forma, eles simplificavam o processamento e a detecção de potenciais e ritmos cerebrais: entre uma miríade de evocações concorrentes, não é uma tarefa trivial decidir sobre a presença ou a ausência de manifestações específicas e, por isso, saber, por controle do protocolo, os momentos prováveis em que as mesmas poderiam ocorrer ajudava indubitavelmente a análise. Porém, como isso impunha fortes restrições às aplicações práticas, logo surgiram propostas de protocolos assíncronos que tornaram um pouco mais flexível a integração de BCIs com os controladores de dispositivos.

Enfim, com base na composição dessas três partes e na definição de um protocolo de operação, vários arranjos de interface cérebro-computador são possíveis. O diagrama da Figura 1.1 mostra o esquemático de uma BCI genérica. O funcionamento primordial desta depende simplesmente da existência de padrões encefálicos com o mínimo de regularidade. Esse pré-requisito é o que possibilita a programação de um computador para identificá-los e classificá-los de acordo com um procedimento estabelecido. Em geral, a atividade natural do cérebro apresenta dinâmica complexa e exhibe fenômenos com alto grau de variabilidade; contudo, ainda assim essa atividade tem algumas características passíveis de reconhecimento. As manifestações elétrico-encefálicas de um indivíduo, por exemplo, podem ser prontamente

registradas através de eletroencefalografia e posteriormente processadas para a extração de atributos associados às mesmas. Com o uso de EEG, especificamente, há três metodologias que, por se popularizarem entre os pesquisadores do ramo, merecem destaque: o paradigma dos ritmos sensório-motores, o paradigma do P300 e o paradigma dos potenciais evocados visualmente em regime estacionário.




Figura 1.1: Esquemático de uma BCI genérica.

1.2.1 SMR-BCI ou Imagística Motora

A possibilidade de gravação, por meio de eletrodos localizados no escalpo, de flutuações de potencial, originários no interior do cérebro, indica que um grande contingente neuronal deve se coadunar para a manifestação de descargas elétricas sincronizadas; pois, caso contrário, as fracas correntes associadas aos transientes sinápticos e aos potenciais de ação não desencadeariam sinais mensuráveis por transdutores externos. Essas descargas sincronizadas surgem como eventos pontuais, identificáveis por formas de onda efêmeras (um exemplo desse tipo será tratado na próxima seção), ou como padrões repetitivos que exibem certos comportamentos oscilatórios. Estes, em geral, provêm de populações de neurônios corticais que apresentam algum artifício de retroalimentação: ou por acoplamento entre condutâncias de membrana excitatória e inibitória de um mesmo neurônio ou por arquiteturas de redes compostas por interneurônios de inibição e conexões de realimentação. No primeiro caso, uma única célula isolada pode se tornar o precursor de comportamentos oscilatórios porque atua como uma espécie de marca-passo para a membrana de outras células e, no se-

gundo caso, as oscilações emergem, em conjunto, das próprias interconexões da rede neuronal. Na prática, não obstante, o que se observa, na maior parte das vezes, é a combinação desses dois mecanismos e não as suas manifestações isoladas.²⁸

Em particular, dois tipos de oscilação têm especial importância para o BCI baseado em Imagística Motora: o ritmo mu entre 8-13 Hz e o ritmo beta-central acima de 13 Hz, ambos provenientes dos córtices motor e somatossensorial primários: os eletrodos C3 e C4 são os mais indicados para registrar esses Ritmos Sensório-Motores (SMRs, do inglês *Sensorimotor Rhythms*). As atividades motora, sensorial e cognitiva geralmente alteram a dinâmica dessas duas ondas cerebrais, efeito perceptível por uma diminuição – Dessincronização Relacionada a Evento (ERD, do inglês *Event-Related Desynchronization*) – ou aumento – Sincronização Relacionada a Evento (ERS, do inglês *Event-Related Synchronization*) – de suas amplitudes.²⁹ Originalmente, essas alterações de potencial específicas foram ligadas com a organização prévia e subsequente realização de um movimento voluntário e cadenciado – como, por exemplo, a rápida (ou vagarosa) elevação dos dedos – e foram caracterizadas da seguinte forma: os ritmos mu e beta central dessincronizam durante a preparação e execução de uma ação motora coordenada; entretanto, a conduta dinâmica de cada um deles difere ao longo da evolução temporal; o ERD na banda alfa (10-12 Hz) inicia cerca de dois segundos e meio antes do começo do movimento, então atinge um ponto de mínimo em torno da ação e volta à linha de base poucos segundos depois; por outro lado, o ERD na banda beta (14-18 Hz) tem curta duração, ocorre bem próximo ao início do movimento e, logo após a ação, é sucedido por um ERS breve e repentino.³⁰

Essas duas oscilações também estão associadas ao ensaio mental de uma ação motora, a Imagística Motora (MI, do inglês *Motor Imagery*), que evidentemente não produz uma resposta muscular aparente. No entanto, é amplamente aceito que essa tarefa cognitiva abarca aproximadamente as mesmas regiões e funções cerebrais envolvidas com o planejamento e efetuação de movimentos, ou seja, de acordo com esse ponto de vista, a principal diferença entre a efetiva atuação e uma suposta representação por pensamento é que a última inclui um bloqueio cortical supressor do deslocamento em si.³¹ Logo, durante um experimento de imaginação de abrir e fechar a mão direita (ou esquerda), por exemplo, os ritmos mu e beta-central, registrados no hemisfério contralateral, apresentam dinâmica similar à experiência de preparação e execução do referido movimento: um acentuado e proeminente ERD na faixa alfa e um rápido ERD, seguido de um súbito ERS, na faixa beta. A despeito da semelhança, uma notável e importante distinção é que, ao longo da ação real, o ERD, inicialmente contralateral, desenvolve uma distribuição bilateral, enquanto, no caso da Imagística Motora, o ERD

se restringe, na maior parte das vezes, somente à região contralateral. Devido a essa diferença, as imaginações de movimento das mãos direita e esquerda funcionam como estratégias de treino para alcançar duas respostas eletro-corticais localizadas e para, a partir disso, empregar estas como opção de controle unidimensional.³² Esse é o método básico que fundamenta a SMR-BCI.³³

Em um ensaio típico para a discriminação de dois estados mentais, um usuário precisa imaginar os movimentos da mão direita ou esquerda, indicados por símbolos visuais exibidos em um monitor a poucos centímetros de distância do seu rosto. Cada sessão dura 8 segundos e inicia com a apresentação de um sinal de atenção (uma cruz no centro da tela, por exemplo) seguido de um ligeiro som de alerta. No terceiro segundo, o sinal de atenção é sobreposto por uma seta direcional (direita ou esquerda), a qual instrui para o indivíduo a tarefa mental que deve ser executada. Durante os cinco segundos restantes, enquanto este procede com a imagística motora, dois tipos de retorno motivacional lhe são comumente mostrados: ou as sinalizações +, – e 0, em diferentes tamanhos, expostas discretamente (em certos instantes) ou uma barra horizontal contínua, extensível e compressível para os dois lados. Ambas as formas de realimentação são dependentes da análise de quão bem os classificadores distinguem os dois padrões de EEG correlacionados aos respectivos comandos cerebrais. Normalmente, cada arranjo experimental consiste em quatro realizações de 40 sessões (20 para a direita e 20 para a esquerda) de 8 segundos e, por isso, leva em média uma hora. Tanto o sequenciamento destas (direita ou esquerda) quanto o período de descanso entre as mesmas são randomizados ao longo das repetições.³⁴ Esse procedimento descrito, com algumas adequações convenientes a cada realidade prática, tornou-se um guia para a elaboração de SMR-BCI; pois ele, de certa forma, sugere um método de treinamento destinado a pessoas que pretendem alcançar respostas eletro-corticais passíveis de identificação. Além desse protocolo, para atingir esse propósito, várias técnicas de processamento de sinais são obviamente necessárias para auxiliar no reconhecimento automático de padrões emergentes com o ensaio mental.

1.2.2 P300-BCI

Como visto no começo da seção anterior, o cérebro emite certas descargas elétricas sincronizadas, que se manifestam momentaneamente ou repetitivamente, mensuráveis por eletroencefalografia. Dentre estas – além das flutuações rítmicas mu e beta-central, reconhecidamente importantes para a Imagística Motora – destacam-se os pequenos potenciais cerebrais suscitados em concomitância com determinados eventos motores, sensoriais e cogniti-

vos. Esses Potenciais Relacionados a Eventos (ERPs, do inglês *Event-Related Potentials*) podem ser interpretados como reflexos de atividades neurais ressonantes associadas com transações informacionais do cérebro; pois, em geral, muito do que se conhece de ERPs se deve à identificação e estudo, com o uso de ensaios experimentais emprestados da psicologia cognitiva, de componentes ondulatórios eletro-encefálicos – que exprimem o funcionamento de estágios do processamento de informação tais como a codificação, a seleção, a memorização, a tomada de decisão, entre outros. Em específico, os ERPs ocasionados por estimulação sensorial são denominados Potenciais Evocados Sensorialmente (SEPs, do inglês *Sensory Evoked Potentials*) e, por reação da mesma, exibem os estados transitório e estacionário (um exemplo desse último será discutido no tópico subsequente). Os SEPs transitórios são convencionalmente descritos como picos positivos e negativos que se sucedem em tempos caracterizáveis a partir do início de uma incitação abrupta. Sumariamente, os picos que ocorrem antes dos primeiros 80 milissegundos, ditos elementos de latência curta, variam em função dos parâmetros do estímulo físico, são relativamente insensíveis a modificações nas demandas do processamento de informação e, devido a isso, são classificados como exógenos. Em contrapartida, alguns dos picos de latência longa só aparecem em conjunto com processos perceptuais e cognoscíveis e, por conta disso, são considerados endógenos.³⁵

Um dos componentes endógenos mais estudados é a onda P300, uma deflexão positiva no sinal de EEG, com latência de aproximadamente 300 milissegundos, procedente dos eletrodos medianos das regiões frontal, central e parietal (FCz, Cz e Pz) quando um indivíduo, ativamente engajado na identificação de um evento pré-estabelecido, detecta certo estímulo relevante e referente à tarefa. Um modo usual para a geração de P300 é o paradigma *Oddball*, no qual um voluntário tem que perceber uma estimulação ocasional e exclusiva entre uma sequência de várias outras incitações uniformizadas e intercaladas. Quando a discriminação do alvo se torna muito difícil, através da aceleração na concatenação dos estímulos, a amplitude dessa onda diminui e sua latência aumenta, como resposta à baixa convicção da pessoa em distingui-lo. Curiosamente, quando a mencionada tarefa se torna muito fácil, nesse caso por desaceleração, a mente pode se extraviar com distrações e, por conta disso, o mesmo efeito costuma ser presenciado. Entretanto, se for dada a devida atenção ao cumprimento das metas, a experiência mostra que a certeza na observação do evento e a conformação (amplitude e latência) do P300 se correlacionam de alguma forma.³⁶ A despeito disso, tanto a sua origem intracerebral quanto o seu papel para a cognição não são totalmente entendidos. Estudos sugerem que essa onda não se origina em uma única região e que talvez a mesma seja a união de atividades concorrentes oriundas de múltiplos sítios encefálicos, como as áreas de associação

dos lobos frontal, parietal e temporal. Já em relação a sua funcionalidade, a hipótese é de que ela esteja relacionada com processos de atualização de contexto e de posterior gravação em memória. Contudo, ambas as teorias ainda estão em debate, ou seja, não são plenamente consolidadas.³⁷

Embora, até o momento, não se tenha respondido uma série de questões importantes acerca do componente P300, a sua confiável detecção, em resposta a um estímulo, possibilita, por exemplo, a sua aplicação em sistemas de BCI para a produção textual. Com esse propósito, o seguinte arranjo experimental é tradicionalmente utilizado: as letras do alfabeto, juntamente com algarismos e a simbologia de operações pertinentes à escrita (espaçamento, correção de caractere, entre outras), são exibidas na tela de um computador, dispostas em uma matriz organizada similarmente a um teclado; as linhas e as colunas desta piscam repetidas vezes e de forma alternada, com o intuito de que cada célula matricial corresponda a um padrão de ERPs distinguível; um usuário, então, deve focalizar atenciosamente e sucessivamente no símbolo que ele deseja comunicar, o que leva à manifestação da onda P300 em instantes específicos. Porém, é quase impraticável identificar – numericamente ou visualmente – a presença dessa evocação em um período imediato a um evento isolado; pois os SEPs transitórios são substancialmente menores que o sinal de eletroencefalografia em curso; portanto, a sua detecção requer o uso de procedimentos de extração. O mais comum destes é a composição média de todas as sessões adquiridas ao longo de um experimento, que fornece uma imagem nítida do referido potencial por meio das superposições construtiva e destrutiva das respectivas deflexões evocada artificialmente e eletroencefalográfica natural; no entanto, essa técnica não é viável à comunicação porque não é exequível em velocidades aceitáveis a esse desígnio. Logo, no desenvolvimento de P300-BCI, a maior parte dos esforços se concentra na elaboração de métodos de processamento que utilizem um número mínimo de sessões conjuntas (de fato, o ideal seria apenas uma sessão) para a identificação fidedigna do componente P300 durante o registro contínuo de EEG.³⁸

1.2.3 SSVEP-BCI

De acordo com o tópico antecedente, os SEPs decorrem de estímulos sensoriais. Se estes forem de natureza visual, então se observa, em eletrodos da região occipital (principalmente O1, O2 e Oz), certos Potenciais Evocados Visualmente (VEPs, do inglês *Visually Evoked Potentials*). Há duas categorias principais de estimulação para a obtenção de VEPs: a luminosa e a padronizada. A primeira é usualmente gerada com feixes de luz oriundos de uma

fonte comum, enquanto a segunda é produzida com imagens de padrões reversos ou com figuras geométricas simples alternadas por um fundo difuso. Qualquer um desses meios possibilita tanto a confecção de estímulos periódicos quanto de estímulos repentinos.³⁹ Sucessivas incitações repentinas (impulsos isolados) originam VEPs transitórios porque são efetuadas em intervalos suficientemente longos nos quais o sistema visual recupera o seu estado inicial. Por outro lado, as incitações periódicas (sequências de impulsos) ocasionam VEPs estacionários porque são repetidas, com altas taxas de oscilação, antes que a resposta do impulso antecessor desapareça. Esses dois aspectos indicam que a estimulação repentina gradualmente se modifica em periódica ao longo de uma faixa de frequências de repetição: a menor taxa de estímulo para a geração de evocações estacionárias é aquela em que começa a entrecorrer sobreposições apreciáveis de duas evocações transitórias consecutivas. No caso de um sistema linear, as respostas transitória e estacionária apresentam uma relação de reciprocidade, ou seja, são apenas formulações alternativas de um mesmo fenômeno observável. Entretanto, a via ótica, tal como outras vias neurais, não obedece ao princípio da superposição (sequer aproximadamente) e, ao invés disso, regularmente apresenta vários tipos de comportamentos não lineares. Em princípio, portanto, os VEPs transitórios e os VEPs estacionários fornecem informações complementares sobre o sistema visual.⁴⁰

Em suma, os Potenciais Evocados Visualmente em Regime Estacionário (SSVEPs, do inglês *Steady-State VEPs*), por conta de que seus constituintes em frequências discretas permanecem aproximadamente inalterados durante amplos períodos, devem ser, por isso, discernidos dos VEPs transitórios. Contudo, essa característica razoavelmente estável não é destacada claramente pelo registro eletroencefalográfico bruto (no domínio do tempo), mas sim pela distribuição espectral desse sinal (no domínio da frequência). Os gráficos da Figura 1.2 exemplificam esse fato e sugerem que os SSVEPs podem ser idealmente entendidos como um conjunto de oscilações periódicas estacionárias, com suas correspondentes fases e amplitudes constantes, manifestado pelo sistema visual, enquanto este estiver excitado por estímulos periódicos uniformes, de modo que as frequências das evocações sejam as mesmas das incitações. Embora haja essa anuência em relação à descrição dos SSVEPs, a dinâmica de propagação cerebral deles não é consensual. Até o momento, há três teorias que foram propostas para explicá-la: (1) SSVEPs se originam no córtex visual primário (V1) e se difundem através da atividade combinada entre fontes distribuídas localmente e amplamente;⁴¹ (2) SSVEPs são gerados por um número finito de dipolos elétricos que se ativam sequencialmente por ao menos duas fontes localizadas nas regiões temporal-medial e occipital-medial dos hemisférios contralaterais;⁴² e (3) SSVEPs derivam de V1 e se espalham para outras áreas do

cérebro através de ondas denominadas viajantes e estacionárias – do original *travelling and standing waves*.⁴³ Essas teorias apresentam alguns aspectos em comum e, aparentemente, não se contradizem, pois a principal fonte de suas diferenças parece decorrer das perspectivas metodológicas de cada uma: (1) avalia a integração de observações tanto de EEG quanto de fMRI e PET; (2) leva mais em conta as evidências adquiridas com o fMRI e o PET; e (3) prioriza os resultados obtidos com o EEG.⁴⁴




Figura 1.2: Exemplos de SSVEPs em 10, 12 e 15 Hz. Os espectros foram extraídos de sinais (registrados em Oz) coletados com um voluntário saudável. A taxa de amostragem foi 256 Hz e as sessões duraram 12 segundos para cada estímulo.

Entre as diversas aplicações de SSVEPs se inclui o seu uso como paradigma de BCI, que suscita o conceito de SSVEP-BCI. A concepção geral deste é codificar as decisões de um usuário através de estímulos visuais oscilantes que induzem SSVEPs em diferentes frequências. Isso requer que o indivíduo escolha um comando por meio de olhar fixo na estimulação apropriada; e que o sistema, com a análise do sinal de EEG, identifique o potencial evocado e, com isso, infira o estímulo selecionado. Em um experimento clássico, por exemplo, um voluntário se senta confortavelmente diante de um monitor a 50 centímetros do rosto; a tela exibe um cursor controlável, ao centro, quatro blocos que piscam em frequências distintas, um em cada lateral para indicar as possíveis direções de movimento do mesmo, e um alvo localizado em algum dos cantos; quando a pessoa olha diretamente para um bloco, o SSVEP relacionado àquela frequência irrompe no córtex visual e é comumente gravado a partir dos

eletrodos O1, O2 e Oz; com a decomposição espectral do registro, as amplitudes das quatro componentes em frequência são, antes, comparadas com certos valores de limiar e, depois, comparadas entre si (isso é na verdade uma visão simplificada de um processamento bem mais complexo do que essa aparente comparação franca, embora esta também seja plausível); se a amplitude de um SSVEP excedeu seu limiar e é a maior entre as quatro possíveis, o bloco concernente é identificado e o cursor desloca um passo fixo na direção estipulada. Nesse tipo de controle, o voluntário, na maioria das vezes, tem um tempo máximo para atingir a meta, ou seja, ele precisa acertar uma sequência mínima de movimentos finitos. É importante notar que, para isso, tanto os comandos (estímulos) quanto o seus resultados devem se restringir ao campo visual do usuário.⁴⁵

1.2.4 Desempenho e Comparação de BCIs

Em relação à SMR-BCIs, o desempenho preliminar desses sistemas costuma apresentar a tendência evidenciada pelo estudo de campo relatado adiante. 324 visitantes, com idades entre oito e noventa anos, voluntariaram-se para um experimento de BCI que envolvia as imaginações das mãos direita e esquerda. Com aproximadamente 12% deles, depois de apenas 10 minutos de treino, as duas tarefas mentais foram corretamente distinguidas com precisão superior a 80%; 78% dos voluntários, por sua vez, obtiveram acurácias entre 60% e 80%; e somente com 10% destes não houve sucesso na discriminação dos comandos cerebrais. Os indivíduos com atuação regular (60-80%) usualmente aumentam seus índices após algumas sessões adicionais de treinamento e, por isso, também são, junto ao grupo de 12% com maior eficiência, considerados bons candidatos ao uso de SMR-BCIs. De acordo com o levantamento descrito, então, esse sistema possivelmente funciona bem com 90% da população. Porém, a investigação revela uma parcela de 10% sem qualquer predisposição para usá-lo, fato que ainda intriga os pesquisadores da área.⁴⁶ Outro estudo de campo com SMR-BCIs, realizado com 99 participantes, foi conduzido durante uma exposição em Graz (Áustria). Cada indivíduo gastou cerca de 20 a 30 minutos em duas sessões de BCI. A primeira consistiu em 40 tentativas sem qualquer realimentação visual. Já na segunda, um classificador foi configurado para proporcioná-la: novamente 40 tentativas, nesse caso, para o usuário controlar o movimento horizontal de uma barra exibida em um monitor. Nesse experimento, os voluntários foram instruídos a imaginar os movimentos da mão direita e dos pés. Depois das duas sessões, aproximadamente 93% dos participantes conseguiram um desempenho de classificação acima de 60% e apenas 7% deles obtiveram um resultado abaixo dos demais. Além disso,

19% atingiram marcas superiores a 80% de acerto.⁴⁷

Baseado nesses experimentos de imaginação de movimento, um procedimento similar foi replicado para testar o desempenho de P300-BCIs. Neste outro estudo de campo, de início, 100 voluntários, após cinco minutos de dedicação, usaram esse sistema de comunicação para soletrar a palavra 'WATER'. Para realizar o treino e a tarefa, os indivíduos tinham à disposição uma matriz com 36 caracteres em que duas versões do experimento foram praticadas: a cintilação de linhas e colunas inteiras ou o brilho de células isoladas. Depois, com algum desses dois arranjos de estímulos, cada usuário teve que preencher um formulário com as seguintes informações: nome, idade, sexo, escolaridade, horas de sono, horas de trabalho, consumo de cigarro e café e, por fim, nível de desconforto provocado pela intensidade luminosa. Dos 100 participantes, todos livres para decidirem que sistema utilizar, 81 conseguiram responder o questionário com o uso da estimulação por linhas e colunas e 38 foram capazes de respondê-lo com o uso da estimulação por células isoladas, em ambos os casos com 100% de sucesso. 19 deles testaram os dois arranjos de estímulos. Menos que 3% dos voluntários não conseguiram soletrar nenhum caractere corretamente. O resultado geral dessa avaliação revelou que, com aproximadamente cinco minutos de treino, um grande número de indivíduos saudáveis alcança taxas elevadas de acerto durante a soletração e também revelou que o desempenho obtido com o sistema em que as linhas e colunas piscam é superior ao com as células isoladas. 89% dos 81 indivíduos que usaram a forma de incitação mais eficaz soletraram corretamente com 80-90% de precisão ao longo da tarefa. Comparada às SMR-BCIs, em que somente 12% (no primeiro caso reportado) e 19% (no segundo) dos voluntários testados atingiram a mesma marca com, respectivamente, 10 e 30 minutos de treino, as P300-BCIs parecem apresentar uma eficiência significativamente maior.⁴⁸

Na mesma linha das propostas anteriores, também foi realizado um estudo de campo para avaliar o desempenho de SSVEP-BCIs frente à utilização de um grande número de usuários. 106 voluntários saudáveis foram recrutados durante uma exposição para esse teste. Cada um deles foi instruído a usar uma tela de digitação baseada em SSVEP-BCI para escrever cinco pequenas expressões, quatro das quais eram escolhidas pelo experimentador (BCI, SIREN, CHUG e BRAIN COMPUTER INTERFACE) e uma decidida livremente pelo usuário. As quatro primeiras eram sugeridas de forma randômica. Na sequência, antes de o participante soletrar a expressão pensada, ele devia dizê-la para o experimentador, para saber com que eficácia a mesma era soletrada. O sistema de seleção das letras funcionava a partir de cinco comandos que oscilavam nas frequências 13, 14, 15, 16 e 16,5 Hz. Em geral, todo o ensaio – entre preparação, treinamento e execução das tarefas – levava cerca de 40 minutos. A

taxa de acerto dos usuários ao usar esse SSVEP-BCI foi, em média, de 95%. Aproximadamente oito entre dez voluntários obtiveram desempenho igual ou superior a 85% e apenas um de vinte era incapaz de usar o sistema.⁴⁹ Como retratado nessa última pesquisa, a maioria dos sistemas baseados em SSVEPs usa estímulos entre 5 a 30 Hz, pois a amplitude da evocação é substancialmente maior dentro desse intervalo. Contudo, produzidas nessa faixa, as estimulações podem ser irritantes e cansativas para várias pessoas e, além disso, podem induzir crises epiléticas em indivíduos fotossensíveis – as frequências mais incitativas vão de 15 a 25 Hz, embora toda a faixa de 1 a 60 Hz seja considerada como possível causadora.⁵⁰ Uma abordagem verossímil para contornar esses infortúnios é a utilização de estímulos espectrais maiores que 30 Hz, pois isso diminui a fadiga e o risco de ataques epiléticos, uma vez que as oscilações de alta frequência são tenuamente visíveis ou praticamente imperceptíveis. Com esse viés, em outra conferência, 86 voluntários foram recrutados para avaliar o desempenho de um sistema SSVEP-BCI com tais características. Nesse caso, foi proposta a tarefa de guiar um robô em miniatura para fora de um labirinto. Para enviar os comandos direcionais, os usuários tinham à disposição quatro Diodos Emissores de Luz (LEDs, do inglês *Light Emitting Diodes*) que, em um primeiro teste, piscavam em frequências convencionais (13, 14, 15 e 16 Hz) e, em um segundo teste, piscavam em altas frequências (34, 36, 38 e 40 Hz). Os resultados indicaram que, com os estímulos da faixa espectral menor, 97% dos voluntários foram capazes de controlar o robô enquanto, com as estimulações do intervalo maior, somente 65% conseguiram realizar o mesmo feito. De certa forma, ficou evidente que a amplitude de evocação tende a decrescer com o aumento da taxa de oscilação dos LEDs e que, por isso, parecem ser mais eficientes as SSVEP-BCIs projetadas com as frequências abaixo de 30 Hz.⁵¹

Como a maioria das investigações científicas, as pesquisas com BCIs relatadas focaram primeiramente na validação dos sistemas por meio de evidências conceituais, a partir de testes com voluntários saudáveis, antes de promover qualquer futura avaliação com pacientes debilitados. Isso não significa que certas informações pertinentes já não sejam extraídas e estendidas para os casos mais gerais. Por exemplo, idealmente, uma BCI deveria funcionar com qualquer usuário; no entanto, isso não é o que esses estudos sugerem. Ao contrário disso, eles indicam a existência de uma margem populacional que não é capaz de utilizar as interfaces cérebro-computador e, embora nenhuma pesquisa de campo tenha sido feita com pacientes, é bem razoável a reprodução qualitativa desse fato para os casos em que os indivíduos tenham alguma deficiência, mesmo que em termos numéricos as estimativas possam ser diferentes. Enfim, independentemente das idiosincrasias de cada grupo testado, é sempre provável a existência de uma minoria de indivíduos que nunca alcance o controle de suas respostas

corticais porque possivelmente os mesmos não manifestam a atividade cerebral necessária para isso. Esse fenômeno é conhecido como “analfabetismo em BCI” – do original *BCI illiteracy*. Embora todos os seres humanos apresentem estruturas encefálicas similares, aproximadamente em regiões iguais e com subdivisões funcionais muito parecidas, há variações individuais na organização do cérebro. Ou seja, para certos voluntários, durante os testes vistos com BCIs baseadas em técnicas eletroencefalográficas, os circuitos neuronais necessários para gerar o sinal de comunicação podem simplesmente não ter produzido potenciais e ritmos elétricos que fossem detectáveis do escalpo. Isso não ocorreu por causa de eventuais disfunções do sistema nervoso; a questão é que tais manifestações elétrico-encefálicas, para alguns usuários em particular, podem não ser mensuráveis porque a população de neurônios que os suscita esteja localizada em sulcos ou sítios profundos do córtex, longe do alcance dos eletrodos, ou (igualmente possível) muito próximo de corpos neuronais mais ativos. Além dessa diferença estrutural do cérebro, outras razões verossímeis associadas ao mencionado analfabetismo são o excesso de artefatos musculares, que prejudica consideravelmente o processamento, a extração e a classificação de sinais cerebrais, e, por fim, mas não menos concebível, o mau entendimento das instruções de como proceder com a interface.⁵²

Apesar da existência dessa categoria de pessoas incapazes de usar determinadas BCIs, esses sistemas de comunicação e controle estão cada vez mais ganhando espaço no cenário científico. Em especial, dentre os três paradigmas abordados (SMRs, P300 e SSVEPs), o último é o único que não requisita o esforço de se concentrar em uma tarefa mental, como a imagística motora ou a expectativa de eventos. Em geral, a fixação do olhar em um estímulo repetitivo e a posterior identificação do potencial evocado visualmente em regime estacionário são condições suficientes para a geração de um sinal para controlar uma máquina. Logo, um sistema elaborado a partir desse método não envolveria, em princípio, muito tempo de treinamento e também, se comparado aos moldes da MI e do P300, não exigiria um elevado empenho do usuário. Talvez, por isso, a SSVEP-BCI, até o presente momento, seja uma das BCIs mais promissoras para projetar aplicações práticas e, dessa forma, seja uma primeira escolha natural para quem se propõe à construção de uma interface cérebro-computador apenas para enviar comandos simples.⁵³

1.3 DESENVOLVIMENTO DE BCIs

Há determinados tipos de mudanças técnicas que podem ser caracterizadas como revoluções tecnológicas capazes de influenciar, de forma pervasiva, as esferas social e eco-

nômica. Tais mudanças não dão origem somente a uma nova gama de produtos, ramos industriais e serviços; elas dão início, sim, a um novo modelo técnico-econômico que altera especialmente a vida cotidiana da população (o setor de energia elétrica, por exemplo, teve esse impacto).⁵⁴ Em geral, esse reconhecimento tecnológico só fica evidente com o passar do tempo e com a aceitação dos desdobramentos advindos do paradigma em ascensão. Por outro lado, não é possível prever a importância de uma tecnologia (supostamente) promissora. Em tempos de globalização, conjectura-se apenas que as mudanças técnicas revolucionárias, se aceitas, difundam-se amplamente pela sociedade e provoquem ajustes estruturais em esfera global. Nesse caso, não se trataria de simples melhorias incrementais em trajetórias tecnológicas já bem estabelecidas, mas de ruptura com o presente.⁵⁵ As interfaces cérebro-computador, do ponto de vista conceitual, enquadram-se, de certa maneira, nessa perspectiva de potencial revolução tecnológica. Desde sua concepção, na década de 70, a BCI pouco a pouco tem se mostrado como uma tecnologia inovadora (em formação) e apresenta capacidade de trilhar trajetórias tecnológicas distintas e de alcançar uma gama diversificada de produtos e serviços até então não conhecidos (apenas idealizados). Como abordado em seções anteriores, há várias pesquisas com BCIs para disponibilizar soluções nas áreas de aplicação clínica e de entretenimento, bem como no ramo de comunicação em geral. Além disso, supõe-se que, se difundidas socioeconomicamente, essas interfaces possam estabelecer uma forma de interação com o ambiente (diferente de tudo o que se conhece até o momento) e que elas possam, por conta disso, promover consideráveis transformações no modo de vida da população. No entanto, vale ressaltar que esse horizonte de eventos não deixa de ser uma aposta.

Nos últimos anos, em particular, as BCIs atraíram a visibilidade de um público não científico, o que deposita nelas uma expectativa ainda maior (e muitas vezes desmedida) em relação aos seus resultados futuros. De certa forma, isso ocorreu porque elas fazem parte da grande área de neurociência e neurotecnologia e esta, por sua vez, despertou o interesse da mídia porque vem recebendo grandes investimentos para fornecer novas explicações, soluções e tecnologias acerca de um objeto de estudo extremamente desafiante e misterioso: o cérebro. A União Europeia, por exemplo, lançou, em 2013, o programa *Human Brain Project* no valor de 1,9 de bilhões de euros para financiar, durante 10 anos, estudos sobre o cérebro;⁵⁶ em 2014, os Estados Unidos da América, outro exemplo, também anunciaram o programa de pesquisa *BRAIN Initiative* cujo valor estimado atingirá, em 12 anos, o montante de 4,5 bilhões de dólares.⁵⁷ Em escala regional, a FAPESP, último exemplo, como já dito na “Introdução”, comprometeu-se, em 2013, em fornecer para o projeto BRAINN cerca de 4 milhões de reais por ano ao longo de uma década.⁵⁸ Assim, em conjunto com os diversos projetos temáticos

dentro dessa grande área, o desenvolvimento de BCIs se tornou um ramo de estudo privilegiado (em termos de recursos financeiros disponíveis).

Evidentemente, esses financiamentos são válidos e se justificam devido à crença de que o acesso a determinados conhecimentos técnicos representa uma vantagem estratégica para as nações que os detêm. Esse domínio geralmente engendra produtos de alta tecnologia que depois fornecem matérias-primas ou insumos tecnológicos intermediários essenciais para muitos bens de capital e de consumo finais. Logo, o desenvolvimento científico pode, sim, dar origem a um novo setor estratégico com ampla participação na economia de um país.⁵⁹ Diante disso, o presente estudo também se justifica pela importância de se dominar algum conhecimento técnico para produção de tecnologias de BCIs, nesse caso, realizado por capital humano brasileiro e dentro das fronteiras nacionais. O desenvolvimento de BCIs ainda não está economicamente instaurado, ou seja, não existe uma indústria e uma cadeia produtiva plenamente difundida e consolidada por detrás dele (diferente, por exemplo, dos circuitos integrados). Por conta disso, é perfeitamente viável adentrá-lo. Supõe-se que, após uma estabilização de mercado com produtos e serviços ligados às BCIs, fique bem mais difícil para os países subdesenvolvidos que não investirem, depois, tentarem competir com os países já estabelecidos, uma vez que estes costumam proteger as suas empresas com barreiras de entrada aos potenciais entrantes.⁶⁰ Assim, como essa tecnologia ainda está, sobretudo, em fase de pesquisa, têm-se condições, enquanto Estado Nacional, de se investir em capital humano para o desenvolvimento de BCIs, de se preparar para a futura concorrência com os mercados externos, de se usufruir dos benefícios relacionados ao domínio de processos de inovação, e, enfim, de se produzir soluções próprias ao invés de importá-las e ficar subjugado às decisões de países imperialistas.⁶¹ É por tais razões que o desenvolvimento de programas de BCI, como os expostos adiante, também não deixa de ser um reflexo de motivações políticas e econômicas.

1.3.1 BCI2000 e OpenViBE

O BCI2000 é um programa computacional flexível destinado à pesquisa e ao desenvolvimento de interfaces cérebro-computador. Ele foi inicialmente criado, no ano 2000, por um projeto que integrava o Centro Wadsworth do Departamento de Saúde do Estado de Nova Iorque (Albany, EUA) e o Instituto de Psicologia Médica e Neurobiologia Comportamental da Universidade de Tübingen (Tübingen, Alemanha). Outras instituições, entre as quais se destacam o BrainLab da Universidade do Estado da Geórgia (Atlanta, EUA) e a Fundação Santa Lúcia (Roma, Itália), também contribuíram para a sua elaboração. O projeto do

BCI2000 tinha três objetivos centrais: conceber um sistema que facilitasse a implementação de qualquer BCI; fornecer suporte para os métodos comumente usados na área; e distribuir o programa e a sua documentação para outros laboratórios. Com o cumprimento dessas três metas, os idealizadores dessa plataforma pretendiam reduzir o tempo, o esforço e o custo dos testes de novas interfaces e, além disso, prover uma padronização de dados para a comparação de análises. Ambos os fatores, então, facilitariam o progresso das pesquisas, principalmente em centros com pouca experiência em programação de BCIs. Atualmente, o BCI2000 está gratuitamente disponível para propósitos educacionais e científicos sem fins lucrativos (<http://www.schalklab.org/research/bci2000>) e vários laboratórios ao redor do planeta o utilizam.⁶²

O BCI2000 é baseado em um modelo geral que permite a configuração de qualquer BCI e, para isso, apresenta quatro módulos que se comunicam entre si: a fonte (para aquisição e armazenamento de dados), o processamento de sinais, a aplicação do usuário e a interface de operação. A comunicação entre esses módulos utiliza protocolos genéricos que transmitem as informações necessárias para a operação. Esses sinais que trafegam de um módulo para o outro são padronizados para minimizar a dependência entre eles. Cada função é alocada em um módulo de forma logicamente consistente. Por exemplo, como cada ciclo de processamento é iniciado pela aquisição de um bloco de dados, a fonte destes age como um relógio para o sistema. De forma similar, como a realimentação varia de acordo com a aplicação, ela pertence ao módulo de aplicação do usuário. Esses princípios contribuem para certa permutabilidade e, ao mesmo tempo, independência entre os módulos. Em geral, os quatro não apresentam restrições quanto às configurações no número de canais ou taxa de amostragem, ao número de parâmetros do sistema, aos sinalizadores de eventos, à complexidade do sinal que controla os dispositivos de saída ou qualquer outro parâmetro. O único fator de escala que restringe o processamento é a própria capacidade da máquina que roda o programa. Evidentemente, o BCI2000 apresenta um modo de processamento *online* que responde de forma apropriada em um curto período (milissegundos). Contudo ele também apresenta ferramentas de análise *offline* para dados armazenados. O objetivo desse tipo de programa é oferecer, de forma prática, métodos para trabalhar com BCI sem a necessidade de especialização em programação e sem grande custo de equipamento. Por fim, os desenvolvedores, de tempos em tempo, fornecem uma atualização do código fonte e uma vasta documentação.⁶³

O OpenViBE, tal como o BCI2000, é uma plataforma computacional feita para a criação, o teste e a utilização de interfaces cérebro-computador. No entanto, diferentemente do outro, ele é de código aberto e livre. Ele resultou de um projeto, iniciado em 2005, para incentivar as pesquisas de BCIs na França, praticamente inexistentes nesse país até aquele

momento. Financiado pela Agência Francesa de Pesquisa (ANR, do francês *Agence Nationale de la Recherche*) e desenvolvido em parceria pelo Instituto Francês de Pesquisas em Ciência da Computação e em Automação (Inria, do francês *Institut National de Recherche en Informatique et en Automatique*) e pelo Instituto Francês de Saúde e Pesquisa Médica (Inserm, do francês *Institut National de la Santé et de la Recherche Médicale*), o projeto OpenViBE combinou a expertise de pesquisadores com conhecimentos técnicos principalmente em neurociência e em ciência da computação e, cinco anos após seu início, forneceu o primeiro protótipo inteiramente funcional. Atualmente, existem quatro aplicações dominantes elaboradas para o uso do OpenViBE. Três delas envolvem ambientes virtuais e jogos de computador: um usuário, por meio de comandos eletroencefalográficos, é capaz de pilotar uma espaçonave, de jogar handball, ou de se movimentar em um cenário fictício. A quarta delas, destinada a fornecer suporte de comunicação para pessoas com mobilidade reduzida, propicia às mesmas uma ferramenta de escrita.⁶⁴

O OpenViBE consiste de um conjunto de módulos programáveis que podem ser eficientemente integrados para desenvolver BCIs com a finalidade de comunicação e controle em ambientes reais ou virtuais. A sua principal característica é a modularidade, ou seja, ele é basicamente uma plataforma de módulos de programas voltados para a aquisição, o pré-processamento, o processamento e a visualização de dados cerebrais, bem como a interação com monitores em realidade virtual. Como o OpenViBE é um programa de propósito geral, isso implica que os usuários podem facilmente adicionar seus próprios códigos de acordo com suas necessidades. Em comparação com outros programas de BCI, a plataforma do OpenViBE aparenta ser altamente modulável, satisfaz diferentes tipos de usuários (sejam eles programadores ou não) e fornece uma interface gráfica amigável conveniente ao desenvolvimento daqueles que não estão familiarizados com linguagens de programação, enquanto as outras plataformas, por outro lado, requerem algum conhecimento básico em computação para desenvolver uma nova interface desde o princípio. O OpenViBE também propõe automaticamente cenários de comunicação *online* a partir da análise de configurações de processamento *offline*. Finalmente, outra característica peculiar desse programa é apresentar um conjunto de ferramentas integradas para o desenvolvimento de ambientes de simulação virtual e para a criação de realimentação visual.⁶⁵

1.3.2 MATLAB e BioSig

O MATLAB[®] é uma linguagem de programação em alto nível disponível em con-

junto com uma plataforma para visualização, programação e computação numéricas. Ele fornece uma forma eficiente de analisar dados, desenvolver algoritmos e criar modelos e aplicações. O MATLAB já vem com uma série de funções matemáticas construídas (para álgebra linear, estatísticas, integração numérica, solução de equações diferenciais, otimização, análise de Fourier etc.), o que facilita e acelera o desenvolvimento de soluções. Ele é conveniente para desenvolver e testar projetos das áreas de processamento de sinais e comunicações, processamento de vídeo e imagem, sistemas de controle, sistemas para medição e teste de grandezas físicas, matemática financeira e biologia computacional, entre outras. O MATLAB é uma plataforma popular entre engenheiros e cientistas tanto na indústria quanto na academia devido a sua praticidade.⁶⁶ Uma das características mais atrativas dele é a facilidade no computado e tratamento matricial de dados, vantajoso para quem trabalha com grande volume de processamento. Além disso, o MATLAB pode ser customizado com uma gama de funções a partir da instalação de caixas de ferramentas (*toolboxes*) específicas. A caixa de ferramenta para processamento de sinais, por exemplo, fornece funções e aplicativos voltados para gerar, medir, transformar, filtrar e visualizar sinais. Ela é útil para analisar e comparar sinais no tempo e na frequência, identificar padrões e tendências, extrair atributos e desenvolver e validar algoritmos personalizados para tais fins.⁶⁷ Existem várias caixas de ferramenta, além da exemplificada, customizadas para sistemas de comunicação, computação paralela, aquisição de dados e assim por diante. Além dessas caixas de ferramentas, algumas empresas também fornecem pequenas Interfaces de Programação de Aplicação (APIs, *Application Programming Interfaces*) com aplicativos e funções prontas para configurar e controlar produtos como amplificadores, processadores etc.

Devido a essa flexibilidade, já existem sistemas de suporte a elaboração de BCIs projetados para usufruir do ambiente de desenvolvimento disponibilizado pelo MATLAB. O BioSig, por exemplo, é uma biblioteca computacional de código aberto destinada ao processamento de sinais biomédicos. Em conjunto com outras áreas de aplicação, ele também foi criado para auxiliar pesquisas em BCI. O BioSig suporta diferentes formatos de entrada, possibilita o tratamento de artefatos, fornece métodos de processamento adaptativo e de extração de características, inclui variadas técnicas de classificação e tem ferramentas para lidar com ausência de dados ou erros de gravação. Seu projeto teve início como uma biblioteca de MATLAB, mas com o intuito de logo torná-lo compatível com GNU Octave – uma linguagem de programação de alto nível voltada, sobretudo, para computação numérica.⁶⁸ Com o advento de outros subprojetos relacionados – como o rtsBCI, o SigViewer e o BioProFeed, entre outros – foi necessário então discriminá-lo e ele recebeu o nome “BioSig para Octave e MATLAB”.⁶⁹

1.3.3 SSVEP-BCI em MATLAB

Para realizar o presente estudo, o MATLAB foi a plataforma de desenvolvimento escolhida por conta da (1) sua reconhecida capacidade de cômputo matricial e (2) sua flexibilidade de criação algorítmica para o processamento digital de sinais, ambas qualidades desejáveis à concepção da BCI. Como o escopo central deste projeto foi o desenvolvimento de uma interface cérebro-computador baseada no paradigma de SSVEPs, esse sistema de comunicação, somente através do processamento digital dos registros eletroencefalográficos, devia, tão logo a aquisição ocorresse, intermediar a intenção de um usuário, manifestada pelo seu direcionamento visual em certo estímulo, e a execução de uma tarefa de controle. Embora já existissem programas computacionais que ofereciam essa solução, como o BCI2000 e o OpenViBE (vistos em tópicos anteriores), o desenvolvimento próprio, além de ter possibilitado um profundo estudo das etapas e estratégias envolvidas na criação de uma BCI, ofereceu também uma plataforma conveniente e flexível para futuras pesquisas relacionadas ao processamento digital de sinais de EEG, algo que as interfaces existentes, preocupadas principalmente com a aplicação voltada aos sistemas de comunicação e controle, nem sempre priorizam.

Como a interface cérebro-computador reuniu dois propósitos distintos, a comunicação alternativa (para futura aplicação em um sistema de navegação de uma cadeira de rodas) e a pesquisa em processamento de sinais, os módulos delineados para o desenvolvimento do sistema atendem a essas duas funções. Embora a exposição detalhada desses módulos seja o assunto do capítulo três, segue adiante, de forma simplificada, uma breve descrição deles.

- a) **Estimulação:** módulo responsável por criar uma janela de exibição dos estímulos periódicos, de acordo com certas configurações pré-estabelecidas.
- b) **Aquisição:** módulo dedicado à captura e ao armazenamento dos dados eletroencefalográficos diretamente em MATLAB.
- c) **Processamento:** módulo que executa o processamento de sinais, que extrai, destes, determinadas características convenientes e que, posteriormente, formata-as para auxiliar a execução dos módulos de treinamento e classificação.
- d) **Treinamento:** módulo que realiza a seleção das (supostas) melhores características e que projeta, com estas, um classificador de estímulos.
- e) **Comunicação e Controle:** módulo que realiza a classificação de novas entradas e que gera um sinal de controle para ser enviado para uma aplicação.

Por fim, a integração do sistema – ou seja, a organização desses módulos em um sequenciamento funcional de acordo com um protocolo de operação bem definido – e os re-

sultados de testes realizados com o mesmo estão a cargo das últimas seções do referido capítulo. Na sequência, discorre-se sobre os fundamentos conceituais e técnicos básicos para o desenvolvimento de interface cérebro-computador baseada em SSVEPs.

- ¹ Anton Nijholt, Desney Tan. Brain-computer interfacing for intelligent systems. *IEEE Intelligent Systems*, v. 23, n. 3, p. 76-77, 2008.
- ² Lewis P. Rowland, Neil A. Shneider. Amyotrophic lateral sclerosis. *New England Journal of Medicine*, v. 344, n. 22, p. 1688-1691, 2001.
- ³ John W. Macdonald, Cristina Sadowsky. Spinal-cord injury. *The Lancet*, v. 359, n. 1, p. 417-418, 2002.
- ⁴ Ruth Bonita. Epidemiology of stroke. *The Lancet*, v. 339, n. 8789, p. 342, 1992.
- ⁵ Geoffrey A. Donnan et al. Stroke. *The Lancet*, v. 371, n. 9624, p. 1612-1614, 2008.
- ⁶ Gerhard Bauer, Franz Gerstenbrand, Erik Rimpl. Varieties of the locked-in syndrome. *Journal of Neurology*, v. 221, n. 2, p. 87, 1979.
- ⁷ Eimear Smith, Mark Delargy. Locked-in syndrome. *British Medical Journal*, v. 330, n. 7488, p. 406-407, 2005.
- ⁸ Gerhard Bauer, Franz Gerstenbrand, Erik Rimpl. Op. cit., p. 77-78, 1979.
- ⁹ Niels Birbaumer. Breaking the silence: brain-computer interfaces (BCI) for communication and motor control. *Psychophysiology*, v. 43, n. 6, p. 524-525, 2006.
- ¹⁰ Jonathan R. Wolpaw et al. BCI meeting 2005 - workshop on signals and recording methods. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 14, n. 2, p. 138, 2006.
- ¹¹ Joseph N. Mak, Jonathan R. Wolpaw. Clinical applications of brain-computer interfaces: current state and future prospects. *IEEE Reviews in Biomedical Engineering*, v. 2, n. 1, p. 192, 2009.
- ¹² Janis J. Daly, Jonathan R. Wolpaw. Brain-computer interfaces in neurological rehabilitation. *The Lancet Neurology*, v. 7, n. 11, p. 1032, 1038-1040, 2008.
- ¹³ Mitchell P. LaPlante, Gerry E. Hendershot, Abigail J. Moss. Assistive technology devices and home accessibility features: prevalence, payment, need, and trends. *Advance Data from Vital and Health Statistics*, v. 217, n. 1, p. 1-2, 1992.
- ¹⁴ Lista das definições da ISO 9999:2007. *Catálogo Nacional de Produtos de Tecnologia Assistiva*. Disponível em: <<http://assistiva.mct.gov.br/lista-das-definicoes-da-iso-9999-2007>>. Acesso em: 05 maio 2015.
- ¹⁵ José del R. Millán et al. Combining brain-computer interfaces and assistive technologies: state-of-the-art and challenges. *Frontiers in Neuroscience*, v. 4, n. 1, p. 5-6, 2010.
- ¹⁶ Claudia Zickler et al. A brain-computer interface as input channel for a standard assistive technology software. *Clinical EEG and Neuroscience*, v. 42, n. 4, p. 236-237, 2011.
- ¹⁷ Febo Cincotti et al. Non-invasive brain-computer interface system: towards its application as assistive technology. *Brain research bulletin*, v. 75, n. 6, p. 796-797, 2008.
- ¹⁸ Ferran Galán et al. A brain-actuated wheelchair: asynchronous and non-invasive brain-computer interfaces for continuous control of robots. *Clinical Neurophysiology*, v. 119, n. 9, p. 2161-2162, 2008.
- ¹⁹ Robert Leeb et al. Self-paced (asynchronous) BCI control of a wheelchair in virtual environments: a case study with a tetraplegic. *Computational intelligence and neuroscience*, p. 1-2, 2007.
- ²⁰ Claude Ghez, John Krakauer. The Organization of Movement. In: Eric R. Kandel, James H. Schwartz, Thomas M. Jessell. *Principles of Neural Science*. 4. ed. New York: McGraw-Hill, 2000. p. 656-657, 666.
- ²¹ Jonathan R. Wolpaw et al. Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, v. 113, n. 6, p. 769-770, 2002.
- ²² Jonathan R. Wolpaw et al. Op. cit., p. 769, 2002.
- ²³ Jonathan R. Wolpaw et al. Op. cit., p. 770, 2002.
- ²⁴ Andrea Kübler, Klaus-Robert Müller. An introduction to brain-computer interfacing. In: Guido Dornhege et al. *Toward Brain-Computer Interfacing*. 1. ed. Cambridge: The MIT Press, 2007. p. 8-9.
- ²⁵ Guido Dornhege et al. General signal processing and machine learning tools for BCI analysis. In: Guido Dornhege et al. *Toward Brain-Computer Interfacing*. 1. ed. Cambridge: The MIT Press, 2007. p. 207-208.
- ²⁶ Jonathan R. Wolpaw et al. Op. cit., p. 772, 2002.
- ²⁷ Jonathan R. Wolpaw et al. Op. cit., p. 772, 2002.
- ²⁸ Wolf Singer. Synchronization of cortical activity and its putative role. *Annual Review of Physiology*, v. 55, n. 1, p. 350-352, 1993.
- ²⁹ Gert Pfurtscheller, Fernando H. Lopes Da Silva. Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, v. 110, n. 11, p. 1842-1843, 1999.
- ³⁰ Gert Pfurtscheller, Christa Neuper. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, v. 89, n. 7, p. 1124, 2001.
- ³¹ Marc Jeannerod. Mental imagery in the motor context. *Neuropsychologia*, v. 33, n. 11, p. 1422-1425, 1995.
- ³² Gert Pfurtscheller, Christa Neuper. Motor imagery activates primary sensorimotor area in humans. *Neurosci-*

ence Letters, v. 239, n. 2, p. 65-68, 1997.

³³ Gert Pfurtscheller, Christa Neuper. Op. cit., p. 1124-1126, 2001.

³⁴ Gert Pfurtscheller, Christa Neuper. Op. cit., p. 1126-1127, 2001.

³⁵ Steven A. Hillyard, Marta Kutas. Electrophysiology of cognitive processing. *Annual Review of Psychology*, v. 34, n. 1, p. 33-35, 1983.

³⁶ Terence W. Picton. The P300 wave of the human event-related potential. *Journal of Clinical Neurophysiology*, v. 9, n. 4, p. 456-457, 1992.

³⁷ John Polich. Updating P300: an integrative theory of P3a and P3b. *Clinical Neurophysiology*, v. 118, n. 10, p. 2137-2138, 2007.

³⁸ Lawrence A. Farwell, Emanuel Donchin. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology*, v. 70, n. 6, p. 512-515, 1988.

³⁹ J. Vernon Odom et al. Visual evoked potentials standard (2004). *Documenta Ophthalmologica*, v. 108, n. 2, p. 116-118, 2004.

⁴⁰ David Regan. Comparison of transient and steady-state methods. *Annals of the New York Academy of Sciences*, v. 338, n. 1, p. 45, 1980.

⁴¹ Ramesh Srinivasan, F. Alouani Bibi, Paul L. Nunez. Steady-state visual evoked potentials: distributed local sources and wave-like dynamics are sensitive to flicker frequency. *Brain Topography*, v. 18, n. 3, p. 182-185, 2006.

⁴² Francesco Di Russo et al. Spatiotemporal analysis of the cortical sources of the steady-state visual evoked potential. *Human Brain Mapping*, v. 28, n. 4, p. 323-334, 2007.

⁴³ Guy R. Burkitt et al. Steady-state visual evoked potentials and travelling waves. *Clinical Neurophysiology*, v. 111, n. 2, p. 246-258, 2000.

⁴⁴ Vialatte François-Benoît et al. Steady-state visually evoked potentials: focus on essential paradigms and future perspectives. *Progress in Neurobiology*, v. 90, n. 4, p. 420-425, 2010.

⁴⁵ Ming Cheng, Shangkai Gao. An EEG-based cursor control system. Proceedings of The First Joint BMES/EMBS Conference. Atlanta: IEEE. 1999. p. 669.

⁴⁶ Gert Pfurtscheller, Christa Neuper. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, v. 89, n. 7, p. 1123-1134, 2001.

⁴⁷ Christoph Guger et al. How many people are able to operate an EEG-based brain-computer interface (BCI)? *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 11, n. 2, p. 145-147, 2003.

⁴⁸ Christoph Guger et al. How many people are able to control a P300-based brain-computer interface (BCI)? *Neuroscience Letters*, v. 462, n. 1, p. 94-98, 2009.

⁴⁹ Brendan Z. Allison et al. How many (and what kinds of) people can use an SSVEP BCI? *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 18, n. 2, p. 107-116, 2010.

⁵⁰ Robert S. Fisher et al. Photic-and pattern-induced seizures: a review for the Epilepsy Foundation of America Working Group. *Epilepsia*, v. 46, n. 9, p. 1426-1441, 2005.

⁵¹ Ivan Volosyak et al. BCI demographics II: how many (and what kinds of) people can use a high-frequency SSVEP BCI? *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 19, n. 3, p. 232-239, 2011.

⁵² Brendan Z. Allison, Christa Neuper. Could anyone use a BCI? In: Desney S. Tan, Anton Nijholt. *Brain-computer interfaces*. 1. ed. London: Springer, 2010. p. 35-54.

⁵³ Yijun Wang et al. Brain-computer interfaces based on visual evoked potentials. *IEEE Engineering in Medicine and Biology Magazine*, v. 27, n. 5, p. 64-71, 2008.

⁵⁴ Cristiane V. Rauern. *Mudanças técnicas e políticas públicas: experiências internacionais na difusão da banda larga e o caso brasileiro*. Tese (Doutorado em Teoria Econômica). Instituto de Economia. Universidade Estadual de Campinas. Campinas. 2013. p. 20.

⁵⁵ Chris Freeman, Luc Soete. *A Economia da Inovação Industrial*. 1. ed. Campinas: Unicamp, 2008. p. 614-625.

⁵⁶ Human Brain Project. *Wikipedia, the free encyclopedia*. Disponível em: <https://en.wikipedia.org/wiki/Human_Brain_Project>. Acesso em: 04 jan. 2016.

⁵⁷ BRAIN Initiative. *Wikipedia, the free encyclopedia*. Disponível em: <https://en.wikipedia.org/wiki/BRAIN_Initiative>. Acesso em: 04 jan. 2016.

⁵⁸ Instituto de Pesquisa sobre Neurociências e Neurotecnologia. *CEPID Centros de Pesquisa, Inovação e Difusão*. Disponível em: <<http://cepid.fapesp.br/centro/11/>>. Acesso em: 21 abr. 2015.

⁵⁹ Chris Freeman, Luc Soete. *A Economia da Inovação Industrial*. 1. ed. Campinas: Unicamp, 2008. p. 587.

⁶⁰ Joe S. Bain. *Barriers to New Competition*. 1. ed. Cambridge: Harvard University Press, 1956. p. 3-10.

⁶¹ Vladimir Lenin. *Imperialismo: fase superior do Capitalismo*. 4. ed. São Paulo: Global, 1987. p. 42-45.

⁶² Jürgen Mellinger, Gerwin Schalk. BCI2000: a general-purpose software platform for BCI research. In: Guido Dornhege et al. *Toward Brain-Computer Interfacing*. 1. ed. Cambridge: The MIT Press, 2007. p. 359-368.

⁶³ Gerwin Schalk et al. BCI2000: A General-Purpose Brain-Computer. *IEEE Transactions on Biomedical Engineering*, v. 51, n. 6, p. 1034-1043, 2004.

⁶⁴ OpenViBE: The first French software programme enabling "action through thought". *Inria Inventors for the Digital World*, 2009. Disponível em: <<https://www.inria.fr/en/news/mediacentre/openvibe>>. Acesso em: 18 maio 2015.

⁶⁵ Yann Renard et al. OpenViBE: An Open-Source Software Platform to Design, Test and Use Brain-Computer Interfaces in Real and Virtual Environments. *Presence: Teleoperators and Virtual Environments*, v. 19, n. 1, p. 35-56, 2010.

⁶⁶ MATLAB Product Description. *MathWorks®*. Disponível em: <http://www.mathworks.com/help/matlab/learn_matlab/product-description.html>. Acesso em: 04 jun. 2015.

⁶⁷ Signal Processing Toolbox. *MathWorks®*. Disponível em: <<http://www.mathworks.com/help/signal/index.html>>. Acesso em: 15 jun. 2015.

⁶⁸ About GNU Octave. *GNU Octave*. Disponível em: <<https://www.gnu.org/software/octave/about.html>>. Acesso em: 02 ago. 2015.

⁶⁹ Alois Schlögl et al. BioSig: an open-source software library for bci research. In: Guido Dornhege et al. *Toward Brain-Computer Interfacing*. 1. ed. Cambridge: The MIT Press, 2007. p. 347-358.

2 ESTIMULAÇÃO, AQUISIÇÃO E PROCESSAMENTO DE SSVEPs

[...] segundo parece, quer *um* seja, quer não seja, tanto ele mesmo quanto as outras coisas, tanto em relação a si mesmos quanto em relação uns aos outros, todos totalmente tanto são quanto não são, e tanto parecem quanto não parecem ser.¹

Uma SSVEP-BCI, para realizar a transdução de informações cerebrais em comandos de máquina, requer a geração e a aquisição dos referidos potenciais evocados e uma série de preparações e transformações dos mesmos, ou seja, demanda processamento dos sinais. Fazem parte desse conjunto de procedimentos a remoção de artefatos, a extração de características, a seleção de atributos, a classificação e a validação, abordagens que não são exclusivas do desenvolvimento de interfaces cérebro-computador, ou seja, são provenientes de um ramo científico abrangente conhecido como reconhecimento de padrões e aprendizagem de máquina. Esses métodos podem ser empregados em um contexto conhecido como aprendizado supervisionado, em geral dividido em etapa de treinamento e etapa de identificação. Na primeira, normalmente nas fases iniciais da aquisição, dispõe-se de dados rotulados para configurar um classificador e, na segunda, requisita-se deste o reconhecimento de novos dados adquiridos. Esse é o cerne da estratégia escolhida para o desenvolvimento da BCI e, portanto, alguns entendimentos conceituais dessa área favorecem a compreensão necessária para isso.

O primeiro deles, que é fundante, mas (filosoficamente) complexo, é o próprio conceito de padrão, inerente a qualquer experiência. De maneira simples e direta, pode-se dizer que um padrão é uma regularidade abstrata e discernível na natureza (ontológica) ou nas criações humanas. Mas, para isso, os elementos de um padrão devem supostamente se repetir de forma previsível e incitar ao menos um dos cinco sentidos. De acordo com esse ponto de vista, a observação sensível é que leva à percepção de padrões que estão amplamente distribuídos pelo mundo. Exemplos deles, encontrados naturalmente ou artificialmente, incluem fractais, espirais, meandros, ondas, espumas, tesselações, fissuras, aqueles formados por simetrias de rotação e reflexão, entre vários outros. No entanto, pode-se argumentar que (em grande parte) os padrões abstratos nas ciências, nas artes e na matemática são observados somente por intermédio de análise (por vezes minuciosa) porque, nesses casos, eles se apresentam de forma caótica, sutil ou não exatamente regular.² Esses padrões costumam possuir estruturas matemáticas subjacentes e, às vezes, só por meio destas aparentam possuir regularidades. Nesse sentido, funções matemáticas poderiam ser utilizadas para se verificar a existência (ou

ausência) deles.³ Em reconhecimento de padrões, uma função com tais características recebe o nome especial de classificador, a qual, devido a sua importância para os propósitos desse estudo, será estudada em detalhes na seção 2.5. Por outro lado, a concepção de padrão suscita outra ideia (não menos complexa): o conceito de emergência. Também de maneira simples e direta, pode-se dizer que uma emergência é uma propriedade nova que surge de um sistema (uma entidade), quando este (esta) atinge certo nível de complexidade, e que, apesar de ela existir apenas na medida em que o sistema (a entidade) existe, distingue-se fundamentalmente das propriedades elementares deste (desta).⁴ Contudo, essas conceituações (reduções) não são tão simples e diretas assim, porque “padrão” e “emergência” são termos usados com diferentes acepções, tanto na ciência quanto na filosofia, e de forma alguma é o objetivo deste trabalho levantá-las e estudá-las em profundidade. No fim, o como eles devem ser aceitos não deixa de ser uma questão de finalidade em si mesma, ou seja, neste contexto, as noções sugeridas são meramente convenientes para que se possa interpretar a SSVEP-BCI da seguinte forma: um sistema capaz de identificar padrões cerebrais que emergem de estimulações com padrões visuais repetitivos.

2.1 GERAÇÃO DE SSVEPs

A experiência mostra que os potenciais evocados gravados por meio de eletroencefalografia irrompem em distintas áreas corticais como consequência de estimulações tácteis, sonoras, olfativas ou visuais, as quais, se devidamente controladas, viabilizam o estudo dos mesmos. Os estímulos tácteis – como leves toques nas unhas ou nos dedos, vibrações na superfície da pele, ligeiras marteladas no tendão patelar, entre outros – dão origem a potenciais no córtex somatossensorial. Na maioria dos indivíduos, essas respostas eletro-encefálicas são observadas, de maneira contralateral, nos eletrodos C3 e C4.⁵ Já os estímulos sonoros – como intermitentes estalidos de microssegundos ou disparos tonais de milissegundos, ambos emitidos por meio de fones de ouvido – suscitam potenciais de latência curta, média e longa, distribuídos por diferentes localizações do escalpo. Os componentes tardios, por exemplo, apresentam amplitude máxima nas regiões central e frontal, principalmente sob Cz, FCz e Fz.⁶ Por sua vez, os estímulos olfativos podem ser exalados em fluxos constantes de ar, o que evita a estimulação indesejada de receptores mecânicos e térmicos enquanto concentrações graduais de elementos odoríferos são mantidas. Artífícios desse tipo possibilitam a verificação de características essenciais dos potenciais evocados quimicamente e das suas disposições corticais, a averiguação de atividade elétrico-neural associada à habituação aos odores e a compa-

ração da relação entre a dosagem e a resposta de substâncias odorantes.⁷ Em geral, essas três primeiras formas de incitação são empregadas, sobretudo, em estudos eletrofisiológicos do cérebro ou em investigações de doenças neurológicas.

A quarta opção de estímulo também é utilizada com essas finalidades, pois os VEPs têm a capacidade de prover informações diagnósticas importantes a respeito da integridade funcional do sistema visual humano, bem como sugerir indícios sobre o funcionamento do mesmo. Inclusive, como forma de sistematizar e guiar essas pesquisas, a Sociedade Internacional de Eletrofisiologia Visual Clínica (ISCEV, do inglês *International Society for Clinical Electrophysiology of Vision*) prepara, de tempos em tempos, um documento com protocolos padrão para testes com potenciais evocados visualmente. Entre as principais recomendações estão o arranjo de eletrodos, três meios para realizar a estimulação e, para cada um destes, os procedimentos experimentais adequados e as prováveis manifestações cerebrais relacionadas. Essa espécie de regulamentação, entretanto, dirige-se principalmente aos estudos mencionados e só abrange a categoria de VEPs transitórios.⁸ Por outro lado, esses potenciais, como abordado durante a explanação introdutória e em seções do primeiro capítulo, igualmente fornecem a uma pessoa, desde que esta tenha o controle de seu movimento ocular, a autonomia necessária à tentativa de exteriorização de suas intenções sem a utilização das vias tradicionais – autossuficiência indispensável para o uso deles em projetos de BCIs. Ou seja, os VEPs asseguram a exposição simultânea (alternativa) e, ao mesmo tempo, possibilitam a arbitrária fixação do olhar (escolha), o que os qualifica como canais de comunicação factíveis. Contudo, diferentemente das referidas investigações clássicas, no caso das VEPs-BCIs, não existe uma indicação procedimental explícita para o emprego deles em tais sistemas. Geralmente, os protocolos e estímulos são propostos de acordo com as sugestões da literatura científica, o conhecimento empírico e o bom senso dos pesquisadores. Em relação aos VEPs transitórios, parte do que já foi estabelecido pela ISCEV pode ser adaptado e rearranjado para a realidade das BCIs baseadas nestes; porém, em relação aos SSVEPs, não há, excetuando a própria experiência acumulada, uma formalização protocolar que recomende padronizações à geração desses potenciais, nem para as análises clínicas e fisiológicas nem para as aplicações de comunicação e controle.

Relembrando, há duas maneiras básicas para produzir estimulação de VEPs: a luminosa, criada com dispositivos emissores de luz direcional, e a padronizada, criada com a exibição de imagens de padrões reversos ou figuras geométricas simples.⁹ Ambas podem ser geradas abruptamente ou periodicamente: o primeiro caso origina os potenciais transitórios enquanto o segundo ocasiona os SSVEPs. Para BCIs baseadas nestes, cada comando está li-

gado a um Estímulo Visual Repetitivo (RVS, do inglês *Repetitive Visual Stimuli*), que em si apresenta uma série de propriedades configuráveis: frequência, fase, intensidade do brilho, coloração, conformação, entre outras. Quando um indivíduo focaliza a visão em um RVS com uma determinada taxa de repetição, o respectivo SSVEP surge no sinal de EEG – especialmente em eletrodos da região occipital – como um componente oscilatório com a mesma frequência fundamental e com os demais harmônicos. De forma ampla, os potenciais evocados visualmente em regime estacionário são detectados na faixa de 1 a 100 Hz, embora com precisões distintas. Entre uma série de configurações que leva a esses diferentes desempenhos está a própria natureza dos RVSS. Não obstante, a escolha desses estímulos deve ser cautelosa para melhor segurança e conforto do usuário, pois um fulgor excessivo certamente causará fadiga nele ou pode até mesmo afetar o seu sistema visual. Apesar de requerer esses cuidados, a confecção de RVSS adequados ainda é superficialmente tratada na maioria das publicações sobre SSVEP-BCI e, além disso, carece de uma standardização precípua para auxiliar as pesquisas e para estabelecer uma base comparativa entre estas. O único fato consensual é que, por análise da vasta literatura, três categorias de estímulos se popularizaram: os luminosos, as figuras simples e os padrões reversos.¹⁰

2.1.1 Estímulos Luminosos, Figuras Simples e Padrões Reversos

Os estímulos luminosos são comumente elaborados a partir de Diodos Emissores de Luz (LEDs, do inglês *Light Emitting Diodes*), lâmpadas fluorescentes ou lâmpadas de xenônio, todos eles aparatos de irradiação controlados por circuitos eletrônicos dedicados. Estes, por sua vez, frequentemente restringem o número de plataformas de desenvolvimento e inevitavelmente provocam interferência eletromagnética quando não adequadamente blindados (a desvantagem desse último aspecto será tratada na seção posterior). Além disso, a intensidade luminosa de tais dispositivos deve ser cuidadosamente monitorada para evitar a rápida fadiga do olho. Em contrapartida, justamente porque funciona com sistemas dedicados, esse tipo de estimulação é bem flexível quanto à reprodução de sequências de iluminação. Os LEDs, por exemplo, podem ser acionados por geradores de formas de onda capazes de modular sinais em um vasto leque de frequências. Assim, em aplicações práticas que requerem muitos comandos (e, portanto, incitações diferentes), os RVSS luminosos são preferencialmente empregados.¹¹ A Figura 2.1 mostra um exemplo de interface para estimulação de SSVEPs montada com um circuito eletrônico que controla as frequências específicas de quatro LEDs, um em cada canto de um monitor.



Figura 2.1: Exemplo de interface montada com quatro LEDs para estimulação de SSVEPs.¹²




Figura 2.2: Exemplos de estampas para composição de estímulos padronizados.

Já as figuras simples são estímulos confeccionados com delineações geométricas (retângulos, quadrados, círculos ou setas) uniformemente preenchidas por uma única cor e exibidos em uma tela de computador, de modo que a visualização seja sucessivamente trocada com o plano de fundo. De forma similar, os padrões reversos são estímulos apresentados em um monitor; contudo, estes são criados com estampas contrárias de alto contraste (tabuleiro de xadrez ou listras alternadas) que oscilam entre si, como exemplificadas na Figura 2.2 acima. Ambos os RVSS padronizados tem limitações quanto às frequências possíveis, pois estas estão condicionadas à taxa de atualização do monitor, ou seja, ao número de vezes que o controlador de tela imprime as imagens armazenadas na memória temporária. Os monitores de LCD (do inglês *Liquid Crystal Display* – Tela de Cristal Líquido), por exemplo, apresentam

taxa usual de 60 Hz; isso implica que somente atingem precisão confiável as incitações periódicas em submúltiplos inteiros desse valor, enquanto, para as demais faixas espectrais, não há qualquer garantia de estimulação. Mesmo para essas frequências supostamente exatas, existe uma dificuldade adicional: o agendamento de tarefas da maioria dos sistemas operacionais pode causar atrasos imprevisíveis na temporização dos estímulos se estes não forem programados com linguagens de baixo nível. Por outro lado, do ponto de vista da implementação de uma SSVEP-BCI, desde que esta necessite de poucos comandos, é preferível utilizar RVSS padronizados porque os códigos fontes que os geram costumam integrar o corpo da função principal, sem precisar de equipamentos suplementares. Isso facilita o contato entre a interface de estimulação e uma eventual aplicação prática, pois ambas podem intercambiar informações de modo direto e, a partir destas, realizar modificações em seus estados. Além disso, a opção pelas figuras simples ou pelos padrões reversos evita certos problemas com interferentes, pois os monitores já oferecem uma blindagem eletromagnética conveniente.¹³

Como observado anteriormente, existem ganhos e prejuízos associados a cada um dos estímulos visuais repetitivos. Dentre todos, ponderar pelo mais adequado é, na verdade, optar por certas restrições inevitáveis que não inviabilizem os propósitos gerais do experimento ou projeto, uma vez que todos os RVSS apresentam algum inconveniente e, ainda assim, desde que periodizados com exatidão, suscitam SSVEPs na região occipital. Para o uso em pesquisas, os RVSS são distinguidos em três bandas de frequência: a baixa (1-12 Hz), a média (12-30 Hz) e a alta (30-60 Hz). As maiores amplitudes de SSVEPs costumam ser observadas próximas de 10 Hz e entre 16-18 Hz, enquanto as menores amplitudes geralmente são presenciadas acima de 30 Hz. Por isso, muitas SSVEP-BCIs utilizam as bandas baixa e média, embora as frequências variem entre os estudos. No entanto, como já visto na seção 1.2.4, essas duas faixas apresentam algumas desvantagens: de acordo com a avaliação de usuários, frequências entre 5-25 Hz tendem a ser mais irritantes e cansativas; em indivíduos fotossensíveis, tanto os RVSS luminosos quanto os padronizados podem provocar crises epiléticas, especialmente os que vão de 15 a 25 Hz; e, além de tudo, as frequências baixas abrangem a banda alfa (8-13 Hz), que pode ocasionar um volume considerável de falsos positivos devido a manifestações cerebrais súbitas. Em princípio, essas dificuldades são evitadas com o uso das frequências elevadas. A despeito da evocação mais fraca, a banda alta exhibe menor atividade encefálica espontânea e a relação sinal-ruído de seus SSVEPs (estimada como a razão entre as potências espectrais evocadas e as potências médias das respectivas faixas adjacentes) é similar às bandas baixa e média. Mas para o seu uso efetivo em interfaces cérebro-computador, as técnicas de processamento precisam ser aprimoradas para evidenciar os potenciais contidos

nela. Por enquanto, os estudos relatam que essa faixa é promissora, porém ainda menos confiável, se comparada com as outras.¹⁴

Um último aspecto importante a respeito de RVSs é a coloração deles, que está ligada, por sua vez, à visão fotópica: sensibilidade do olho em condições luminosas que admitem a percepção das cores. Em luminosidades moderada e elevada, esse tipo de visão, mediada pelas células cones, é o principal contribuinte ao aparecimento de potenciais evocados visualmente, enquanto em luminosidade baixa, a visão escotópica (noturna), mediada pelas células bastonete, é o principal contribuinte.¹⁵ Como as BCIs são projetadas para funcionar em ambientes claros, a coloração dos estímulos visuais se torna uma característica importante para se investigar. Foi reportado, por exemplo, que incitações com luz vermelha, amarela e azul provocam efeitos distintos nos SSVEPs. Luz vermelha, quando modulada em 11 Hz, suscita a resposta mais forte, mas esta decai bruscamente nas frequências contíguas. Embora menor que a anterior, a luz azul também apresenta uma reação máxima, em torno de 13 Hz nesse caso, e um declínio nas demais faixas. A luz amarela, por outro lado, parece evocar de forma mais fraca igualmente ao longo de todo o espectro.¹⁶ Entretanto, ainda não há estudos conclusivos sobre como RVSs de diversas colorações influenciam a intensidade da evocação e o desempenho de SSVEP-BCIs e estudos sobre como os mesmos se relacionam com a visão fotópica. Devido a essas lacunas, é difícil decidir pela melhor configuração de cores.¹⁷

2.2 REGISTRO DE SINAIS ENCEFÁLICOS

As técnicas de aquisição de sinais biológicos dependem das características biofísicas e bioquímicas do tecido em observação. Mesmo se tais características fossem todas bem conhecidas e estudadas, devido à enorme complexidade dos sistemas vivos, ainda assim seria pouco provável que existisse um único aparelho que as monitorasse simultaneamente. Em geral, cada equipamento, portanto, explora apenas algumas propriedades que fornecem vestígios sobre a atividade natural do tecido em análise. Assim, em relação ao sistema nervoso central, os procedimentos de medição usuais apresentam exatamente essa mesma limitação. A Imagem de Ressonância Magnética Funcional, ou *Functional Magnetic Resonance Image* (fMRI), por exemplo, é uma técnica que aproveita as propriedades magnéticas distintas da oxihemoglobina (diamagnética) e da desoxihemoglobina (paramagnética) para obter um contraste Dependente do Nível de Oxigenação Sanguínea, ou *Blood Oxygenation Level-Dependent* (BOLD), que permite monitorar, em organismos vivos, alterações na concentração de oxigênio do sangue no decurso de condições fisiológicas normais. Isso viabiliza o mapea-

mento de regiões cerebrais supostamente ativas.¹⁸ Outro exemplo, a Espectroscopia de Infravermelho Próximo, ou *Near Infrared Spectroscopy* (NIRS), afere, em tecidos biológicos, a absorbância da luz para vários comprimentos de onda na faixa espectral de 700-1000 nm. Essa medida, como a fMRI, mesmo que por características biofísicas diferentes, também possibilita a avaliação de modificações hemodinâmicas no tecido nervoso durante a estimulação de funções neurológicas.¹⁹ E, além de fMRI e NIRS, como visto no capítulo 1, existem outras técnicas (MEG, PET) que, cada uma à sua maneira, proporcionam os seus vislumbres sobre o sistema nervoso (sem a necessidade de procedimentos invasivos) e, por isso, são todas consideradas poderosas ferramentas de investigação científica. Contudo, o método de aquisição comumente utilizado em aplicações de BCI é a eletroencefalografia porque esta é a que (atualmente) melhor atende os principais requisitos para integrar um sistema de comunicação: praticidade, portabilidade e taxa de amostragem conveniente.

2.2.1 Eletroencefalografia

O Sistema Nervoso Central (SNC) é essencialmente formado por células neuronais (neurônios) e células gliais (neuróglia), de modo que as primeiras se conectam entre si por sinapses e assim engendram uma intrincada rede para a propagação de sinais eletroquímicos, enquanto as segundas estabelecem uma espécie de tecido de preenchimento que acomoda e supre essa rede.²⁰ De certa forma, essas duas estruturas contribuem para a manifestação de potenciais de campo extracelulares detectáveis através de eletroencefalografia. Por um lado, todos os neurônios apresentam uma separação de cargas entre os meios intracelular e extracelular e, devido a isso, suas membranas mantêm um potencial de repouso por volta de 60 e 70 mV, com polaridade negativa no interior da célula.²¹ Esse potencial de membrana está sujeito a flutuações (hiperpolarização ou despolarização) desencadeadas por um elaborado mecanismo controlado por fluxos iônicos (K^+ , Na^+ , Ca^{2+} , Cl^-) e, quando estas ultrapassam certo limiar, as células neuronais disparam um potencial de ação que se propaga ao longo do axônio até atingir os terminais sinápticos. Nestes, esse sinal eletroquímico causa uma reação que libera, na fenda sináptica, neurotransmissores que se difundem e se conectam em receptores localizados nos dendritos (ou corpos celulares) de outros neurônios.²² A depender dos neurotransmissores e receptores envolvidos nesse processo, tem origem um Potencial Pós-Sináptico Excitatório (EPSP, do inglês *Excitatory Postsynaptic Potential*) ou um Potencial Pós-Sináptico Inibitório (IPSP, do inglês *Inhibitory Postsynaptic Potential*). No decurso de vários potenciais de ação, os decorrentes EPSPs e IPSPs se tornam os principais geradores de poten-

ciais de campo extracelulares.²³ Por outro lado, as neuróglia não apresentam potenciais de ação e, em consequência, não suscitam EPSPs e IPSPs. Contudo, as células gliais igualmente mantêm um potencial de repouso e este também está sujeito a flutuações. Por exemplo, um aumento na concentração de K^+ no meio extracelular causado por neurônios próximos leva à despolarização das células gliais no entorno deles. Se essa concentração cresce localmente, então gradientes de potencial se estabelecem ao longo dessas neuróglia e, por sua vez, ocasionam variações de corrente iônica parecidas com as dos neurônios. A partir desse artifício, potenciais de campo podem se desenvolver porque as células da glia formam um amplo tecido com propriedades bioquímicas e biofísicas similares. Enfim, estruturalmente, se em parte os neurônios estão associados à geração de potenciais de campo extracelulares, é provável que as neuróglia sejam as responsáveis por um efeito de amplificação dos mesmos.²⁴

De forma abrangente, a manifestação elétrica observada e registrada com eletroencefalografia é uma medida atenuada de fluxos de corrente extracelulares provenientes da soma da atividade de muitos neurônios. Porém, nem todas as células neuronais constituem igualmente o sinal de EEG; de fato, este é formado principalmente por neurônios corticais na vizinhança dos eletrodos, ou seja, estruturas encefálicas profundas como o hipocampo, o tálamo e o tronco encefálico não contribuem diretamente. Mais especificamente, os grandes responsáveis por esse sinal são as células piramidais: os principais neurônios de projeção no córtex cerebral. Seus dendritos apicais, localizados próximos à superfície cortical, recebem uma grande variedade de ligações sinápticas, que são as principais fontes de atividade elétrica da qual deriva o sinal de EEG. Para entender (de forma simplificada) como essa estrutura contribui para essa geração, considere o fluxo de corrente oriundo de um EPSP no dendrito apical de um desses neurônios piramidais. Na vizinhança do sítio de geração do EPSP, essa corrente, por meio de sorvedouros e vertedouros na membrana neuronal, estabelece um circuito fechado, entre os meios intracelular e extracelular, que obedece (aproximadamente) à lei de Ohm. Como a resistência da membrana é bem maior que as resistências das soluções iônicas (interna e externa), uma diferença de potencial se instaura entre esses meios. Para um eletrodo posicionado na parte superior da cabeça, a depender da proximidade dele com o sorvedouro ou o vertedouro de corrente, essa voltagem contribui para a conformação de uma deflexão positiva ou negativa no sinal de EEG. De forma similar, um IPSP também cria um circuito fechado (no sentido inverso ao do EPSP) e uma diferença de potencial (embora de valor contrário) detectável. Curiosamente, de acordo com a profundidade das sinapses desses dendritos apicais, o EPSP e o IPSP podem originar voltagens (externamente) idênticas. Logo, não há como distinguir se um potencial cortical ocorre devido a um EPSP em camadas corticais mais pro-

fundas ou a um IPSP em camadas corticais mais superficiais, ou seja, eventos sinápticos no córtex não podem ser determinados, de forma inequívoca, somente através de eletroencefalografia.²⁵ Apesar disso, a distribuição de eletrodos no escalpo (surpreendentemente) possibilita a identificação de atividades cerebrais associadas a grandes volumes de neurônios e isso, por sua vez, já trás informações pertinentes para a elaboração de BCIs.

Como visto na “Introdução”, a primeira recomendação para o posicionamento dos eletrodos, denominada sistema 10-20, foi proposta, em 1958, por um comitê da Federação Internacional das Sociedades de Eletroencefalografia e Neurofisiologia Clínica com o intuito de padronizar as aquisições e permitir a comparação entre as pesquisas laboratoriais. Esse sistema evitava a colocação de eletrodos em pontos arbitrários uma vez que ele especificava marcos anatômicos longitudinais e laterais a partir dos quais certos comprimento deveriam ser inicialmente estabelecidos e, por conseguinte, ele determinava cada posição em função de tamanhos percentuais (10% ou 20%) dessas distâncias referenciais.²⁶ Desde então, uma variedade de outras disposições tem sido utilizada como forma de acrescentar eletrodos. Em 1991, a Sociedade Americana de EEG inclusive sugeriu uma nomenclatura combinatória para a adição deles.²⁷ Novos eletrodos então foram alocados nos pontos médios entre as localizações tradicionais. Essa nova recomendação, em conjunto com o padrão 10-20, deu origem ao posicionamento conhecido como sistema 10% (10-10) ou 10-20 estendido, que, de tempos em tempos, ainda passa por ligeiras modificações.²⁸ A padronização dos pontos de fixação de eletrodos, por sua vez, limita (o que em eletroencefalografia se convencionou denominar) a montagem (o arranjo em si) – assunto que será discutido em detalhe no capítulo 3. No momento, apenas convém salientar que o registro cerebral é disponibilizado, de fato, a partir da sua escolha – em geral relacionada às particularidades de cada estudo.

Depois de adquirido, embora se assemelhe (às vezes) mais a um ruído branco do que a alguma atividade elétrica do córtex, o registro eletroencefalográfico indica a tensão (representada por um valor de amplitude) em função do tempo. O sinal (originalmente) cortical tem que atravessar as leptomeninges, o líquido cefalorraquidiano, a dura-máter, o osso, a gálea e, por fim, o escalpo para só depois atingir os eletrodos – percurso que o atenua fortemente. Por exemplo, descargas eletrocortográficas apresentam amplitudes de 500-1.500 μV e vários transientes pontiagudos (*spikes*) proeminentes. Já as amplitudes do EEG (medidas de pico a pico), por sua vez, são marcadamente reduzidas e se situam entre 10 e 100 μV – na maior parte das vezes entre 10 e 50 μV em adultos saudáveis. Esse sinal de EEG (no domínio do tempo) pode ser transformado em um espectro, que se revela amplo e informativo, porém não uma simples mistura de frequências. Parece existir alguma organização rítmica associada

a ondas com amplitudes e comprimentos específicos. No entanto, a aparente existência de ritmos predominantes não indica atividade normal – alguns deles podem significar anormalidade – e, por outro lado, uma aparência completamente difusa, à primeira vista, não implica em anormalidade. “Reatividade” pode ser a designação mais adequada em tais situações. Um registro de frequência mista pode ser bastante sensível a certos estímulos. Geralmente, a curva da resposta espectral de um aparelho de EEG concentra-se na gama de 0,1 a 100 Hz. Mais especificamente, convencionou-se em dividir as frequências nas seguintes bandas: delta (0,1-3,5 Hz); teta (4-7,5 Hz); alfa (8-13 Hz); beta (14-30 Hz); gama (acima de 30 Hz). Essa nomenclatura de letras gregas não representa um sequenciamento lógico e só tem significado mesmo do ponto de vista histórico. Os termos “ritmo alfa” e “ritmo beta” foram introduzidos por Berger (1929); o “ritmo gama” foi posteriormente usado por Jasper e Andrews (1938) para designar oscilações de frequências acima de 30 ou 35 Hz; o termo “ritmo delta” foi introduzido por Walter (1936) para designar todas as oscilações de frequências abaixo da faixa alfa e, posteriormente, o mesmo Walter achou necessário introduzir uma designação especial para as frequências delta de 4 a 7,5 Hz e, para isso, utilizou a letra teta.²⁹

Os primeiros aparelhos de EEG eram predominantemente analógicos. Hoje em dia, todos eles vêm equipados com conversores analógico-digitais (ADC, do inglês *analog-to-digital converter*). Esses conversores transformam os sinais contínuos em sequências de tempo discreto, ou seja, amostram os registros dos eletrodos a uma taxa fixa. O uso de ADC pressupõe alguns cuidados para evitar distorções de sinal. Uma delas, conhecida como *aliasing*, ocorre quando as taxas de amostragem são muito baixas. A frequência mais alta que se deseja representar digitalmente – chamada frequência (ou limite) de Nyquist – deve ser inferior à metade da taxa de amostragem. Se sinais com frequências mais elevadas (do que essa barreira impõe) forem digitalizados, eles ficam representados por frequências (abaixo do limite) completamente falsas. O *aliasing* é crítico porque, embora ele seja causado por frequências subamostradas, as baixas oscilações também são distorcidas e impregnadas pelas falsas e porque, uma vez presente no sinal, não pode mais ser removido. Além da possibilidade de *aliasing*, sinais subamostrados não representam com precisão as formas de ondas analógicas. Quando estas são importantes para alguma análise em particular, o sinal de EEG é tradicionalmente amostrado pelo menos a oito ou dez vezes a frequência mais elevada do componente de interesse. Mesmo que essa taxa de amostragem deva ser suficientemente alta para preservar as formas de onda desejadas, ela, no entanto, deve ser escolhida de maneira a não sobrecarregar o computador desnecessariamente. Como o crânio atenua a atividade de frequências superiores a 40 Hz, as taxas de amostragem entre 200 a 400 Hz costumam ser suficientes para a gra-

vação extracraniana. Assim, os aparelhos de EEG comerciais apresentam taxa de 256 Hz, embora alguns deles tenham valores adicionais da ordem de quilohertz. Os ADCs geralmente funcionam (de forma rápida e fixa) a partir de um único núcleo de processamento, que digitaliza sequencialmente as medidas dos eletrodos. Quando muitos destes estão sujeitos à amostragem em série, isso acarreta um atraso temporal. Em um sistema de EEG com 32 canais, por exemplo, um evento que ocorreu simultaneamente nos eletrodos 1 e 32 seria exibido com um certo deslocamento de amostras entre eles. A maioria dos sistemas digitais, para superar essa ligeira defasagem, utiliza um circuito que amostra e retém (*sample and hold*) as informações de cada canal por um instante mínimo. Com isso, embora as amostras sejam adquiridas em série, elas são simultaneamente entregues a todos os canais, o que então assegura análises comparativas no domínio do tempo.³⁰

Em suma, a eletroencefalografia monitora, com eletrodos afixados no escalpo, flutuações de tensão resultantes de circuitos de corrente iônica (devido à excitação sináptica) em dendritos de vários neurônios piramidais (localizados em diferentes camadas do córtex). Isso, de certa forma, também confere a essa técnica ao menos duas desvantagens: a baixa resolução espacial e a atenuação do sinal original. No entanto, com uma taxa de amostragem em geral acima de 256 Hz, a técnica apresenta acurácia suficiente ao desenvolvimento de sistemas que precisam detectar, em intervalos de tempo curtos, a presença de potenciais evocados (muitas vezes em frequências de no máximo 30 Hz). Além disso, o EEG – diferentemente, por exemplo, da Eletrocorticografia, que necessita de trepanação e dissecação anatômica – coleta dados de maneira não invasiva, ou seja, sem requerer intervenção cirúrgica. Diante desse quadro, portanto, ele é um aparelho adequado à elaboração de uma interface cérebro-computador.

2.3 REMOÇÃO DE ARTEFATOS

Os dados brutos, adquiridos com a eletroencefalografia, estão impregnados de artefatos. Estes podem ser categorizados de duas formas, os extrínsecos e os intrínsecos. Os artefatos do primeiro tipo são as partes do registro compostas por excesso de informações não provenientes do cérebro, logo, de origem externa. A maioria desses interferentes está associada a problemas com os eletrodos – pois se estiverem quebrados ou inadequadamente anexados à cabeça eles apresentam impedâncias muito altas – ou com os dispositivos elétricos ao redor – sobretudo os que estão aterrados no mesmo circuito que o amplificador de EEG. Os ruídos eletromagnéticos, por excelência, são os causados pela própria rede de energia elétrica (em 60Hz, no Brasil) e pelas capacitâncias parasitas presentes na mesma. Em geral, os demais

interferentes externos têm origem fisiológica. Os mais comuns são os cardíacos e os oculográficos. Do primeiro tipo, o complexo QRS, relacionado à despolarização ventricular, é a deflexão do sinal de eletrocardiografia (ECG) que mais interfere no registro de EEG (embora não seja a única). Já do segundo tipo, o movimento vertical do olho é o que demanda a maior preocupação e, talvez por isso mesmo, é o causador de artefatos melhor documentado. Evidentemente, os pequenos deslocamentos de membros e articulações e a contração (seguida de relaxação) da musculatura facial também podem provocar distúrbios eletroencefalográficos.³¹

Além dessa mistura de sinais não desejados, a medida de EEG em si apresenta baixa resolução espacial, ou seja, não há como distinguir com precisão a localização da atividade neuronal, apenas há como atribuir o manifesto da mesma a regiões corticais compostas por um grande número de neurônios. Dessa forma, os dados brutos também estão incorporados de artefatos intrínsecos: as partes do registro constituídas por excesso de informações de origem encefálica, mas que não são de interesse para alguma análise em particular. Para a identificação de SSVEPs pertencentes à banda alfa, como visto em seções anteriores, a variação energética dessa mesma faixa (observada subitamente ou durante a alternância de exposição fótica) representa uma espécie de ruído interno. De forma geral, ambas as formas de interferência (extrínsecas ou intrínsecas) levam a problemas de análise porque os sinais de interesse (sejam SEPs ou SMRs) são muito fracos em comparação com elas. Os artefatos são frequentemente identificáveis por causa da alta tensão que eles apresentam e, em virtude disso, por causa da saturação que eles provocam no sinal amplificado, ou seja, mudanças de voltagem quase instantâneas, a partir da linha de base, não são características de atividade cerebral e, embora não especifiquem a origem, alertam para possíveis interferências.³² Pesquisadores experientes, por simples inspeção visual, conseguem facilmente identificar essas deflexões eletroencefalográficas indesejadas; não obstante, sistemas de comunicação e controle, para funcionarem adequadamente, precisam realizar essa busca automaticamente e, na sequência, removê-las (ao menos parcialmente). Há vários métodos disponíveis para conseguir isso; dois deles, considerados básicos, são a filtragem temporal e a filtragem espacial.³³

2.3.1 Filtragem Temporal

Em geral, um filtro (no contexto de processamento de sinais) é um processo que altera o conteúdo espectral de um sinal temporal, de forma que ocorra a redução de componentes em frequências malquistas, ou seja, ele permite a passagem apenas de certas bandas espectrais enquanto atenua as demais. Um filtro é considerado analógico se opera em sinais

contínuos e digital se opera em sequências de valores discretos.³⁴ Idealmente, ele não deveria só remover as frequências indesejadas, mas deveria também apresentar sensibilidade uniforme para as que fossem desejadas. Embora tal dispositivo não exista de fato, o filtro Butterworth original (analógico), por exemplo, projetado com base na mencionada filosofia, utiliza sucessivas combinações de elementos básicos de circuitos para a obtenção de aproximações consecutivas do que seria a saída de um filtro ideal.³⁵ Em contrapartida, com o advento dos computadores modernos, uma grande variedade de filtros digitais, com diferentes graus de complexidade computacional, tornou-se acessível. Além das versões concebidas a partir de transformação bilinear das funções de transferência dos filtros analógicos clássicos (Butterworth, Chebyshev, Bessel), vários filtros digitais inteiramente novos surgiram: os adaptativos, os de Resposta ao Impulso Finita (FIR, do inglês *Finite Impulse Response*), os de Resposta ao Impulso Infinita (IIR, do inglês *Infinite Impulse Response*), entre outros. Embora cada um deles apresente vantagens e desvantagens, filtros (digitais) passa-banda podem ser facilmente implementados através de aplicação sequencial dos algoritmos utilizados para filtros passa-baixa e passa-alta. Assim, grande parte dos aparelhos de EEG modernos geralmente disponibiliza um variado conjunto desses filtros, que são especificados por ordem (número de coeficientes do filtro) e por limites de faixa (frequências de corte).³⁶ O sinal eletroencefalográfico é geralmente adquirido com filtros analógicos de banda larga, usualmente de 0,1 a 100 Hz, e, nesse caso, o conteúdo espectral removido (durante a aquisição) não pode ser recuperado. Por outro lado, os filtros digitais só se aplicam de forma subsequente e, por isso, proporcionam uma grande flexibilidade: permitir a visualização de registros antes e depois da filtragem. No entanto, é importante reconhecer que estes não podem isolar formas de onda se estas estiverem dentro da banda de frequência com maior atividade fisiológica.³⁷

No contexto de EEG, em teoria, pode-se assumir que quanto mais larga é a banda de frequência registrada, mais fidedigna é a reprodução da atividade real. De certa forma, isso parece bem razoável; contudo a gravação de uma extensa faixa de frequências também aumenta significativamente a quantidade de interferentes. Nesse sentido, os filtros são empregados com a finalidade de se alcançar um compromisso entre a redução de constituintes estranhos e a preservação (tanto quanto for possível) das ondas e potenciais cerebrais em observação. Para isso, define-se um intervalo de frequências para as quais o sinal não seja significativamente distorcido e tenha algum nível de precisão determinado. A questão do que vem a ser “distorção significativa” não tem uma resposta direta e pode variar de acordo com as especificidades da área e do problema em estudo. Para a atividade eletroencefalográfica, por exemplo, admite-se que uma componente em frequência apresente no mínimo 70% de sua tensão efeti-

va. Caso a atenuação do filtro reduza a tensão original em mais de 30%, a distorção é, então, considerada “significativa” e, portanto, não recomendada. Contudo este parece ser um número arbitrário (uma convenção prática que, com o tempo, tornou-se popular), aceito pelas diversas sociedades de EEG que o advogam. Em princípio, não há nenhuma razão (teórica) que impeça essas sociedades de decidir um novo valor (digamos 25% de atenuação apenas). Os equipamentos de ECG, outro exemplo, são autorizados a apresentar uma redução (dentro do espectro definido) de no máximo 10%. Ou seja, quando se trata de parâmetros de filtro aceitáveis, cada indústria ou ramo científico os define de acordo com os aspectos práticos da área.³⁸

2.3.2 Filtragem Espacial (CAR e TWAR)

De forma ampla, pode-se interpretar como filtragem espacial qualquer procedimento que, para reduzir a presença de elementos indesejáveis na sequência de dados, envolva a combinação (ou transformação) de sinais registrados com múltiplos eletrodos. Para isso, existem categorias de filtros com base na composição de médias comuns, na análise de componentes independentes, na análise de componentes principais, na distribuição de padrões semelhantes, na combinação de máximo contraste, entre outras.³⁹ Na primeira delas figura uma das técnicas mais usuais, a Referência Média Comum (CAR, do inglês *Common Average Reference*). Nesta, o valor médio entre todos os sinais da montagem é subtraído dos canais de interesse. Idealmente, se toda a superfície da cabeça fosse recoberta por eletrodos igualmente espaçados e o potencial elétrico medido apresentasse fontes pontuais, o algoritmo CAR resultaria em uma distribuição de voltagem com média zero. Como na prática esses dois pressupostos não são atendidos, o que ele de fato fornece é um sinal de EEG aproximadamente livre de referência. Por um lado, o CAR atua principalmente nas deflexões que estão presentes na maioria dos eletrodos (artefatos espacialmente comuns) e, por isso, consegue eliminá-las. Isso lhe confere uma característica de filtro espacial passa alta, ou seja, a capacidade de acentuar componentes com distribuição altamente focal. Em contrapartida, potenciais espúrios aparecem se alterações de sinal estiverem presentes em quase todos os canais e, ao mesmo tempo, ausentes (ou minimizadas) nos eletrodos de interesse.⁴⁰

Matematicamente, o CAR estabelece que, dado um arranjo de n canais e suas respectivas tensões V_i (onde $i = 1, 2, \dots, n$), o V_i^{CAR} seja computado pela expressão 2.1 adiante.⁴¹

$$V_i^{CAR} = V_i - \frac{1}{n} \sum_{j=1}^n V_j \quad (2.1)$$

De acordo com essa formulação, para compor a referência média, o CAR combina, em cada instante, as informações de todos os eletrodos, ou seja, embora manifestações espaciais concomitantes sejam identificadas, não se leva em consideração possíveis regularidades que seriam observadas somente a partir de uma escala temporal (na vizinhança de um ponto). Nesse contexto, como possibilidade de extensão do algoritmo original, pode-se utilizar o coeficiente de correlação de Pearson (r_{ij}) – indicado na equação 2.2, em que var e cov indicam, respectivamente, a variância e a covariância – para avaliar o conteúdo de trechos simultâneos dos sinais (mesmo que diminutos), ao invés da convencional inspeção ponto a ponto.

$$r_{ij} = \frac{cov(V_i, V_j)}{\sqrt{var(V_i)var(V_j)}} \quad (2.2)$$

Pode-se, então, empregar esse coeficiente para ponderar o cálculo do clássico valor médio e, com isso, dar origem a uma Referência Média Ponderada Temporalmente (TWAR, do inglês *Temporally Weighted Average Reference*), como mostrado na igualdade 2.3 logo abaixo. Esse fator multiplicativo apreende informações do domínio do tempo e, com isso, confere ao filtro TWAR, que também preserva propriedades semelhantes ao CAR, uma característica espaço-temporal, mas só quando a aplicação permite o processamento de segmentos do registro.

$$V_i^{WCAR} = V_i - \frac{1}{n} \sum_{j=1}^n r_{ij} V_j \quad (2.3)$$

Posteriormente, no capítulo 3, para avaliar o impacto desses filtros espaciais para o funcionamento geral da BCI, será mostrado como eles integram o módulo de processamento e influenciam os resultados dos módulos de treinamento e de comunicação e controle.

2.4 EXTRAÇÃO DE CARACTERÍSTICAS

Na maioria das aplicações práticas, os dados de entrada de um sistema, como é o caso da BCI, são numerosos e pertencem a um espaço vetorial com dimensionalidade alta. É, por isso, usual a transformação deles para um novo espaço de dimensão reduzida em que o problema de reconhecimento de padrões seja mais tratável. Essa espécie de processamento é normalmente denominada extração de características – ou extração de atributos – e aplicada tanto às etapas de treinamento e teste quanto às fases de operação em que as informações brutas são atualizadas constantemente. Nas circunstâncias em que a questão envolve alguma detecção em tempo real, as características devem ser computáveis de forma rápida e, ainda as-

sim, preservar uma boa propensão à discriminação. Portanto, os algoritmos que realizam essa tarefa precisam ser eficientemente programados e, além disso, eles não podem incorrer em descarte de conteúdo importante para a identificação do objeto ou do fenômeno em análise.⁴² Logo, de forma simplificada, o objetivo tradicional de um extrator de atributos é encontrar, em meio aos dados, uma representação que permita o reconhecimento tanto de padrões similares, quando objetos da mesma categoria, quanto de padrões não semelhantes, quando objetos de categorias diferentes.⁴³

Isso implica na necessidade de formalização de atributo relevante, definição particularmente útil para tratar dessa tarefa de construção de um subespaço de características proveniente de um espaço original. Para tanto, considere um conjunto de origem O no qual haja n atributos usados para descrever amostras e no qual cada atributo i (onde $i = 1, 2, \dots, n$) pertença a um domínio $\mathcal{F}_i$. Uma amostra, então, é qualquer ponto que faz parte do espaço amostral $\mathcal{F}_1 \times \mathcal{F}_2 \times \dots \times \mathcal{F}_n$. Também considere um subconjunto de O , S , no qual as amostras estejam pareadas com um conjunto de rotulação T e que exista uma função objetivo $f: S \rightarrow T$ que associa cada $s \in S$ a um único rótulo $t \in T$. Dadas essas proposições, segue adiante a noção mais simples de relevância para a extração de características:

Definição 1 (atributo relevante para uma função objetivo f). Um atributo x_i é relevante para uma função objetivo f se há exemplares a e b em S tal que eles difiram entre si apenas por suas atribuições devido a x_i e se a e b apresentam rótulos diferentes, ou seja, se $f(a) \neq f(b)$.

De acordo com essa primeira concepção, o atributo x_i é relevante caso existam amostras em que quaisquer alterações nos valores de x_i afetam os resultados fornecidos pela função objetivo f . De certa forma, isso indica que a **Definição 1** é adequada para as situações em que as imagens de f são objetos reais (organizados em vetores, matrizes, entre outras estruturas), de modo que um algoritmo de aprendizagem possa consultá-los e utilizá-los ativamente. Como exemplos dessa instância, em seções posteriores, serão apresentados um método de classificação (baseado em mínimos quadrados) e outro de seleção (baseado em correlação de Pearson) que requisitam, para os cálculos de seus coeficientes, vetores com os rótulos de treinamento (além dos dados propriamente ditos), ou seja, ambos dispõem de S e f .⁴⁴

Por outro lado, a **Definição 1** não se aplica quando o algoritmo de aprendizagem tem acesso apenas às amostras de S e, nesse caso, ela não é capaz de determinar a relevância de um atributo. Uma das formas de remediar esse inconveniente é acrescentar, na definição

anterior, a noção de relevância no que diz respeito a uma distribuição:

Definição 2 (*atributo relevante para um conjunto amostral S*). Um atributo x_i é relevante para um conjunto amostral S se há exemplares a e b em S tal que eles difiram entre si apenas por suas atribuições devido a x_i , se $f(a) \neq f(b)$ e se a e b apresentam diferentes distribuições de rótulos.

Como exemplos a que a **Definição 2** se aplica, também serão vistas uma técnica de classificação (discriminante de Fisher) e outra de seleção (critério de Fisher) que não necessitam diretamente da rotulação (para o cálculo de seus coeficientes), desde que a organização dos dados já reflita alguma distribuição de rótulos. Isso evidentemente não garante que a **Definição 2** funcione para todas as circunstâncias e (muito menos) significa que as duas definições propostas sejam as únicas. Mas, no geral, as concepções de relevância sempre estão atreladas às heurísticas de aprendizagem (vinculadas, por sua vez, a algoritmos de seleção e classificação) e, por conta disso, um atributo fortemente relevante para um determinado contexto pode não ter tanta relevância assim para outro.⁴⁵

Mesmo a partir de definições de relevância, a tarefa de achar uma representação adequada para um conjunto de dados é um dos grandes desafios em aprendizagem de máquina. Nesse sentido, construir uma representação de atributos também é uma oportunidade para incorporar conhecimentos *a priori* sobre esse conjunto e, ao mesmo tempo, favorecer aplicações *a posteriori*. Para isso, existem diversas técnicas genéricas que podem ser empregadas para a extração de características: transformações lineares, convoluções, agrupamentos, somas e produtos de funções, entre outras.⁴⁶ Na sequência da exposição, por exemplo, serão mostrados dois procedimentos baseados em transformações espectrais – a transformada rápida de Fourier e o periodograma de Welch – porque, de certa forma, são convenientes para a identificação de potenciais evocados em frequências bem determinadas. Se por um lado, então, fica claro que a extração de características é uma das etapas cruciais para o processamento de grandes volumes de dados; por outro lado, ficará evidente, em seções futuras, que ela também está, em grande parte, condicionada à inspeção (desses volumes) com testes estatísticos ou com métodos de aprendizagem de máquina. Por isso, deve-se ter cuidado para não perder conteúdo relevante durante a fase de construção de atributos e, para se verificar isso, deve-se efetuar uma comparação entre os desempenhos obtidos com os dados brutos e com os dados projetados em outros espaços de representação. Em geral, é preferível incluir informação em excesso a arriscar o descarte de informação útil.⁴⁷

Em um problema de reconhecimento de SSVEPs (bem como de outras manifestações eletroencefalográficas) para aplicação em BCI, extrair atributos de um registro temporal demasiado grande, em geral, não tem qualquer utilidade e, por isso, é conveniente dividi-lo em partes para que destas supostamente se identifiquem padrões elementares. Contudo, para que esse procedimento seja válido, a fenomenologia do EEG e do potencial evocado em questão devem atender (ao menos aproximadamente) a dois requisitos (ideais): (1) o sinal de EEG deve consistir de segmentos quase-estacionários e de transientes, que podem estar sobrepostos (aqui, "quase-estacionário" quer dizer que, dentro de um segmento, a estimativa espectral de um intervalo de tempo curto não varia apreciavelmente, e "transiente" significa elementos não-estacionários efêmeros que aparecem como uma única onda); e (2) um segmento deve ser especificado por seu comprimento e por sua estimativa espectral e um transitório, por sua vez, deve ser indicado por um conjunto de elementos gráficos e o instante da sua ocorrência.⁴⁸ Para sumarizar toda a ideia, então, segue o exemplo: os dados filtrados, provenientes dos métodos de remoção de artefatos, são numerosos e, nesse formato temporal, ainda são, em geral, pouco informativos; para contornar esse fato, a estratégia usual é segmentá-los em várias partições com os mesmos tamanhos e, depois disso, extrair, de cada novo fragmento, um conjunto de atributos que favoreça a identificação do padrão desejado; como exemplo, a tensão medida por um canal de EEG, amostrado em 256 Hz, origina, para o tempo de 10 segundos, uma série com 2560 pontos, que pode, em princípio, ser utilizada na íntegra; no entanto, como a análise direta de tantos pontos costuma ser pouco proveitosa, a divisão dessa série em 10 blocos de 256 e a subsequente extração de dois atributos por segmento (por exemplo) reduzem a dimensionalidade do espaço analítico de 2560 para apenas 20. Enfim, embora haja essa vantagem, a principal dificuldade desse tipo de abordagem é descobrir as extrações de características que melhor preservam o conteúdo do sinal autêntico. Para SSVEP-BCI, porém, é natural que a tentativa de extrair características esteja associada às frequências de evocação.

2.4.1 Transformada Rápida de Fourier e Periodograma de Welch

Em linhas gerais, a Transformada Rápida de Fourier (FFT, do inglês *Fast Fourier Transform*) é um algoritmo que computa, com menor custo computacional, exatamente os mesmos valores obtidos com a Transformada Discreta de Fourier (DFT, do inglês *Discrete Fourier Transform*).⁴⁹ Mas antes de tratar efetivamente da primeira é apropriado introduzir noções gerais sobre a segunda. A DFT é um procedimento matemático utilizado para calcular o conteúdo espectral de uma sequência de valores discretos. Embora para o sinal de EEG essa

sequência seja obtida por amostragem periódica de um registro contínuo no domínio do tempo, a DFT, de forma ampla, aplica-se à análise de qualquer sequência discreta, independentemente do que esta represente. A inspiração para definir a DFT (é claro) vem da transformada de Fourier contínua $X(f)$, definida para um sinal $x(t)$ de tempo contínuo.

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-i2\pi ft} dt \quad (2.4)$$

Em processamento de sinais contínuos, a equação 2.4 é a forma canônica de transformar uma função $x(t)$ no domínio do tempo para uma função $X(f)$ no domínio da frequência. A expressão de $X(f)$ permite a determinação do conteúdo espectral de qualquer sinal (contínuo) de interesse prático e, com isso, abre um vasto leque de análise para as Engenharias e para a Física. Pode-se dizer que, de certa forma, a transformada de Fourier também seja um dos formalismos matemáticos mais dominantes e generalizados para a análise de sistemas.⁵⁰

O advento da computação digital e os esforços de pioneiros em obter algoritmos de processamento para esse novo ramo levaram ao desenvolvimento da DFT, que é análoga à transformação anterior, mas é definida, nesse caso, para uma sequência $X[k]$ de frequências discretas e para uma sequência $x[n]$ de valores discretos, geralmente amostrados a partir de uma função contínua $x(t)$ no domínio do tempo.

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-i2\pi k \frac{n}{N}} \quad k = 0, \dots, N-1 \quad (2.5)$$

Embora a equação 2.5 seja o procedimento matemático mais simples para determinar o conteúdo espectral de uma sequência temporal, ela é relativamente ineficiente. Na medida em que se aumentam o número de pontos na DFT para centenas ou milhares, a quantidade de cálculos necessários para computá-la se torna excessiva. No início da era da computação moderna, as DFTs com mais de mil pontos levavam tanto tempo para serem avaliadas que o cômputo delas se restringia aos centros de investigação informática e às grandes universidades.⁵¹

Porém, em 1965, Cooley e Tukey publicaram um artigo que descrevia um algoritmo muito eficiente para implementar a DFT. Esse algoritmo, com o tempo, ficou conhecido como a transformada rápida de Fourier. Como indicado pela expressão (2.5), o cômputo da DFT de uma sequência $x[n]$ originalmente envolve N^2 operações, pois há N coeficientes $X[k]$ e, para cada um destes, existe uma soma de N termos. Por outro lado, Cooley e Tukey mostraram uma técnica com a qual era possível avaliar o mesmo resultado, só que com cálculos da ordem de $N \cdot \log_2 N$ – um número de operações substancialmente inferior ao valor N^2 ,

sobretudo para valores crescentes de N .⁵² Depois desses pesquisadores, outros algoritmos foram propostos com a mesma finalidade, mas foi (inicialmente) graças a Cooley e Tukey (e à indústria de semicondutores, evidentemente) que as DFTs de 1024 pontos, hoje, podem ser executadas (nos computadores domésticos) em poucos segundos (ou milissegundos). De certa forma, essa inovação tornou o poder da análise de Fourier acessível.⁵³

Já o periodograma de Welch é um método que usa a referida transformada rápida de Fourier para estimar a Densidade Espectral de Potência (PSD, do inglês *Power Spectral Density*), que representa, por sua vez, a distribuição da energia espectral (de um sinal) por unidade de tempo. Esse método envolve a segmentação do registro, a avaliação de periodogramas modificados desses segmentos e, por fim, o cálculo da média desses periodogramas. Isso indica que essa técnica pode fornecer uma resolução temporal mínima para testar e medir sinais não-estacionários. Para ver isso, considere $x[n]$, $n = 0, \dots, N - 1$, uma sequência de amostras (idealmente estacionária). Ao dividir a sequência $x[n]$ em K segmentos (possivelmente sobrepostos) de comprimento L e cujos pontos de início (de cada segmento) têm distância $D \leq L$, obtém-se:

$$\begin{aligned} x_1[m] &= x[m] & m &= 0, \dots, L - 1 \\ x_2[m] &= x[m + D] & m &= 0, \dots, L - 1 \\ &\vdots & & \\ x_K[m] &= x[m + (K - 1) \cdot D] & m &= 0, \dots, L - 1 \end{aligned} \quad (2.6)$$

Supõe-se que esses K segmentos (2.6) recubram por inteiro a sequência inicial de amostras, logo, $(K - 1) \cdot D + L = N$. Agora, para cada um desses segmentos de tamanho L , calcula-se o periodograma modificado. Para isso, multiplicam-se os $x_k[m]$ por uma função $w[m]$ que enquadra os dados (janela de Parzen, janela de Hamming, entre outras), o que leva à obtenção de novas sequências $x_k[m] \cdot w[m]$. Pode-se, então, avaliar as FFTs de $x_k[m] \cdot w[m]$ (2.7).

$$X_k[n] = \frac{1}{L} \sum_{m=0}^{L-1} x_k[m] \cdot w[m] e^{-i2\pi n \frac{m}{L}} \quad (2.7)$$

Por conseguinte, os periodogramas modificados $I_k[n / L]$ são calculados a partir das FFTs, como exposto na formulação 2.8 abaixo.

$$I_k[n / L] = \frac{L}{U} |X_k[n]|^2 \quad n = 0, \dots, L / 2 \quad (2.8)$$

Nesta, U representa uma constante dada pela fórmula 2.9 adiante.

$$U = \frac{1}{L} \sum_{m=0}^{L-1} w^2[n] \quad (2.9)$$

Por fim, a estimativa da densidade espectral de potência é basicamente fornecida pela média de todos os periodogramas modificados, como evidenciado na expressão 2.10 a seguir.⁵⁴

$$\hat{P}[n / L] = \frac{1}{K} \sum_{k=0}^K I_k[n / L] \quad (2.10)$$

No contexto de extração de características, por qualquer dos métodos anteriores (FFT ou periodograma de Welch), os coeficientes relacionados às frequências de estimulação são agrupados em uma matriz de atributos, de forma a sintetizar e organizar os dados para as etapas de seleção e classificação.

2.5 ESTRATÉGIAS DE CLASSIFICAÇÃO

Mesmo após a extração de características, os dados oriundos dessa etapa geralmente não são cognoscíveis à simples inspeção humana. Isso, porém, não quer dizer que, deles, inexistam padrões emergentes. Assim, mesmo que não evidentes à primeira vista, uma possível abordagem para detectá-los é a utilização de um método conhecido como aprendizagem supervisionada: aplicação em que dados de treino – vetores de atributos identificados com seus correspondentes valores alvos – servem de exemplos para projetar algoritmos de reconhecimento de padrões.⁵⁵ Entre tais técnicas de identificação figura o classificador: uma função, ou uma combinação de funções, utilizada para distinguir categorias de dados e projetada a partir de uma sequência de operações computacionais. Essa concatenação de instruções algorítmicas, por sua vez, através do referido conjunto de treinamento, estipula, para o espaço de atributos, várias superfícies de decisão que segmentam e agrupam os pontos de acordo com a rotulação fornecida. Esses objetos topológicos têm a capacidade de discriminar novas entradas a partir das subdivisões que os mesmos estabelecem nesse espaço, pois essas regiões estão atreladas aos respectivos rótulos. No contexto da SSVEP-BCI, um classificador deve ser capaz de distinguir as frequências de estimulação visual (classes) a partir dos conteúdos espectrais extraídos do sinal de EEG (atributos).

Em geral, é frequentemente inviável um desempenho de classificação perfeito e, por isso, um importante parâmetro a ser estimado (como será trabalhado em detalhes na seção 2.7) é, para cada rótulo, a probabilidade de acerto de novos dados, a qual, de certa forma, re-

flete o grau de dificuldade envolvido no problema. Essa proporção, por sua vez, depende principalmente de dois aspectos: (1) da variabilidade entre os valores de atributos agrupados sob a mesma rotulação e (2) da diferença entre os valores de atributos relativos a rotulações distintas. Esses dois fatores indicam que a fronteira conceitual entre a extração de características e a escolha de classificação mais adequada é um tanto quanto arbitrária, pois, em princípio, um extrator ideal deveria prover uma representação que tornasse trivial o trabalho do classificador, enquanto um classificador onipotente, por outro lado, não deveria precisar da ajuda de um extrator muito rebuscado. Apesar dessas considerações teóricas, o fato é que a abstração fornecida pelo espaço vetorial de atributos, na prática, permite o desenvolvimento de um amplo domínio de teorias de classificação.⁵⁶ Dentro dessa gama, os discriminantes lineares, devido a sua simplicidade, são considerados como métodos básicos de aplicação em problemas de reconhecimento de padrões e, inclusive, são utilizados como base de comparação para outros classificadores projetados com heurísticas mais sofisticadas (comumente não lineares).

2.5.1 Classificadores Lineares

Considere o espaço vetorial $\mathbf{X}$ com vetores $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ que agrupam n atributos relevantes e o conjunto Y com elementos y que estabelecem representações de classes. A partir disso, uma função discriminante pode ser definida como uma função $f: \mathbf{X} \rightarrow Y$ que relaciona cada vetor de características $\mathbf{x} \in \mathbf{X}$ a uma única representação de classe $y \in Y$. Nesse caso, uma função discriminante linear é formada por uma combinação linear entre os componentes do vetor de atributos $\mathbf{x}$ e os coeficientes de um vetor de pesos $\mathbf{w} = [w_1, w_2, \dots, w_n]^T$ e é acrescida por um parâmetro de limiar w_0 , como mostrado à esquerda da expressão 2.11 logo abaixo. Também, para futuros cálculos, é conveniente simplificar essa fórmula, como expresso à direita da mesma equação; isso leva à introdução de dois novos termos, $\tilde{\mathbf{w}} = [w_0, \mathbf{w}^T]^T$ e $\tilde{\mathbf{x}} = [x_0, \mathbf{x}^T]^T$, com $x_0 = 1$.⁵⁷

$$y(\mathbf{x}) = w_0 + \mathbf{w}^T \mathbf{x} = w_0 + \sum_{i=1}^n w_i x_i = \sum_{i=0}^n w_i x_i = \tilde{\mathbf{w}}^T \tilde{\mathbf{x}} \quad (2.11)$$

Em um problema de separação com duas classes, C_1 e C_2 por exemplo, projetar um classificador significa simplesmente calcular os valores apropriados para $\mathbf{w}$ e w_0 de forma que estes estabeleçam uma superfície divisora entre elas – duas técnicas para realizar esse cálculo serão detalhadas nas seções 2.5.1.1 e 2.5.1.2. Na sequência, com esses coeficientes bem definidos,

uma nova entrada pode ser avaliada com a seguinte regra: decidir por C_1 se $y(\mathbf{x}) > 0$ e decidir por C_2 se $y(\mathbf{x}) < 0$. Ou seja, $\mathbf{x}$ é atribuído a C_1 se o produto interno $\mathbf{w}^T \mathbf{x}$ exceder o limite imposto por w_0 e, caso contrário, $\mathbf{x}$ é designado como pertencente a C_2 .⁵⁸

O resultado $y(\mathbf{x}) = 0$, por sua vez, define a fronteira entre as classes, a qual corresponde, nesse caso, a um hiperplano H de dimensão $(n - 1)$ contido em um espaço n -dimensional. Se dois pontos, $\mathbf{x}_A$ e $\mathbf{x}_B$, pertencem a essa superfície de decisão, então $y(\mathbf{x}_A) = y(\mathbf{x}_B) = 0$, o que implica nas expressões 2.12. A última destas revela que $\mathbf{w}$ é ortogonal a qualquer vetor inserido em H , ou seja, $\mathbf{w}$ determina a orientação do hiperplano.

$$\begin{aligned} w_0 + \mathbf{w}^T \mathbf{x}_A &= w_0 + \mathbf{w}^T \mathbf{x}_B \\ \mathbf{w}^T (\mathbf{x}_A - \mathbf{x}_B) &= 0 \end{aligned} \quad (2.12)$$

Assim, a regra de escolha mencionada se justifica porque H subdivide o espaço de atributos em duas regiões disjuntas: o subespaço $\mathcal{R}_1$ para C_1 e o subespaço $\mathcal{R}_2$ para C_2 . Todos os pontos da superfície de decisão ($y(\mathbf{x}) = 0$), por outro lado, geralmente são associados a um estado de indecisão – opção mais frequente – ou atrelados a uma única classe.

Além desses aspectos, $y(\mathbf{x})$ fornece uma medida algébrica da distância perpendicular d entre $\mathbf{x}$ e o hiperplano. Para verificar esse fato, decompõe-se $\mathbf{x}$ (2.13) como a soma de dois termos: sua projeção ortogonal $\mathbf{x}_\perp$ em H e o vetor $d\hat{\mathbf{w}}$ com o desejado comprimento – positivo se $\mathbf{x} \in \mathcal{R}_1$ e negativo se $\mathbf{x} \in \mathcal{R}_2$.

$$\mathbf{x} = \mathbf{x}_\perp + d \frac{\mathbf{w}}{\|\mathbf{w}\|} \quad (2.13)$$

Ao multiplicar e somar ambos os lados da igualdade 2.13, respectivamente, por $\mathbf{w}^T$ e w_0 , obtêm-se as formulações 2.14 adiante.

$$\begin{aligned} w_0 + \mathbf{w}^T \mathbf{x} &= w_0 + \mathbf{w}^T \mathbf{x}_\perp + d \frac{\mathbf{w}^T \mathbf{w}}{\|\mathbf{w}\|} \\ y(\mathbf{x}) &= y(\mathbf{x}_\perp) + d \frac{\|\mathbf{w}\|^2}{\|\mathbf{w}\|} \end{aligned} \quad (2.14)$$

Como $y(\mathbf{x}_\perp) = 0$ ($\mathbf{x}_\perp$ está contido em H), a última destas pode, enfim, ser rearranjada na expressão 2.15, que é o resultado procurado.

$$d = \frac{y(\mathbf{x})}{\|\mathbf{w}\|} \quad (2.15)$$

Em particular, se $\mathbf{x} = [0, 0, \dots, 0]^T$, então $d_0 = w_0 / \|\mathbf{w}\|$, justamente a distância da origem até o hiperplano. Se $w_0 > 0$, esta se localiza em $\mathcal{R}_1$ e, se $w_0 < 0$, em $\mathcal{R}_2$. Se $w_0 = 0$, logo $y(\mathbf{x})$

tem a forma homogênea $\mathbf{w}^T \mathbf{x}$, o que significa que H passa através da origem. Todos esses detalhes circunstanciais – embora referentes à distinção entre apenas duas categorias – ajudam a estabelecer uma intuição para explorar o problema de separação de muitas classes.

Nesse caso geral, considere que os vetores de características $\mathbf{x}$ se distribuam por entre as classes C_k , onde $k = 1, 2, \dots, m$. Para escolher hiperplanos que adequadamente segmentem o espaço de atributos em m regiões de decisão $\mathcal{R}_k$ e que, ao mesmo tempo, evitem subespaços com classificação ambígua, uma possível abordagem é a combinação de m funções lineares, como mostrado na expressão 2.16, em conjunto com a seguinte regra de decisão: atribuir $\mathbf{x}$ à categoria c_k (ou seja, $\mathbf{x} \in \mathcal{R}_k$) se $y_k(\mathbf{x}) > y_l(\mathbf{x})$ para todo $k \neq l$.⁵⁹

$$y_k(\mathbf{x}) = w_{k0} + \mathbf{w}_k^T \mathbf{x} = w_{k0} + \sum_{i=1}^n w_{ki} x_i = \sum_{i=0}^n w_{ki} x_i = \tilde{\mathbf{w}}_k^T \tilde{\mathbf{x}} \quad (2.16)$$

Com isso, a fronteira entre as classes C_k e C_l é fornecida pela identidade $y_k(\mathbf{x}) = y_l(\mathbf{x})$, da qual se deduz as igualdades 2.17. Destas, a equação derradeira, como visto a pouco na situação para duas variedades, representa hiperplanos H_{kl} de dimensão $(n - 1)$.

$$\begin{aligned} w_{k0} + \mathbf{w}_k^T \mathbf{x} &= w_{l0} + \mathbf{w}_l^T \mathbf{x} \\ (\mathbf{w}_k - \mathbf{w}_l)^T \mathbf{x} + (w_{k0} - w_{l0}) &= 0 \end{aligned} \quad (2.17)$$

Disso também decorre que os $(\mathbf{w}_k - \mathbf{w}_l)$ são ortogonais aos respectivos H_{kl} e que as distâncias de $\mathbf{x}$ até os hiperplanos são dadas por $(y_k(\mathbf{x}) - y_l(\mathbf{x})) / \|\mathbf{w}_k - \mathbf{w}_l\|$, propriedades similares ao caso anterior. Porém, existe uma notável distinção: não são os vetores de pesos em si, mas sim as diferenças entre eles, que identificam, de acordo com as regiões de decisão correspondentes, a natureza dos vetores de características.⁶⁰

Para que todo esse formalismo funcione é preciso que os atributos sejam (pelo menos com certa aproximação) linearmente separáveis e, além disso, como dito no início desta seção, é necessário calcular apropriadamente os valores de $\mathbf{w}_k$ e w_{k0} . No contexto de aprendizagem supervisionada, a primeira condição, em geral, depende da natureza dos dados enquanto a segunda depende, principalmente (mas não exclusivamente), da abundância dos mesmos, ou seja, esse último aspecto indica que obter um classificador linear com boa capacidade de generalização requer, entre outros fatores, um volume substancial de amostras rotuladas. Com essas exigências satisfeitas, para o cômputo dos vetores de pesos, há duas técnicas usuais: o Método dos Mínimos Quadrados (LSM, do inglês *Least Squares Method*) e o Discriminante Linear de Fisher (FLD, do inglês *Fisher's Linear Discriminant*).

2.5.1.1 Método dos Mínimos Quadrados

Considere um conjunto amostral com as observações $\tilde{\mathbf{x}}_i = [x_{i0}, x_{i1}, \dots, x_{in}]^T$ – onde $i = 1, 2, \dots, p$ – rotuladas de forma binária $r_{ki} = +1 \forall \mathbf{x}_i \in \mathcal{R}_k$ ($y_{ki} > 0$) e $r_{ki} = -1 \forall \mathbf{x}_i \notin \mathcal{R}_k$ ($y_{ki} < 0$). Esses dados podem ser utilizados para calcular os vetores de pesos $\tilde{\mathbf{w}}_k$. O tratamento de p equações lineares simultâneas ($y_{ki} = \tilde{\mathbf{w}}_k^T \tilde{\mathbf{x}}_i$) é simplificado pela introdução de uma notação matricial: os exemplares de treino são organizados na matriz $\tilde{\mathbf{X}}$ em que a p -ésima linha é formada por $\tilde{\mathbf{x}}_i^T$; os resultados dos produtos internos são dispostos nos vetores $\mathbf{y}_k$; e os rótulos são agrupados nos vetores $\mathbf{r}_k$. Dessa forma, o problema se resume a encontrar os coeficientes de $\tilde{\mathbf{w}}_k$ que satisfazem o equacionamento 2.18, mostrado a seguir.

$$\begin{bmatrix} y_{k1} \\ y_{k2} \\ \vdots \\ y_{kp} \end{bmatrix} = \begin{bmatrix} x_{10} & x_{11} & \cdots & x_{1n} \\ x_{20} & x_{21} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{p0} & x_{p1} & \cdots & x_{pn} \end{bmatrix} \begin{bmatrix} w_{k0} \\ w_{k1} \\ \vdots \\ w_{kn} \end{bmatrix} \Leftrightarrow \mathbf{y}_k = \tilde{\mathbf{X}} \tilde{\mathbf{w}}_k \quad (2.18)$$

Caso $\tilde{\mathbf{X}}$ fosse não singular, bastaria reescrever a expressão 2.18 para o formato $\tilde{\mathbf{w}}_k = \tilde{\mathbf{X}}^{-1} \mathbf{y}_k$, que este forneceria uma solução formal. No entanto, $\tilde{\mathbf{X}}$ tem conformação retangular, usualmente com mais linhas (amostras) do que colunas (atributos). Como o sistema tem mais equações do que variáveis, $\tilde{\mathbf{w}}_k$ é sobredeterminado e, por isso, não há um resultado exato. Por outro lado, mesmo assim, pode-se procurar um $\tilde{\mathbf{w}}_k$ que minimize um vetor de erros $\mathbf{e}_k$, definido como a diferença entre o valor $\mathbf{y}_k$ obtido e o valor $\mathbf{r}_k$ esperado, como apontado abaixo.

$$\mathbf{e}_k = \mathbf{y}_k - \mathbf{r}_k = \tilde{\mathbf{X}} \tilde{\mathbf{w}}_k - \mathbf{r}_k \quad (2.19)$$

Pode-se, então, tentar minimizar o seu módulo elevado à segunda potência, que é equivalente ao critério de minimização da função dos erros quadráticos, ou seja, ao LSM.⁶¹

Esse problema pode ser resolvido pela técnica do gradiente, a qual prove uma solução em forma fechada simples. Para isso, parte-se da formulação dos erros e, com o uso de propriedades matriciais, rearranja-se a mesma até a obtenção da última das igualdades 2.20.

$$\begin{aligned} E_k^{LSM} &= \|\tilde{\mathbf{X}} \tilde{\mathbf{w}}_k - \mathbf{r}_k\|^2 \\ &= (\tilde{\mathbf{X}} \tilde{\mathbf{w}}_k - \mathbf{r}_k)^T (\tilde{\mathbf{X}} \tilde{\mathbf{w}}_k - \mathbf{r}_k) \\ &= \tilde{\mathbf{w}}_k^T \tilde{\mathbf{X}}^T \tilde{\mathbf{X}} \tilde{\mathbf{w}}_k - \tilde{\mathbf{w}}_k^T \tilde{\mathbf{X}}^T \mathbf{r}_k - \mathbf{r}_k^T \tilde{\mathbf{X}} \tilde{\mathbf{w}}_k + \mathbf{r}_k^T \mathbf{r}_k \\ &= \tilde{\mathbf{w}}_k^T \tilde{\mathbf{X}}^T \tilde{\mathbf{X}} \tilde{\mathbf{w}}_k - 2 \tilde{\mathbf{w}}_k^T \tilde{\mathbf{X}}^T \mathbf{r}_k + \mathbf{r}_k^T \mathbf{r}_k \end{aligned} \quad (2.20)$$

Nesta, aplica-se o gradiente (a despeito da notação concisa, é bom salientar que as derivadas parciais são avaliadas, na verdade, ao longo das expressões resultantes de cada produto veto-

rial) e se obtém a equação 2.21 adiante.

$$\nabla E_k^{LSM} = 2\tilde{\mathbf{X}}^T \tilde{\mathbf{X}} \tilde{\mathbf{w}}_k - 2\tilde{\mathbf{X}}^T \mathbf{r}_k \quad (2.21)$$

Ao igualá-la a zero e reorganizá-la, encontra-se a expressão 2.22 a seguir. Esta, por sua vez, exibe alguma similaridade com o equacionamento do problema original: $\tilde{\mathbf{X}} \tilde{\mathbf{w}}_k = \mathbf{y}_k$. Embora os termos $\tilde{\mathbf{X}}^T \tilde{\mathbf{X}}$ e $\tilde{\mathbf{X}}^T \mathbf{r}_k$ substituam, respectivamente, $\tilde{\mathbf{X}}$ e $\mathbf{y}_k$, a formulação permanece a mesma reprodução geral de um arranjo de equações lineares.

$$\tilde{\mathbf{X}}^T \tilde{\mathbf{X}} \tilde{\mathbf{w}}_k = \tilde{\mathbf{X}}^T \mathbf{r}_k \quad (2.22)$$

Contudo, diferente da primeira, essa segunda tem a grande vantagem de que $\tilde{\mathbf{X}}^T \tilde{\mathbf{X}}$ é uma matriz quadrada e frequentemente não singular. Nessas condições, o sistema tem solução direta

$$\begin{aligned} \tilde{\mathbf{w}}_k &= (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{r}_k \\ &= \tilde{\mathbf{X}}^\dagger \mathbf{r}_k \end{aligned} \quad (2.23)$$

na qual a matriz p por n

$$\tilde{\mathbf{X}}^\dagger = (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \quad (2.24)$$

é conhecida como pseudoinversa de $\tilde{\mathbf{X}}$.⁶² A matriz $\tilde{\mathbf{X}}^\dagger$ é considerada como uma generalização do procedimento de inversão, pois também se aplica às matrizes não-quadradas. Evidentemente que se $\tilde{\mathbf{X}}$ for quadrada e não singular, vale a propriedade $(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} = \tilde{\mathbf{X}}^{-1} (\tilde{\mathbf{X}}^T)^{-1}$ e, assim, $\tilde{\mathbf{X}}^\dagger = \tilde{\mathbf{X}}^{-1}$, ou seja, a pseudoinversa se reduz à inversa.⁶³

A solução fornecida pelo LSM, para o cálculo dos coeficientes $\tilde{\mathbf{w}}_k$, depende diretamente do vetor de rótulos $\mathbf{r}_k$. A escolha da rotulação pode, então, influenciar o desempenho desse classificador e, portanto, não deve ser estabelecida de forma arbitrária. (rótulos desbalanceados, por exemplo, podem favorecer alguma classe em particular e desfavorecer outras). Isso também sugere que para um conjunto de amostras em que a **Definição 1** reflete os supostos atributos relevantes, o LSM consegue razoavelmente discriminar novos dados.

2.5.1.2 Discriminante Linear de Fisher

Outra tática para calcular $\mathbf{w}_k$ é abrir mão dos coeficientes w_{k0} ! À primeira vista, essa concessão pode não parecer interessante porque, para os classificadores lineares, os w_{k0} (como exposto anteriormente) são as variáveis de ajuste que estabelecem as distâncias entre os hiperplanos H_{kl} e a origem do espaço de atributos. Apesar dessa aparente desvantagem,

logo ficará claro que essa redução de dimensionalidade pode ser feita de tal forma que se alcance projeções ortogonais para a separação das classes. Para isso, parte-se da escolha de que w_{k0} dever ser igualado a $-w_k^T \mu$, em que μ é o vetor médio de atributos avaliado de acordo com todas as p observações de treinamento, como mostrado na formulação 2.25 adiante.

$$\mu = \frac{1}{p} \sum_{i=1}^p x_i = \left[\frac{1}{p} \sum_{i=1}^p x_{i1}, \frac{1}{p} \sum_{i=1}^p x_{i2}, \dots, \frac{1}{p} \sum_{i=1}^p x_{in} \right] \quad (2.25)$$

Essa suposição permite o rearranjo da expressão 2.16 e a consequente obtenção da equação 2.26. Nessa nova configuração, cada $y_k(x)$ se torna uma projeção (produto interno) entre os coeficientes w_k (que se quer calcular) e o vetor de atributos subtraído de sua média geral.

$$y_k(x) = w_k^T (x - \mu) \quad (2.26)$$

Nesse caso, como a distribuição de rótulos é conhecida, pode-se utilizar essa informação para ajustar os valores de w_k de forma a maximizar as projeções que separam as classes. Esse é o intuito do método do discriminante linear de Fisher.

De acordo com essa técnica, a partir dos dados de treinamento, obtém-se (para um problema de classificação binário) primeiro os vetores de médias entre as classes, $\mu_{+k} \forall x_i \in \mathcal{R}_k$ e $\mu_{-k} \forall x_i \notin \mathcal{R}_k$, como mostrado na fórmula 2.27 abaixo. A diferença entre essas médias fornece uma medida de separação entre os pontos projetados de cada categoria.

$$\mu_{\pm k} = \frac{1}{\#\{i \in C_{\pm k}\}} \sum_{i \in C_{\pm k}} x_i \quad (2.27)$$

Isso, porque pode-se definir as médias projetadas das classes, $\mu_{+k} \forall x_i \in \mathcal{R}_k$, $\mu_{-k} \forall x_i \notin \mathcal{R}_k$,

$$\begin{aligned} \mu_{\pm k} &= \frac{1}{\#\{i \in C_{\pm k}\}} \sum_{i \in C_{\pm k}} w_k^T x_i \\ &= w_k^T \left\{ \frac{1}{\#\{i \in C_{\pm k}\}} \sum_{i \in C_{\pm k}} x_i \right\} \\ &= w_k^T \mu_{\pm k} \end{aligned} \quad (2.28)$$

e disso decorre que a distância entre essas médias projetadas, $\mu_{+k} - \mu_{-k} = w_k^T (\mu_{+k} - \mu_{-k})$, pode ser alargada por meio do escalonamento dos coeficientes w_k . Em princípio, essa maximização parece bastar para resolver o problema, pois o único inconveniente aparente é que w_k , a depender da situação, torna-se arbitrariamente grande; mas esse fato é facilmente contornado com adição da seguinte restrição: $\|w_k\|^2 = 1$. Ou seja, com o uso de multiplicadores

de Lagrange (por exemplo), as médias projetadas podem ser maximizadas e, ainda assim, estar sujeitas a restrições. Nesse caso, é possível mostrar que $\mathbf{w}_k \approx (\boldsymbol{\mu}_{+k} - \boldsymbol{\mu}_{-k})$. Entretanto, há distribuições de dados que, embora sejam separáveis no espaço de atributos, apresentam considerável volume de sobreposição no espaço das médias projetadas. Essa dificuldade aparece principalmente quando as classes (que se deseja separar) têm espalhamentos com covariância tendenciosamente não-diagonal.⁶⁴ Por conta disso, para minimizar o problema da sobreposição, Ronald Fisher, em 1936, formulou a questão da seguinte forma:⁶⁵ que função linear deve ser maximizada para alcançar a maior separação entre as médias projetadas e, ao mesmo tempo, obter as menores variâncias dentro das distribuições de cada classe?

Para respondê-la, além das médias projetadas, define-se também as variâncias projetadas das classes, $\sigma_{+k}^2 \forall \mathbf{x}_i \in \mathcal{R}_k, \sigma_{-k}^2 \forall \mathbf{x}_i \notin \mathcal{R}_k$,

$$\begin{aligned}
 \sigma_{\pm k}^2 &= \sum_{i \in \mathcal{C}_{\pm k}} [\mathbf{w}_k^T \mathbf{x}_i - \mu_{\pm k}]^2 \\
 &= \sum_{i \in \mathcal{C}_{\pm k}} [\mathbf{w}_k^T \mathbf{x}_i - \mathbf{w}_k^T \boldsymbol{\mu}_{\pm k}]^2 \\
 &= \mathbf{w}_k^T \left\{ \sum_{i \in \mathcal{C}_{\pm k}} (\mathbf{x}_i - \boldsymbol{\mu}_{\pm k})(\mathbf{x}_i - \boldsymbol{\mu}_{\pm k})^T \right\} \mathbf{w}_k \\
 &= \mathbf{w}_k^T \mathbf{S}_{\pm k} \mathbf{w}_k
 \end{aligned} \tag{2.29}$$

e, a partir de ambas (agora), o método do FLD busca as funções lineares $y_k(\mathbf{x}) = \mathbf{w}_k^T (\mathbf{x} - \boldsymbol{\mu})$ para as quais o critério da expressão 2.30 seja máximo e independente de $\|\mathbf{w}_k\|$.

$$J_k^{FLD}(\mathbf{w}_k) = \frac{(\mu_{+k} - \mu_{-k})^2}{\sigma_{+k}^2 + \sigma_{-k}^2} \tag{2.30}$$

Nesta, porém os coeficientes $\mathbf{w}_k$ não aparecem de forma explícita. Por outro lado, basta empregar os rearranjos das igualdades 2.31, em que $\mathbf{S}_B$ é a matriz de covariância entre as classes,

$$\begin{aligned}
 (\mu_{+k} - \mu_{-k})^2 &= (\mathbf{w}_k^T \boldsymbol{\mu}_{+k} - \mathbf{w}_k^T \boldsymbol{\mu}_{-k})^2 \\
 &= \mathbf{w}_k^T \{(\boldsymbol{\mu}_{+k} - \boldsymbol{\mu}_{-k})(\boldsymbol{\mu}_{+k} - \boldsymbol{\mu}_{-k})^T\} \mathbf{w}_k \\
 &= \mathbf{w}_k^T \mathbf{S}_B \mathbf{w}_k
 \end{aligned} \tag{2.31}$$

e 2.32, em que $\mathbf{S}_W$ é a matriz de covariância dentro das classes,

$$\begin{aligned}
 \sigma_{+k}^2 + \sigma_{-k}^2 &= \mathbf{w}_k^T \mathbf{S}_{+k} \mathbf{w}_k + \mathbf{w}_k^T \mathbf{S}_{-k} \mathbf{w}_k \\
 &= \mathbf{w}_k^T \{\mathbf{S}_{+k} + \mathbf{S}_{-k}\} \mathbf{w}_k \\
 &= \mathbf{w}_k^T \mathbf{S}_W \mathbf{w}_k
 \end{aligned} \tag{2.32}$$

para se obter o critério J_k^{FDA} , exposto a seguir, como função direta de $\mathbf{w}_k$.

$$J_k^{FDA}(\mathbf{w}_k) = \frac{\mathbf{w}_k^T \mathbf{S}_B \mathbf{w}_k}{\mathbf{w}_k^T \mathbf{S}_W \mathbf{w}_k} \quad (2.33)$$

Nesse formato vetorial, a função J_k^{FDA} pode ser diferenciada com respeito ao $\mathbf{w}_k$, como mostrado nas expressões 2.34,

$$\begin{aligned} \nabla J_k^{FDA}(\mathbf{w}_k) &= \frac{\mathbf{S}_B \mathbf{w}_k}{\mathbf{w}_k^T \mathbf{S}_W \mathbf{w}_k} - \frac{(\mathbf{w}_k^T \mathbf{S}_B \mathbf{w}_k) \mathbf{S}_W \mathbf{w}_k}{(\mathbf{w}_k^T \mathbf{S}_W \mathbf{w}_k)^2} \\ &= \frac{(\mathbf{w}_k^T \mathbf{S}_W \mathbf{w}_k) \mathbf{S}_B \mathbf{w}_k - (\mathbf{w}_k^T \mathbf{S}_B \mathbf{w}_k) \mathbf{S}_W \mathbf{w}_k}{(\mathbf{w}_k^T \mathbf{S}_W \mathbf{w}_k)^2} \end{aligned} \quad (2.34)$$

e igualada a zero para resultar na equivalência 2.35 adiante,

$$\mathbf{S}_W \mathbf{w}_k = \lambda \cdot \mathbf{S}_B \mathbf{w}_k \quad (2.35)$$

em que $\lambda = (\mathbf{w}_k^T \mathbf{S}_W \mathbf{w}_k) / (\mathbf{w}_k^T \mathbf{S}_B \mathbf{w}_k)$. Como $\mathbf{S}_B \mathbf{w}_k$ (vide as equações 2.31) aponta sempre na direção de $(\boldsymbol{\mu}_{+k} - \boldsymbol{\mu}_{-k})$ e como apenas a direção de $\mathbf{w}_k$ (e não sua magnitude) é necessária para os propósitos de classificação (vide as equações 2.17), pode-se ignorar o fator de escala e, além disso, multiplicar ambos os lados por $\mathbf{S}_W^{-1}$, o que leva a uma solução aproximada (mas igualmente eficiente) para $\mathbf{w}_k$, como exibida na expressão 2.36 abaixo.

$$\mathbf{w}_k \approx \mathbf{S}_W^{-1}(\boldsymbol{\mu}_{+k} - \boldsymbol{\mu}_{-k}) \quad (2.36)$$

Diferentemente do LSM, a solução obtida com o FLD não depende diretamente dos rótulos, apenas da distribuição associada a eles. Nesse caso, para facilitar o cômputo $\mathbf{w}_k$, é conveniente agrupar os dados de treinamento de forma a facilitar a avaliação das médias e variâncias projetadas das classes. De certa forma, isso sugere que, para um conjunto amostral em que a **Definição 2** reflete os supostos atributos relevantes, o FLD deve discriminar satisfatoriamente dados atualizados. Em termos matemáticos, existe uma equivalência direta (embora não tenha sido mostrada aqui) entre os dois métodos expostos. Apesar disso, ambos conseguem fornecer intuições particulares e complementares sobre o problema de classificação linear e, por isso, foram igualmente trabalhados (ao invés de se optar por apenas um deles). Mas tanto por um quanto por outro, uma vez fixados os parâmetros (o que em aprendizagem de máquina representa a etapa final do treinamento), estes podem ser utilizados para distinguir novas entradas. Portanto, projetar um classificador linear, aplicado ao contexto de SSVEP-BCI, é basicamente ajustar coeficientes de funções para reconhecer, nos atributos extraídos do sinal de EEG, padrões associados às frequências de estimulação.

2.6 SELEÇÃO DE ATRIBUTOS

Fundamentalmente, a aprendizagem computacional exige etapas que envolvam a extração de características e a classificação, ambas tratadas em tópicos antecedentes. No entanto, além de decidir quais atributos usar na descrição, pode-se também decidir como combiná-los para a obtenção de um melhor resultado na discriminação das classes. Essa segunda decisão é nomeada de seleção de características relevantes (ou a eliminação de irrelevantes), que (no contexto do presente estudo) é proposta de acordo com as **Definições 1 e 2** e preferencialmente de acordo com a escolha do classificador, uma vez que o desempenho deste é quem aponta para a suficiência do método empregado (por isso é que a exposição desse tema foi postergada até agora). O ideal é aplicar procedimentos em que o número de exemplares de treino para atingir o nível desejado de precisão cresça lentamente com o número de atributos extraídos, caso nem todos estes sejam necessários para alcançar uma acurácia satisfatória.⁶⁶ Apesar disso, a seleção de atributos, embora seja prioritariamente realizada para selecionar características informativas, tem outras motivações gerais (do ponto de vista sistemático) como a redução do espaço amostral (para limitar a armazenagem e aumentar a velocidade de processamento), a redução na configuração de atributos (para poupar recursos ao longo da análise ou mesmo durante a execução de algoritmos) e a compreensão (inspeção) de grandes volumes de dados (para adquirir conhecimento sobre o processo que os gerou).⁶⁷

O problema de selecionar atributos é o mesmo de encontrar, em um conjunto amostral, um subconjunto de características originais de tal forma que um algoritmo de classificação, apenas com acesso aos dados selecionados, produza um discriminante com a maior precisão possível. Percebe-se, então, que essa seleção opera entre os atributos existentes, ou seja, não há extração (construção) de novas características. Uma definição formal para esse procedimento de escolha tem a seguinte proposição:

Definição 3 (*subconjunto de atributos ótimo*). *Dado uma função discriminante $y(\mathbf{x})$ e um conjunto amostral S com atributos $x_1, x_2, \dots, x_n$, a partir de uma distribuição de rótulos e de um algoritmo de seleção, um subconjunto de atributos ótimo $\mathbf{x}_{oti}$ é aquele para o qual o resultado de classificação $y(\mathbf{x}_{oti})$ alcança o máximo desempenho.*

De acordo com essa enunciação, um subconjunto de atributos ótimo não precisa ser único, pois, em geral, é possível obter precisões iguais com o uso de diferentes arranjos de características. Quando duas (ou mais) destas estão perfeitamente correlacionadas, por exem-

plo, elas são intercambiáveis em relação ao subconjunto ótimo, ou seja, uma pode substituir a outra. Além disso, há um inconveniente ao usar essa definição em cenários práticos de aprendizagem de máquina: não se tem acesso à distribuição de dados real (apenas à de rótulos), o que implica que a acurácia do classificador representa somente uma estimativa.⁶⁸ Mesmo assim, a etapa de seleção de atributos costuma ser decisiva para solucionar problemas de reconhecimento de padrões e, por isso mesmo, há um grande número de abordagens diferentes para realizá-la. Na sequência da exposição, os métodos (que serão apresentados) empregam a técnica de filtro de seleção e, de acordo com esta, tentam validar cada característica somente a partir dos dados, ou seja, desconsideram, a cada passo de execução, o resultado do classificador (embora este ainda seja utilizado para avaliar o desempenho final do algoritmo). Nesse sentido, eles representam uma espécie de pré-processamento de atributos, como forma de preparação para a etapa de classificação.⁶⁹ Os seletores baseados em métodos de filtros estão entre as técnicas mais simples para realizar uma ordenação no espaço de atributos e se sustentam na avaliação de métricas calculadas somente com as características extraídas do sinal. O filtro de seleção é geralmente alguma função estatística que retorna índices de relevância entre cada atributo e cada rotulação. Embora essa abordagem pressuponha a independência dos dados e prejudique a identificação de variáveis correlacionadas, a escolha dessa métrica de indexação pode favorecer, até certo ponto, o desempenho de alguns classificadores.⁷⁰

2.6.1 Filtros de Seleção

Um filtro seletor de atributos é uma função J que retorna um índice de relevância para estimar o quanto um subconjunto de características extraídas de um dado conjunto amostral é eficiente para uma tarefa específica (como a classificação ou a estimação, por exemplo). Esses filtros são às vezes chamados de "métricas de seleção de atributo", embora (rigorosamente) eles não tenham as propriedades formais necessárias para se enquadrar como uma distância métrica. A despeito disso, os índices de relevância podem ser associados a cada uma das características x_i (onde $i = 1, 2, \dots, n$) e, dessa forma, estabelecer uma ordenação $J(x_1) \leq J(x_2) \leq \dots \leq J(x_n)$ entre elas. Por conseguinte, pode-se então estipular que os x_i com valores abaixo de certo limiar sejam removidos (processo que guarda similaridade aos filtros espectrais e suas frequências de corte, o que justifica a denominação "filtro" de seleção). Esse procedimento tem a capacidade de selecionar atributos que sejam independentes, mas se estes (de alguma forma) estiverem correlacionados, boa parte das características consideradas importantes pode ser informação redundante. Mas ainda assim, os métodos de fil-

tros podem ser empregados no contexto de classificação. Geralmente, o valor do índice de relevância deve (de alguma forma) estar associado com a precisão de qualquer classificador razoavelmente treinado para executar uma determinada tarefa. Por exemplo, de certa forma, pode-se argumentar que métodos de filtros baseados na concepção de atributo relevante proposto pela **Definição 1** sejam apropriados para selecionar características favoráveis aos algoritmos de classificação também guiados pelo mesmo princípio. Nesse sentido, o mesmo valeria para métodos fundamentados de acordo com a **Definição 2**. No entanto, essa suposta associação, entre o seletor e o discriminante, não tem qualquer indício de generalidade e, em termos teóricos, pode (na verdade) ser bem difícil de estabelecer (rigorosamente) para os diversos contextos analíticos.

Os coeficientes de correlação estão entre os métodos mais simples para mensurar a relevância de atributos e, com isso, estabelecer um critério de seleção. Eles são bastante utilizados como testes de avaliação estatística e podem também ser aplicados no contexto de reconhecimento de padrões. O coeficiente de correlação de Pearson, por exemplo, anteriormente usado à ponderação da filtragem espacial TWAR, fornece um índice de relevância entre cada atributo x_i e cada rótulo r_k (equação 2.37), à maneira da **Definição 1**. Isso sugere que ele seja capaz de ordenar características independentes que favoreçam o treinamento de um classificador linear que emprega o algoritmo de LSM para determinar $\mathbf{w}_k$.

$$J(x_i, r_k)_{ik} = \frac{cov(x_i, r_k)}{\sqrt{var(x_i)var(r_k)}} \quad (2.37)$$

Os valores de $J(x_i, r_k)_{ik}$ variam de ± 1 , se x_i e r_k forem linearmente dependentes, a zero, se os mesmos estiverem completamente descorrelacionados. Note que alguns atributos podem ser tanto positivamente quanto negativamente correlacionados, o que para os propósitos de seleção muitas vezes não tem importância e, por isso, o valor absoluto é considerado. Outro exemplo de coeficiente é o número de Fisher (expressão 2.38), uma adaptação da J_k^{FLD} para o caso de observação de cada atributo x_i isolado, que elege (em consonância com a **Definição 2**) características favoráveis ao discriminante de Fisher.

$$J(\mu_{+ik}, \mu_{-ik})_{ik} = \frac{\mu_{+ik} - \mu_{-ik}}{\sigma_{+ik} + \sigma_{-ik}} \quad (2.38)$$

Por qualquer desses seletores, o espaço vetorial de atributos é arranjado por ordem de significância, de acordo com o índice de relevância aplicado. Com isso, pode-se reduzir a dimensão da análise com o descarte das características de menor pontuação e pode-se melhorar o desempenho de classificação. Além disso, no contexto de SSVEP-BCI, os atributos com a maior

pontuação localizam as áreas do córtex que melhor correspondem ao critério de seleção e, com isso, identificam possíveis regiões de atividade relacionadas à estimulação.

2.7 VALIDAÇÃO E DESEMPENHO

Os coeficientes do discriminante, calculados por qualquer que seja a metodologia, precisam ser testados antes de atuar em novas amostras. Por um lado, modelagens matemáticas tradicionais geralmente envolvem a estimativa dos parâmetros de um modelo tido como verossímil, ou seja, presume-se que a função final do modelo pertença à família de funções propostas e que a tarefa se resume apenas ao circunstancial cálculo de variáveis. Nesse contexto, uma análise do fenômeno de interesse costuma levar a equações paramétricas que têm um significado físico e que, portanto, são ajustadas a partir de amostras mensuradas. Evidentemente, a validade dos valores obtidos para os parâmetros deve ser avaliada dentro de intervalos de confiança; entretanto, a validade da função cujos parâmetros são estimados não é questionada pela análise estatística. Por outro lado, em abordagens de aprendizagem de máquina, a família de funções (em que se busca um suposto padrão funcional) não precisa ter qualquer verossimilhança com o fenômeno de interesse. Aliás, diferente de modelos dinâmicos clássicos (em que as variáveis normalmente têm significado físico explícito), os parâmetros ajustáveis de modelos de inteligência artificial não requisitam essa significação e, além de tudo, diferem, entre si, em vários aspectos. Por exemplo, para a solução de um mesmo problema de classificação, o número de vetores suporte de uma Máquina de Vetores Suporte (SVM, do inglês *Support Vector Machine*), o número de neurônios de uma rede neural e o número de monômios de uma aproximação polinomial, todos específicos em seu contexto, não têm qualquer relação de mutualidade (em princípio). Por conta disso, a própria escolha do modelo necessita ser submetida à avaliação estatística. Como consequência disso, a acurácia na estimativa dos parâmetros deixa de ser um problema em si mesmo. Isso, porque, dentro dessa ótica, a grande questão passa a ser a capacidade de generalização do modelo, ou seja, a capacidade deste de fornecer, para dados novos (que não foram usados para calcular os coeficientes), estimativas precisas da quantidade de interesse.⁷¹

2.7.1 Métodos de Validação

Em sua configuração mais simples, um problema de reconhecimento de padrões geralmente envolve dois conjuntos de dados: um para o treinamento, que é usado para a esti-

mativa de parâmetros, e um para a validação, que é usado para avaliar os mesmos. A aplicação de modelos não pode ser feita apenas a partir da avaliação de desempenho obtido com dados de treinamento: situações como essa podem ocorrer quando os exemplares de treino são relativamente escassos e a quantidade de parâmetros ajustáveis é inevitavelmente grande. Se o problema de aprendizagem se apresenta dessa forma, ele é considerado subdeterminado, ou seja, mesmo que os coeficientes se ajustem às amostras de treino de forma precisa, ainda assim eles resultam em um modelo de predição com desempenho ruim para novos dados (generalização precária). Esse efeito é popularmente conhecido como sobreajuste (do original em inglês, *overfitting*). Nesse sentido, o conjunto de validação fornece justamente um meio de detectar a presença desse efeito (pois, caso o desempenho com o conjunto de validação seja significativamente pior do que o desempenho com o conjunto de treinamento, isso indica a possibilidade de sobreajuste) e, além disso, comparar a capacidade de generalização de vários modelos. Se diversos destes forem comparados a partir do conjunto de validação, o melhor deles pode ser considerado uma estimativa otimista do desempenho de previsão em novos dados. Ainda assim, é conveniente separar um terceiro conjunto (chamado) de teste, diferente dos anteriores, para avaliar o resultado final do modelo.⁷²

¹ Platão. Parmênides, 166 c. In: Maura Iglésias, Fernando Rodrigues. *Parmênides. Texto grego estabelecido e anotado por John Burnet*. 3. ed. Rio de Janeiro & São Paulo: PUC-Rio & Loyola, 2003. p. 129.

² Pattern. *Wikipedia, the free encyclopedia*. Disponível em: <<https://en.wikipedia.org/wiki/Pattern>>. Acesso em: 18 ago. 2015.

³ Ian Stewart. *What shape is a snowflake?* 1. ed. London: Weidenfeld & Nicolson, 2001. p. 6.

⁴ Elly Vintiadis, E. Emergence. *Internet Encyclopedia of Philosophy*. Disponível em: <<http://www.iep.utm.edu/emergenc/>>. Acesso em: 18 ago. 2015.

⁵ Takao Nakanishi, Kyoji Takita, Yasuo Toyokura. Somatosensory evoked responses to tactile tap in man. *Electroencephalography and Clinical Neurophysiology*, v. 34, n. 1, p. 1-2, 1973.

⁶ Terence W. Picton et al. Human auditory evoked potentials. In: Evaluation of components. *Electroencephalography and Clinical Neurophysiology*, v. 36, n. 1, p. 179-185, 1974.

⁷ Gerd Kobal, Cornelia Hummel. Cerebral chemosensory evoked potentials elicited by chemical stimulation of the human olfactory and respiratory nasal mucosa. *Electroencephalography and Clinical Neurophysiology*, v. 71, n. 4, p. 241-242, 1988.

⁸ J. Vernon Odom et al. ISCEV standard for clinical visual evoked potentials (2009 update). *Documenta Ophthalmologica*, v. 120, n. 1, p. 111-119, 2010.

⁹ J. Vernon Odom et al. Visual evoked potentials standard (2004). *Documenta Ophthalmologica*, v. 108, n. 2, p. 116, 2004.

¹⁰ Danhua Zhu et al. A survey of stimulation methods used in SSVEP-based BCIs. *Computational Intelligence and Neuroscience*, v. 210, n. 1, p. 1-2, 2010.

¹¹ Danhua Zhu et al. Op. cit., p. 2-6, 2010.

¹² Luisa F. S. Uribe. *Desenvolvimento de uma interface homem-máquina baseada em potenciais evocados visuais em regime estacionário*. Dissertação (Mestrado em Engenharia Elétrica). Faculdade de Engenharia Elétrica e de Computação. Universidade Estadual de Campinas. Campinas. 2013. p. 20.

¹³ Danhua Zhu et al. Op. cit., p. 2-6, 2010.

¹⁴ Danhua Zhu et al. Op. cit., p. 6-7, 2010.

¹⁵ Billy R. Wooten. Photopic and scotopic contributions to the human visually evoked cortical potential. *Vision Research*, v. 12, n. 10, p. 1657-1658, 1972.

¹⁶ David Regan. An effect of stimulus colour on average steady-state potentials evoked in man. *Nature*, v. 210, n. 1, p. 1056 - 1057, 1966.

- ¹⁷ Danhua Zhu et al. Op. cit., p. 7-8, 2010.
- ¹⁸ Seiji Ogawa et al. Brain magnetic resonance imaging with contrast dependent on blood oxygenation. *Proceedings of the National Academy of Sciences*, v. 87, n. 24, p. 9868, 1990.
- ¹⁹ Arno Villringer et al. Near infrared spectroscopy (NIRS): a new tool to study hemodynamic changes during activation of brain function in human adults. *Neuroscience Letters*, v. 154, n. 1, p. 101, 1993.
- ²⁰ Eric R. Kandel. Nerve cells and behavior. In: Eric R. Kandel, James H. Schwartz, Thomas M. Jessell. *Principles of Neural Science*. 4. ed. New York: McGraw-Hill, 2000. p. 20-25.
- ²¹ John Koester, Steven A. Siegelbaum. Membrane potencial. In: Eric R. Kandel, James H. Schwartz, Thomas M. Jessell. *Principles of Neural Science*. 4. ed. New York: McGraw-Hill, 2000. p. 126.
- ²² John Koester, Steven A. Siegelbaum. Propagated signaling: the action potential. In: Eric R. Kandel, James H. Schwartz, Thomas M. Jessell. *Principles of Neural Science*. 4. ed. New York: McGraw-Hill, 2000. p. 150-160.
- ²³ Eric R. Kandel, Steven A. Siegelbaum. Synaptic integration. In: Eric R. Kandel, James H. Schwartz, Thomas M. Jessell. *Principles of Neural Science*. 4. ed. New York: McGraw-Hill, 2000. p. 212-219.
- ²⁴ Erwin-Josef Speckmann, Chrstian E. Elger. Introduction to the neurophysiological basis of the EEG and DC potentials. In: Ernst Niedermeyer, Fernando Lopes da Silva. *Electroencephalography: basic principles, clinical applications, and related fields*. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005. p. 17-19.
- ²⁵ Gary L. Westbrook. Seizures and epilepsy. In: Eric R. Kandel, James H. Schwartz, Thomas M. Jessell. *Principles of Neural Science*. 4. ed. New York: McGraw-Hill, 2000. p. 914-915.
- ²⁶ Herbert H. Jasper. The ten-twenty electrode system of the International Federation. *Electroencephalography and Clinical Neurophysiology*, v. 10, n. 1, p. 371-375, 1958.
- ²⁷ Edward L. Reilly. EEG recording and operation of the apparatus. In: Ernst Niedermeyer, Fernando Lopes da Silva. *Electroencephalography: basic principles, clinical applications, and related fields*. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005. p. 139-141.
- ²⁸ Marc R. Nuwer et al. IFCN standards for digital recording of clinical EEG. *Electroencephalography and Clinical Neurophysiology*, v. 106, n. 3, p. 259-261, 1998.
- ²⁹ Ernst Niedermeyer. The normal EEG of the waking adult. In: Ernst Niedermeyer, Fernando Lopes da Silva. *Electroencephalography: basic principles, clinical applications, and related fields*. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005. p. 167-168.
- ³⁰ Gregory L. Krauss, W. Robert S. Webber. Digital EEG. In: Ernst Niedermeyer, Fernando Lopes da Silva. *Electroencephalography: basic principles, clinical applications, and related fields*. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005. p. 798-800.
- ³¹ Edward L. Reilly. Op. cit., 2005. p. 155-157.
- ³² Edward L. Reilly. Op. cit., 2005. p. 157.
- ³³ Benjamin Blankertz et al. Optimizing spatial filters for robust EEG single-trial analysis. *IEEE Signal Processing Magazine*, v. 25, n. 1, p. 44, 2008.
- ³⁴ Richard G. Lyons. *Understanding Digital Signal Processing*. 2. ed. New Jersey: Prentice Hall PTR, 2004. p. 157.
- ³⁵ Stephen Butterworth. On the theory of filter amplifiers. *Wireless Engineer*, v. 7, n. 6, p. 536, 1930.
- ³⁶ G. Alarcon, C. N. Guy, C. D. Binnie. A simple algorithm for a digital three-pole Butterworth filter of arbitrary cut-off frequency: application to digital electroencephalography. *Journal of Neuroscience Methods*, v. 104, n. 1, p. 35-36, 2000.
- ³⁷ Gregory L. Krauss, W. Robert S. Webber. Op. cit., 2005. p. 807.
- ³⁸ Edward L. Reilly. Op. cit., 2005. p. 149.
- ³⁹ Gary Garcia-Molina, Danhua Zhu. *Optimal spatial filtering for the steady state visual evoked potential: BCI application*. Proceedings of the 5th International IEEE EMBS Conference on Neural Engineering. Cancun: [s.n.], 2011. p. 156.
- ⁴⁰ Dennis J. Mcfarland et al. Spatial filter selection for EEG-based communication. *Electroencephalography and Clinical Neurophysiology*, v. 103, n. 3, p. 387, 1997.
- ⁴¹ Dennis J. Mcfarland et al. Op. cit., p. 388-389, 1997.
- ⁴² Christopher M. Bishop. *Pattern Recognition and Machine Learning*. 1. ed. New York: Springer, 2006. p. 2.
- ⁴³ Richard Duda, Peter E. Hart, David Stork. *Pattern Classification*. 2. ed. New York: John Wiley & Sons, 2001. p. 11.
- ⁴⁴ Avrim L. Blum, Pat Langley. Selection of relevant features and examples in machine learning. *Artificial Intelligence*, v. 97, n. 1, p. 247-248, 1997.
- ⁴⁵ Avrim L. Blum, Pat Langley. Op. cit., p. 248-249, 1997.
- ⁴⁶ Isabelle Guyon, André Elisseeff. An introduction to variable and feature selection. *Journal of Machine Learning Research*, v. 3, n. 1, p. 1170-1171, 2003.
- ⁴⁷ Isabelle Guyon, André Elisseeff. An introduction to feature extraction. In: Isabelle Guyon et al. *Feature Extraction: Foundations and Applications*. 1. ed. New York: Springer, 2006. p. 2-4.

-
- ⁴⁸ Günter Bodenstern, H. Michael Praetorius. Feature extraction from the electroencephalogram by adaptive segmentation. *Proceedings of the IEEE*, v. 65, n. 5, p. 642-652, 1977.
- ⁴⁹ Pierre Duhamel, Vitterli Martini. Fast Fourier transforms: a tutorial review and a state of the art. *Signal Processing*, v. 19, n. 4, p. 259-299, 1990.
- ⁵⁰ Richard G. Lyons. Op. cit., 2004. p. 41-42.
- ⁵¹ Richard G. Lyons. Op. cit., 2004. p. 42.
- ⁵² James W. Cooley, John W. Tukey. An algorithm for the machine calculation of complex Fourier series. *Mathematics of Computation*, v. 19, n. 90, p. 297-301, 1965.
- ⁵³ Richard G. Lyons. Op. cit., 2004. p. 113.
- ⁵⁴ Peter D. Welch. The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. *IEEE Transactions on Audio and Electroacoustics*, v. 15, n. 2, p. 70-73, 1967.
- ⁵⁵ Christopher M. Bishop. Op. cit., 2006. p. 3.
- ⁵⁶ Richard Duda, Peter E. Hart, David Stork. Op. cit., 2001. p. 11-12.
- ⁵⁷ Christopher M. Bishop. Op. cit., 2006. p. 181-182.
- ⁵⁸ Richard Duda, Peter E. Hart, David Stork. Op. cit., 2001. p. 216-217.
- ⁵⁹ Christopher M. Bishop. Op. cit., 2006. p. 182-183.
- ⁶⁰ Richard Duda, Peter E. Hart, David Stork. Op. cit., 2001. p. 218-219.
- ⁶¹ Richard Duda, Peter E. Hart, David Stork. Op. cit., 2001. p. 239-240.
- ⁶² Richard Duda, Peter E. Hart, David Stork. Op. cit., 2001. p. 240-241.
- ⁶³ Roger Penrose. A generalized inverse for matrices. *Mathematical Proceedings of the Cambridge Philosophical Society*, v. 51, n. 3, p. 406-413, 1955.
- ⁶⁴ Christopher M. Bishop. Op. cit., 2006. p. 186-189.
- ⁶⁵ Ronald A. Fisher. The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, v. 7, n. 2, p. 179-182, 1936.
- ⁶⁶ Avrim L. Blum, Pat Langley. Op. cit., p. 247-247, 1997.
- ⁶⁷ Isabelle Guyon, André Elisseeff. Op. cit., 2006. p. 4-5.
- ⁶⁸ Ron Kohavi, George H. John. Wrappers for feature subset selection. *Artificial intelligence*, v. 97, n. 1, p. 275-276, 1997.
- ⁶⁹ Ron Kohavi, George H. John. Op. cit., p. 280, 1997.
- ⁷⁰ Włodzisław Duch. Filter methods. In: Isabelle Guyon et al. *Feature Extraction: Foundations and Applications*. 1. ed. New York: Springer, 2006. p. 89-117.
- ⁷¹ Gérard Dreyfus, Isabelle Guyon. Assessment methods. In: Isabelle Guyon et al. *Feature Extraction: Foundations and Applications*. 1. ed. New York: Springer, 2006. p. 78.
- ⁷² Gérard Dreyfus, Isabelle Guyon. Op. cit., 2006. p. 78-79.

3 DESENVOLVIMENTO DE SSVEP-BCI

Durante qualquer pesquisa com BCIs, em algumas etapas de seu desenvolvimento, é necessária a participação de voluntários saudáveis para testar o sistema. Por conta disso, o projeto, o uso e o desempenho de cada procedimento a ser usado devem ser claramente formulados em um protocolo experimental. Este, por sua vez, depois precisa ser submetido à análise, ponderação, orientação e subsequente aprovação de um comitê de ética, especialmente indicado para essa tarefa e diligentemente isento de patrocínios e pesquisadores, ou outros tipos de influência indevida, que possam causar conflitos de interesse. Esse comitê independente tem que estar em conformidade com as leis e regulamentações do país no qual a pesquisa é realizada e, além disso, tem que monitorar os estudos em andamento, bem como exigir, dos responsáveis pelos mesmos, informações e explicações a respeito de eventos adversos (principalmente os graves), se por ocasião tenham ocorrido.¹ No Brasil, o Conselho Nacional de Saúde (CNS), através da Resolução 196/96, criou a Comissão Nacional de Ética em Pesquisa (CONEP) para implementar as normas e diretrizes que regulamentam as pesquisas com a participação de seres humanos. O CONEP tem função consultiva, deliberativa, normativa e educativa. Ele atua em conjunto com uma rede de Comitês de Ética em Pesquisa (CEPs) organizados nas instituições onde as próprias investigações científicas são realizadas. Portanto, a Unicamp apresenta um CEP para acompanhar e avaliar os aspectos éticos de todos os estudos com a participação de voluntários humanos. Todo projeto de pesquisa deve ser entregue no CEP responsável pelo acompanhamento da mesma e, a partir disso, precisa receber um número de identificação, o qual corresponde ao Certificado de Apresentação para Apreciação Ética (CAAE).² Como já mencionado na “Introdução”, o desenvolvimento desta SSVEP-BCI esteve vinculado ao projeto DESTINE, que foi aprovado pelo CEP da Unicamp em 11/08/2010 (protocolo CEP 791/2010, CAAE 0617.0.146.000-10). Para o presente estudo, dez participantes saudáveis, oito homens e duas mulheres, com idade média de $26,3 \pm 3,3$ anos, consentiram em capturar registros eletroencefalográficos com a finalidade de montar um banco de dados para testar o sistema – os detalhes sobre o protocolo de aquisição estão na seção 3.7, no final do capítulo, e o Termo de Consentimento Livre e Esclarecido (TCLE), para voluntários sadios, está em anexo.

A partir de todos os esclarecimentos e conhecimentos expostos anteriormente, foi possível desenvolver uma versão preliminar de uma interface-cérebro computador de acordo com as especificações desejadas, parte delas, inclusive, já enunciadas no primeiro capítulo.

Embora, até o momento, a exposição privilegiasse uma sequência didática para tentar assegurar uma boa compreensão sobre alguns dos fundamentos técnicos acerca do desenvolvimento de SSVEP-BCI, a estruturação desse sistema não apresentou, de fato, a mesma linha de raciocínio e, de certa forma, representou uma mistura de todas as informações tratadas até o momento. No entanto, para ordenar minimamente todos os algoritmos de processamento de sinais e, além disso, organizar o funcionamento da interface, os procedimentos computacionais recorrentes foram agrupados em módulos – que são núcleos de realização de tarefas compostos por funções auxiliares que trabalham para alcançar um objetivo em comum – e, assim, o protocolo de operação se resumiu a criar uma rotina de execução desses módulos básicos. A SSVEP-BCI deste estudo foi projetada com cinco deles: o de estimulação, o de aquisição, o de processamento, o de treinamento e o de comunicação e controle. A integração e intercomunicação precisas entre essas estruturas modulares, como será visto daqui em diante, garantiu a execução da BCI.

3.1 ESTIMULAÇÃO.

A grande atração em usar monitores para gerar as estimulações visuais é que os mesmos, por meio de programação, propiciam a exibição de uma ampla variedade de estampas e padrões. Tais programas são frequentemente escritos em linguagens de sistemas – por exemplo, C ou Pascal – para conseguir total controle do equipamento e, assim, alcançar a devida precisão do estímulo. Mas, embora essas linguagens sejam flexíveis, elas não são conducentes com um rápido e (às vezes necessário) desenvolvimento. Por outro lado, linguagens interpretativas – como BASIC, LISP, Mathematica e MATLAB – procuram abstrair os detalhes do dispositivo e fornecem um ambiente de criação mais generoso; porém, não asseguram a geração acurada porque não acessam as instruções de máquina. Para aliar as melhores características de ambas, existem pacotes algorítmicos que são capazes de integrar essas duas funcionalidades, como é o caso da *Psychophysics Toolbox Version 3* – uma caixa de ferramentas gratuita para MATLAB com funções dedicadas a sintetizar e mostrar, com exatidão, estímulos sonoros e visuais controlados, geralmente voltados às pesquisas em neurociências.³

Sinteticamente chamada de Psychtoolbox-3, esse conjunto de aplicações estabelece uma interface entre a plataforma do MATLAB e o controle de máquina que dirige as configurações do monitor. As rotinas do núcleo da Psychtoolbox permitem acesso à memória de imagem da tela (*display frame buffer*) e à tabela de tratamento das cores (*color look-up table*), o que as capacitam a sincronizar com o intervalo de apagamento vertical (*vertical blanking*

interval), temporizar em submúltiplos de milissegundos e exibir, caso necessário, comandos de OpenGL – que é uma biblioteca de funções específicas para computação gráfica 2D e 3D.⁴ Por consequência, esses atributos tornam essa caixa de ferramentas adequada à confecção de estímulos visuais repetitivos, com a precisão necessária para suscitar os SSVEPs, e também tornam-na apropriada à redução no tempo e esforço de desenvolvimento.⁵ Isso tudo foi o que levou à escolha da Psychtoolbox-3 como ferramenta auxiliar para o desenvolvimento de trechos de código para a geração dos estímulos visuais repetitivos.

3.1.1 Módulo de Estimulação

O módulo de estimulação, no contexto deste estudo, deve ser entendido como uma única função que, quando inicializada, exibe no monitor um conjunto de RVSs pré-definidos, como ilustrado pelo pseudocódigo da Tabela 3.1 adiante. Essa função tem, como variáveis de entrada, a frequência f_n de cada estímulo $n = 1, 2, \dots, N$ e o número de quadriculados laterais Q necessários para compor a estampa xadrez. Como saída, o algoritmo constantemente atualiza os padrões reversos de acordo com suas frequências. Para isso, utiliza-se o intervalo de atualização da tela t , o número de quadros q_n que deve ser transcorrido para cada frequência f_n e contadores c_n para monitorar o momento de troca das estampas, de forma a criar um laço de código em que essa mudança ocorra indefinidamente (até que a tecla *escape* seja pressionada). As posições dos estímulos foram pré-estabelecidas, ou seja, o módulo não foi preparado para recebê-las: modificações dessa natureza precisariam ser reprogramadas. Outra peculiaridade é que a Psychtoolbox-3, para garantir a acurácia nas taxas de atualização, requer uma exibição em modo de tela cheia e, geralmente, necessita da ausência de outras aplicações concorrentes. Por conta disso, o módulo de estimulação foi criado para executar (independentemente dos demais módulos) em um computador (embora de propósito geral) dedicado apenas para a exibição dos RVSs desejados.

Para o caso de aplicação na cadeira de rodas com controle compartilhado, esse isolamento (em princípio) não restringiria a funcionalidade geral dos comandos por BCI, uma vez que a realimentação para um usuário já é estabelecida naturalmente pelos movimentos (certos e errados) do referido veículo. Para o caso de aquisições com a finalidade de montar bancos de dados de SSVEPs (para posterior desenvolvimento de algoritmos voltados ao aprendizado de máquina, ao reconhecimento de padrões e ao processamento de sinais), esse isolamento também não implicaria em fortes restrições, uma vez que as instruções adicionais para um indivíduo podem ser enviadas via sistema auditivo. No entanto, para uma aplicação

em que o resultado dos comandos esteja vinculado a acontecimentos subsequentes na própria tela de estimulação, o esquema proposto, como dificultaria o intercâmbio de informações entre o módulo de estimulação e os outros módulos, poderia resultar em atrasos de comunicação e perda de desempenho na realização da tarefa. Nessa situação, talvez fosse mais conveniente executar, em um único núcleo de processamento, todos os módulos da interface cérebro-computador. Mas isso, por sua vez, levaria a outros desafios de projeto: programar paralelamente sem que haja perda de precisão na taxa de atualização dos estímulos, por exemplo.

Tabela 3.1: Algoritmo da função de exibição dos RVSs.

```

Input: blink frequencies  $f_n$  for each stimulus  $n = 1, 2, \dots, N$  and
       number of lateral squares  $Q$  at the checkerboard.
Output: display stimuli interface on full screen mode.

1  begin
2      setup the Psychtoolbox default settings
3      create the reversal checkerboard prints according to  $Q$ 
4      define positioning of each stimulus
5      define  $c_n$  counters
6       $t \leftarrow$  flip interval of window
7       $q_n \leftarrow$  round  $f_n / t$ 
8       $c_n \leftarrow$  zero
9      display checkerboard
10     while escape
11         if  $c_n$  equals  $q_n$ 
12             change the current print by the reversal pattern
13             display checkerboard
14              $c_n \leftarrow$  zero
15         end
16     end
17     return
18 end

```

O módulo de estimulação foi programado para exibir, simultaneamente e em posições fixas, de um a quatro estímulos com o mesmo padrão. Isso, no entanto, não representa qualquer limitação desse sistema, apenas uma escolha de desenvolvimento. O código é suficientemente flexível para reprogramar telas que exibam mais incitações e que, se for necessário, permitam a visualização de padrões diferentes. Em princípio, uma tela com até quatro estímulos satisfazia as exigências iniciais do estudo. Maiores detalhes de como criá-los e configurá-

los são facilmente encontradas na página do desenvolvedor da Psychtoolbox-3, que (para isso) fornece um amplo repertório de documentos e tutoriais.

3.1.2 Funcionamento do Módulo de Estimulação

Uma vez definidas as entradas da função de exibição dos RVSs, a simples execução desse algoritmo dá início ao funcionamento do módulo de estimulação: o monitor entra em modo de tela cheia e começa a exibir os estímulos com as configurações desejadas. Como forma de ilustrar isso, adiante estão expostos os instantâneos de três tipos possíveis de incitações obtidas com a execução direta dele (sem a exigência de reprogramação, portanto). Com o propósito de realizar análises futuras a respeito de sua própria capacidade de evocação e também para ajudar na compreensão do funcionamento de outros módulos, as capturas de tela exibem as representações de estímulos com padrões quadriculados distintos que (apenas para fins desta pesquisa) receberam as seguintes denominações: figura simples (Figura 3.1), padrão reverso 1 (Figura 3.2) e padrão reverso 2 (Figura 3.3).




Figura 3.1: Instantâneo da tela de exibição do RVS em formato de figura simples, com as proporções (embora menores) mantidas. O estímulo da esquerda piscava em 12 Hz e o da direita em 15 Hz. Propositadamente, a imagem mostra as estampas contrárias.

Na situação real, para os três casos, os RVSs da esquerda piscavam a 12 Hz e os da direita a 15 Hz. Embora as imagens mostrem propositadamente as estampas contrárias, convém lembrar que elas, durante a execução do módulo, alternavam-se de acordo com a taxa de repetição estipulada para cada estímulo. Preferencialmente, o brilho do monitor sempre foi mantido no máximo, desde que a intensidade luminosa não incomodasse o usuário. A propor-

ção entre a dimensão da tela e a área das estampas está representada em escala com um monitor de 15 polegadas (1366×768 pixels), com a diferença de que, em tamanho original, as laterais dos quadrados teriam cerca de quatro centímetros (180 pixels, exatamente).




Figura 3.2: Instantâneo da tela de exibição do RVS em formato de padrão reverso 1, com as mesmas convenções da Figura 3.1.




Figura 3.3: Instantâneo da tela de exibição do RVS em formato de padrão reverso 2, com as mesmas convenções da Figura 3.1.

Para obter o máximo contraste, os padrões foram criados com as cores branca e preta; mas uma simples mudança, em uma das linhas de código, permite a alteração para quaisquer colorações dentro do sistema de cores aditivas para dispositivos eletrônicos, composto por Vermelho, Verde e Azul (RGB, do inglês *Read, Green and Blue*). Para aumentar ou

diminuir a área dos estímulos, também é preciso realizar poucas modificações no programa-fonte, embora o tamanho tenha sido ajustado em consonância com exemplos encontrados na literatura (já abordados em parte da introdução e em seções dos capítulos 1 e 2). Por sua vez, a densidade de visualização dos quadriculados, como visto há pouco, é configurada diretamente por uma das variáveis de entrada do módulo de estimulação. O principal motivo para isso é que, de acordo com a preferência de cada usuário, essa densidade pode ser ajustada para promover um maior conforto visual durante a utilização da SSVEP-BCI. Em geral, não há uma decisão consensual sobre a estampa mais agradável de olhar e, por isso, tal como a taxa de repetição do estímulo, esse parâmetro tem que ser igualmente flexível para realizar testes rápidos um pouco antes de experiências com a interface. Além disso, para um mesmo indivíduo e para uma mesma frequência de incitação, variações nesse parâmetro (aparentemente simples) curiosamente suscitam diferentes padrões de evocação (isso ficará claro, em seções adiante, ao longo das análises realizadas para cada um dos RVSS propostos).

Enfim, há poucos estudos que tentam identificar ou estabelecer alguma forma de associação entre as variações na configuração do estímulo e os SSVEPs resultantes dessas alterações visuais (cor, contraste, forma, tamanho, estampa e frequência). Por causa disso, além de evidentemente integrar a BCI deste estudo, o módulo de estimulação foi igualmente projetado para auxiliar pesquisas futuras com diferentes RVSS padronizados, de forma que permita investigar possíveis regularidades entre cada um deles e o seu respectivo potencial evocado.

3.2 AQUISIÇÃO

Os equipamentos disponíveis para a gravação do sinal de EEG foram basicamente dois: o g[®].USBamp e o g[®].SAHARAsys. O g.USBamp é um amplificador de sinais biológicos que permite aquisições de eletroencefalografia, eletro-oculografia, eletromiografia e eletrocardiografia – com 16 canais, 24 bits de informação e uma frequência de amostragem que pode ser ajustada para valores específicos contidos no intervalo de 64 Hz a 38.400 Hz. O amplificador possui quatro coletores de potenciais (separados) e cada um deles tem quatro entradas de canal. Isto possibilita gravar simultaneamente e sem interferência os diferentes tipos de registro mencionados. Além disso, esses quatro coletores podem ser devidamente interligados para adquirir 16 canais de EEG, com um mesmo aterramento e uma mesma referência para todos eles. Esse amplificador, a partir de um conector USB, pode ser acoplado diretamente a um computador e não precisa de nenhum outro dispositivo eletrônico adicional para a aquisi-

ção de dados. Além disso, o aparelho tem internamente uma unidade de calibração e outra de verificação de impedância, bem como conectores para receber os eletrodos específicos das técnicas de medida citadas anteriormente. Uma última característica importante é que o g.USBamp pode ser controlado por APIs, geralmente fornecidas pelo fabricante do produto. Uma delas permite ativar as funções do amplificador diretamente do ambiente MATLAB 2012b para Windows® 7 de 32 bits, a plataforma de desenvolvimento escolhida para elaborar a BCI.⁶

Já o g.SAHARAsys é um sistema de eletrodos secos e ativos que realiza derivações eletrofisiológicas não invasivas. Os eletrodos são considerados secos porque são transdutores elétricos alternativos à versão úmida (eletrodos de gel), principalmente para eliminar a preparação da pele e a aplicação da pasta eletrolítica: ambas para redução das impedâncias na superfície de contato, embora tais procedimentos normalmente tornem mais demorados os ensaios experimentais. Os eletrodos secos, no entanto, acabam justamente por apresentar impedâncias elevadas, o que amplifica o ruído do sinal (fato tratado com um pouco mais de detalhamento no tópico seguinte). Assim, para que eles possam ter utilidade, elas, por sua vez, precisam ser convertidas localmente para quantidades menores. A forma mais apropriada de reduzi-las é através de um amplificador de conversão local. Nesse contexto, os eletrodos são considerados ativos porque eles empregam diretamente no sítio de detecção essa transformação de impedância – através de circuitos eletrônicos ativos.⁷ Ademais, o g.SAHARAsys permite a aquisição de 16 canais, possui dois eletrodos de gel eletrolítico (um para a referência e outro para o terra) e é projetado para uso em amplificadores com entrada unipolar ou diferencial. Esse sistema de eletrodos funciona em conjunto com o g.USBamp.⁸

Além de dispositivos apropriados (como os indicados há pouco), para realizar uma determinada aquisição de EEG, a seleção dos canais é de suma importância porque, como ficará evidente na sequência da exposição, ela tem grande impacto para o modo de gravação e para o número final de eletrodos a serem usados. Convencionou-se em chamar de “montagem” a combinação particular de eletrodos resultante dessa escolha. Em geral, diferentes disposições são utilizadas com propósitos bem específicos. Não obstante, a montagem apresenta ao menos duas funções simultâneas. A primeira é abranger o maior número de áreas possíveis do escalpo para adquirir os dados e, em consonância com esse propósito, usar todos os eletrodos do sistema 10-20 estendido satisfaria esse objetivo. A segunda, em contrapartida, é registrar de tal maneira que fique perceptível a presença de certas manifestações cerebrais de interesse, que podem ser favoravelmente observadas em sítios corticais pertinentes.⁹ De acordo com essas considerações, somadas ao intuito de identificar SSVEPs para aplicação em

BCI, e depois de recorrentes testes experimentais ao longo do desenvolvimento da interface, a montagem definitiva, indicada na Figura 3.4, privilegiou o registro com eletrodos nas regiões central, parietal e occipital, conforme enfileirado a seguir: O1, O2, Oz, PO3, PO4, PO7, PO8, POz, P1, P2, Pz, CPz, C1,C2, Cz, FCz. O arranjo final ficou limitado em 16 eletrodos porque era o máximo número de canais que os equipamentos disponíveis comportavam.




Figura 3.4: Montagem dos eletrodos para aquisição de SSVEPs.¹⁰

Igualmente importante é a escolha da referência dos eletrodos. Isso porque, uma vez que tanto os potenciais evocados quanto os potenciais intrínsecos à atividade natural do cérebro são considerados elementos que refletem distintas unidades geradoras, cada um destes pode ser definido (e reconhecido) por atributos específicos: polaridade, região de ocorrência no escalpo, conteúdo espectral, latência, tensão, entre outros. Em geral, essas propriedades seriam idealmente caracterizadas a partir de um potencial neutro (ou referencial nulo); contudo, sabe-se que, na natureza, é possível apenas mensurar (comparar) a diferença de potencial entre dois pontos. Logo, para fazer aquisições de EEG, também é indispensável definir um sítio de referência, e é desejável que este (ao menos) apresente em torno dele um campo elétrico (tanto quanto for possível) constante. Exemplos de pontos de referência para efetuar o registro eletroencefalográfico são o vértice da cabeça (Cz), a ponta do nariz, um dos mastoi-

des, um dos lóbulos da orelha, entre outros. Cada um deles tem efeitos particulares sobre as gravações e devem ser avaliados de acordo com as necessidades da pesquisa. Essa decisão tem forte impacto porque quaisquer manifestações elétricas que ocorram na proximidade do eletrodo de referência afetam as medições de todos os demais eletrodos (independente do posicionamento deles). Para tentar contornar esse inconveniente, durante um bom tempo, buscou-se algum ponto na superfície corporal que não fosse eletricamente ativo (neutro), mas o que se concluiu (de fato) é que esse ponto não existe porque as atividades eletrofisiológicas se comportam como processos dinâmicos distribuídos espaço-temporalmente.¹¹ No caso deste estudo, por indicação do próprio fabricante do aparelho de EEG, o eletrodo de referência e outro de aterramento foram posicionados nos mastoides.¹²

3.2.1 Módulo de Aquisição: Estrutura e Funcionamento

O módulo de aquisição é dividido em duas partes procedimentais: (1) a configuração da aparelhagem necessária para adquirir adequadamente os dados e (2) a medição e o armazenamento dos mesmos. A precedente, em geral, é realizada uma única vez, no início de todo ensaio experimental, e se incumbe de efetuar a calibração dos canais de amplificação, a verificação da impedância dos eletrodos, a criação da entrada analógica e as configurações da mesma; enquanto a posterior é a parte responsável (sempre que for requisitada) por aferir os valores de tensão de cada eletrodo e armazená-los de forma sistemática, para os processos ulteriores.

Quanto às configurações do aparelho de EEG, a primeira delas é a calibração do amplificador de sinais biológicos. A amplitude de um sinal digital (que se deseja monitorar) costuma ser calibrada por meio do envio de um sinal de referência (com amplitude A bem conhecida) através dos canais de amplificação de dados (que se pretende utilizar).¹³ Isso permite corrigir eventuais distorções e, nesse sentido, mostra que qualquer amplitude mensurada com o uso de um canal é (na verdade) conhecida em relação à amplitude de um sinal de referência. Essa correção acontece da seguinte forma: enquanto um sinal de referência é amostrado pelo conversor analógico-digital, uma sequência de códigos avalia a faixa de valores inteiros usada para quantificá-lo e amplificá-lo e guarda essa informação em uma constante C denominada fator de escala; além deste, todo amplificador (para cada canal) apresenta uma constante Z associada ao nível zero-volt do ADC; assim, com o uso dessas constantes, os valores das amostras digitais $s[n]$ são instantaneamente convertidos para voltagens $x[n]$ (antes de qualquer análise quantitativa do sinal medido), como mostrado na equação 3.1 adiante.¹⁴

$$x[n] = A \left(\frac{s[n] - Z}{C} \right) \quad (3.1)$$

O g.USBamp utiliza, como sinal de referência padrão, uma onda senoidal com amplitude de 250 mV e frequência de 10 Hz. Durante a calibração, os eletrodos são internamente desconectados dos canais. Com o uso da API, as chamadas que ajustam (gUSBampCalibration) e salvam (gUSBampSaveCalibration) o fator de escala (scaling) e o nível zero-volt (offset), para cada canal, estão no trecho de código a seguir.

```
%-----
%   g.USBamp Calibration
%-----
amplifierId = 'UB-2011.11.46';
[offset, scaling] = gUSBampCalibration(amplifierId, true);
gUSBampSaveCalibration(offset, scaling, amplifierId);
%-----
```

Após a calibração, é preciso criar uma entrada analógica para receber os dados de EEG. Para isso, faz-se uso de funções do MATLAB fornecidas através da caixa de ferramentas para aquisição de dados (*Data Acquisition Toolbox*). Para essa caixa, a conexão com o g.USBamp é vista como um adaptador cuja chamada tem o nome 'guadaq'. Nesse sentido, a primeira etapa para realizar quaisquer registros é a criação de uma entrada analógica (analogInput). Para isso, é preciso apenas criar um objeto de dispositivo – por meio da função analoginput, que recebe o nome e a porta do referido adaptador, como sugerido abaixo. Evidentemente que, antes de usar esse objeto, algumas configurações precisam ser feitas (geralmente com o uso da função set) para assegurar a qualidade dos dados de entrada. As principais serão abordadas na sequência da exposição.

```
%-----
%   g.USBamp Analog Input
%-----
gUSBampAdaptor = daqhwinfo('guadaq');
stringBoardIds = gUSBampAdaptor.InstalledBoardIds;
numericBoardIds = str2double(stringBoardIds);
analogInput = analoginput('guadaq', numericBoardIds);
%-----
```

Outro procedimento importante é a verificação das impedâncias de contato entre os eletrodos e a pele (superfície do escalpo). Isso é necessário porque, como sugerido há pouco, caso essas impedâncias forem elevadas, a qualidade do sinal de EEG se reduz. Esse impacto negativo ocorre, sobretudo, porque elas (quando extrapolam um limite) diminuem consideravelmente a rejeição de modo comum – a capacidade que um sistema de aquisição deve ter para rejeitar os ruídos comuns aos eletrodos ativos e ao eletrodo de referência. Ou seja, quaisquer fontes ruidosas idênticas devem ser atenuadas pelo amplificador diferencial para

que na saída do mesmo a tensão medida não esteja repleta de interferentes provocados (principalmente) por dispositivos elétricos presentes no ambiente de gravação. Para conseguir isso (pelo menos em parte), esses amplificadores já são projetados com uma alta impedância de entrada (da ordem de $M\Omega$), fixa e estável. Por outro lado, a impedância do eletrodo varia de forma perceptível e, nesse caso, pode atingir valores elevados subitamente (acima de $50 K\Omega$). Quando isso ocorre, a razão entre as duas impedâncias abordadas (a segunda dividida pela primeira) aumenta e, com isso, a rejeição de modo comum e (por consequência) a relação sinal ruído diminuem. Os eletrodos ativos (que reduzem a impedância localmente) são confeccionados justamente para minimizar esse efeito.¹⁵

O g.USBamp tem uma unidade para medir, em relação ao eletrodo de aterramento, a impedância de cada um dos eletrodos secos. Para usá-la, basta colocar a entrada analógica (analogInput) em modo 'Impedance' e, depois, chamar a função gUSBampImpedance. Como resultado, ela retorna o vetor impedanceMeasure com os respectivos valores de impedância em Kohms. Dessa forma, foi possível criar um trecho de código (como sugerido abaixo) que atualizasse a verificação das impedâncias e que não permitisse seguir com os demais comandos do módulo até que as mesmas estivessem abaixo de $5 K\Omega$ – limite comumente aceito pela literatura. Geralmente, os motivos que levam alguma impedância a exceder esse marco estão associados com os seguintes fatos: o eletrodo em questão não está devidamente encostado no escalpo, o usuário pode estar se movimentando em demasia, os eletrodos de referência e aterramento já estão desgastados (o gel eletrolítico perdeu o efeito) e por isso precisam ser substituídos, entre outros. Mas independentemente da causa, enquanto o limiar não fosse atingido, a aquisição não prosseguia.

```
%-----
%   g.USBamp Impedance
%-----
set(analogInput, 'Mode', 'Impedance');
while impedanceMeasure > impedanceReferenceValues
    impedanceMeasure = gUSBampImpedance(amplifierId, true);
end
%-----
```

Após a verificação e a certificação das impedâncias dos eletrodos, é necessário configurar a entrada analógica (analogInput) criada anteriormente. Em primeiro, decide-se o número de canais com o uso da chamada addchannel. Depois, por meio da função set, estabelece-se a taxa de amostragem ('SampleRate'), o modo de armazenagem dos dados ('BufferingMode') e o modo de operação da entrada analógica ('Mode'). Neste estudo, channelsNumber = 16, sampleRate = 256 e o 'BufferingMode' foi definido como 'Auto' (o que significa atribuir ao MATLAB o gerenciamento da memória para aquisição de

dados com dispositivos externos). Por fim, a entrada analógica foi reestabelecida para executar em modo `'Normal'`, o que indica ao amplificador que serão feitas medidas de sinais biológicos. Essas configurações estão mostradas abaixo.

```
%-----
%   g.USBamp Settings
%-----
addchannel(analogInput, 1:channelsNumber);
set(analogInput, 'SampleRate', sampleRate);
set(analogInput, 'BufferingMode', 'Auto');
set(analogInput, 'Mode', 'Normal');
%-----
```

Outra configuração importante para a entrada analógica é o agrupamento do aterramento e da referência para os canais. Como dito no início da seção 3.2, o `g.USBamp` tem quatro grupos (A, B, C e D) de quatro canais cada. Por conta disso, para fazer aquisições com 16 eletrodos e estabelecer que todos eles tenham os mesmos soquetes de aterramento e referência, basta habilitar essa funcionalidade com o uso das instruções de código na sequência.

```
%-----
%   g.USBamp Ground and Reference
%-----
set(analogInput, 'GroupAToCommonGround', 'Enable', ...
    'GroupAToCommonReference', 'Enable');
set(analogInput, 'GroupBToCommonGround', 'Enable', ...
    'GroupBToCommonReference', 'Enable');
set(analogInput, 'GroupCToCommonGround', 'Enable', ...
    'GroupCToCommonReference', 'Enable');
set(analogInput, 'GroupDToCommonGround', 'Enable', ...
    'GroupDToCommonReference', 'Enable');
%-----
```

Além das configurações básicas, o `g.USBamp` fornece um conjunto de filtros digitais Butterworth passa-banda e *notch*. Para saber quais deles estão disponíveis, executa-se a instrução `gUSBampShowFilter(sampleRate)`, que retorna, na janela de comando, uma lista com a numeração de todos os filtros disponíveis para aquela taxa de amostragem.

```
%-----
%   g.USBamp Bandpass Filters
%-----
%   Valid Bandpass Filters for 256 Hz:
%   Filter: HP:      LP:      Order:  Type:
%   -----
%   32      0.10     0.00      8      butter
%   33      1.00     0.00      8      butter
%           ⋮
%   52      5.00     60.00     8      butter
%   53      5.00     100.00    8      butter
%-----
for k = 1:channelsNumber
    set(analogInput.Channel(k), 'BPIndex', 52);
end
%-----
```

Como exemplos, os trechos de programa anterior e posterior sugerem respectivamente as escolhas de um filtro passa-banda (5-60 Hz) e um filtro *notch* (58-62 Hz). Os filtros são configurados por canal e indicados pela sua numeração. Isso permite que nem todos os canais sejam filtrados (caso se queira). A utilização desses recursos, fornecidos pelo amplificador g.USBamp, já reduz consideravelmente ruídos que se manifestam fora da faixa de interesse e igualmente elimina boa parte do artefato em 60 Hz provocado pela rede de energia elétrica. Além disso, executar a filtragem em conjunto com as aquisições poupa esforço computacional durante a operação do módulo de processamento (tratado na próxima seção), que estaria incumbido de realizar essa tarefa, caso a mesma não pudesse ser feita de antemão.

```
%-----
%   g.USBamp Notch Filters
%-----
%   Valid Notch Filters for 256 Hz:
%   Filter: HP:      LP:      Order:  Type:
%
%   2          48.00   52.00      4      butter
%   3          58.00   62.00      4      butter
%-----
for k = 1:channelsNumber
    set(analogInput.Channel(k), 'NotchIndex', 3);
end
%-----
```

Todas essas chamadas de funções mostradas até o momento foram agrupadas em uma sequência de código que, quando executada, realiza de imediato as configurações e verificações necessárias para o uso da aparelhagem eletroencefalográfica, ou seja, a união de todas elas compõe essa primeira parte procedimental do módulo de aquisição. A segunda parte, por sua vez, reúne as instruções para medir e armazenar os dados (de fato) sempre que se quiser monitorar a atividade cerebral do usuário. Para isso, a entrada analógica (`analogInput`) deve ser informada a respeito da quantidade de registros (`dataNumber`) que se deseja adquirir durante uma inspeção (`'SamplesPerTrigger'`) e depois deve ser inicializada por meio do comando `start`, como sugerido no código adiante. Então, um laço `while` aguarda o número de amostras disponíveis (`analogInput.SamplesAvailable`) atingir a quantia especificada anteriormente, para que as mesmas sejam subsequentemente capturadas (`getdata`) e salvas (`save`). Com o uso dessas funções, esses dados automaticamente vêm formatados de forma matricial: as linhas representam o número de amostras e as colunas o número de eletrodos. Para exemplificar o funcionamento dessa sequência de instruções, suponha a realização de uma aquisição de 12 segundos, com o uso de 16 canais, enquanto um usuário olha para um dos estímulos, e feita para integrar um conjunto de treinamento. Com uma taxa de amostragem de 256 Hz, a entrada analógica recebe um `dataNumber = 12 · 256`, é inicializada, aguar-

da todas 3072 amostras (de cada canal) serem mensuradas e disponibilizadas e, por fim, transfere-as para uma variável (`data`) e as armazena no computador (`'fileName.mat'`). O arquivo final contém uma matriz de 3072×16 , com todos os dados adquiridos.

```
%-----
%   g.USBamp Acquirement
%-----
set(analogInput, 'SamplesPerTrigger', dataNumber);
start(analogInput);
while analogInput.SamplesAvailable < dataNumber
end
data = getdata(analogInput, analogInput.SamplesAvailable);
save('fileName.mat', 'data');
%-----
```

Essa ilustração, embora simples, revela um aspecto extremamente importante sobre o funcionamento do módulo de aquisição: a temporização é realizada através do monitoramento das amostras disponíveis. Nesse sentido, para compor um volume substancial de dados de treinamento, basta fazer chamadas sucessivas desse módulo, de acordo com um protocolo de operação bem definido, e agrupar e rotular os resultados de cada uma dessas investidas. Por outro lado, para executar uma aplicação de comunicação e controle, em geral, esse módulo deve ser solicitado uma única vez (durante a tarefa). Só que, nesse caso, a quantidade de amostras disponíveis precisa ser constantemente monitorada para que, a cada montante de dados acumulados, os mesmos sinalizem instantes pré-definidos – a chegada do ducentésimo quinquagésimo sexto ponto, amostrado em 256 Hz, indica que passou 1 segundo, por exemplo. Com isso, pode-se definir um relógio de sistema para informar os momentos em que algumas instruções devem ser executadas no inteiro do laço de aquisição, com o intuito de viabilizar aplicações imediatamente após o registro de EEG. Mas para alcançar esse objetivo, como será tratado ao longo da exposição, o módulo de processamento e o módulo de comunicação e controle foram projetados para atuar em intervalos diminutos (antes que o relógio do sistema indique o próximo instante), de forma que não haja amontoamento de amostras.

3.3 PROCESSAMENTO

Para o funcionamento da SSVEP-BCI, algumas funções de processamento são aplicadas de forma recorrente para, a cada passo de execução, preparar os dados para a atuação dos algoritmos de aprendizagem de máquina. Parte dessas funções já foi apresentada (conceitualmente) no capítulo 2: CAR, TWAR, segmentação de registro, FFT, periodograma de Welch. Nessa seção, por outro lado, será (primeiro) tratado como empregá-las na prática para a obtenção de um módulo automático que receba o sinal adquirido com o EEG e devolva

uma matriz com os atributos organizados convenientemente para as etapas seguintes. Como esses procedimentos devem ser realizados a cada nova inspeção da atividade cerebral, agrupá-los em torno de um único núcleo de processamento torna-os fáceis de executar. Depois de apresentada a estrutura desse módulo, como meio de fornecer alguma intuição sobre o seu funcionamento, serão expostas observações gráficas que ajudam a perceber algumas das virtudes e limitações a seu respeito.

3.3.1 Módulo de Processamento

No contexto da SSVEP-BCI em desenvolvimento, o módulo de processamento deve ser interpretado como um conjunto de funções básicas que prepara os dados brutos para as etapas de seleção e classificação e que se aplica (quase inteiramente) tanto ao longo da fase de treinamento quanto da fase de comunicação e controle. Ele inicialmente recebe os registros de EEG formatados matricialmente no final do módulo de aquisição – como visto há pouco, as linhas representam a dimensão do tempo e as colunas o posicionamento dos eletrodos. Esse processamento envolve quatro procedimentos sequenciais: a subdivisão da série temporal, a filtragem espacial, a extração de características e a organização da matriz de atributos. O primeiro deles se emprega somente durante o treino, único momento em que há, de fato, um grande volume de dados acumulados, enquanto os demais se empregam em ambas as fases.

Tabela 3.2: Algoritmo da função de subdivisão dos dados.

```

Input: raw data  $\{x_n\}$  for each channel  $n = 1, 2, \dots, N$ ,
       window  $W$  and overlap  $O$  dimensions.
Output: splitted data  $\{y_{nm}\}$ .
19 begin
20    $M \leftarrow$  number of subdivisions determined from  $x_n, W$  and  $O$ 
21   for each  $n$ 
22     for each  $m = 1, 2, \dots, M$ 
23        $y_{nm} \leftarrow$  windowing  $x_n$ 
24     end
25   end
26   return  $\{y_{nm}\}$ 
27 end

```

A subdivisão da série temporal em segmentos de igual tamanho está diretamente associada à reprodução de informações que simulem os trechos das aquisições *online*, ou seja,

o comprimento da janela de dados configurado para a operação da etapa de comunicação e controle deve ser exatamente o mesmo usado para a partição da matriz dos registros brutos. Assim, uma vez que o sistema conectado à aplicação responda em blocos de três segundos, a referida matriz também tem que ser particionada em segmentos com igual medida de tempo. Embora a largura destes deva ser idêntica, os blocos resultantes não necessitam ser disjuntos, ou seja, pode (e às vezes é desejável) haver sobreposição de pontos, principalmente nas situações em que há poucos dados disponíveis para o treinamento. No caso da SSVEP-BCI, isso não indica uma limitação do sistema, apenas representa (para o usuário) um menor tempo gasto para a aquisição de dados de treino, o que pode ser interessante do ponto de vista prático. A função que realiza essa subdivisão está sumarizada no pseudocódigo da Tabela 3.2 anterior. As variáveis de entrada são a matriz $\{x_n\}$, que reúne as séries temporais de cada canal, e os comprimentos da janela e da sobreposição de dados, respectivamente W e O . Com essas variáveis, determina-se o número de subdivisões M e os inícios e términos de cada recorte de sinal, de forma a auxiliar o processo de segmentação. No final, essa função retorna uma estrutura tridimensional $\{y_{nm}\}$, em que os registros de EEG estão separados por canal e segmento.

Tabela 3.3: Algoritmo da função CAR.

```

Input: splitted data  $\{x_{nm}\}$  for each channel  $n = 1, 2, \dots, N$  and
      each window  $m = 1, 2, \dots, M$ .
Output: CAR data  $\{y_{nm}\}$ .
28 begin
29    $w_m \leftarrow \{x_{nm}\}$  averaged between channels
30   for each  $n$ 
31     for each  $m$ 
32        $y_{nm} \leftarrow x_{nm} - w_m$ 
33     end
34   end
35   return  $\{y_{nm}\}$ 
36 end

```

Já a filtragem espacial, como tratado no capítulo 2, está relacionada com a tentativa de remoção automática (pelo menos em parte) dos artefatos. Para isso, as formulações matemáticas dos filtros CAR e TWAR foram basicamente traduzidas para linguagem de programação, para que fosse possível trabalhar com os dados janelados. As funções criadas para realizar essa tarefa estão apresentadas, respectivamente, nos pseudocódigos das Tabelas 3.3 e 3.4. Para as duas funções, a variável de entrada é uma estrutura tridimensional $\{x_{nm}\}$ oriunda

da etapa de subdivisão e a saída é uma estrutura $\{y_{nm}\}$ de dimensão similar, mas com os dados espacialmente filtrados. A diferença entre essas funções é que a primeira realiza a média simples w_m entre os canais, enquanto a segunda requer o cálculo do coeficiente de correlação de Pearson $\{c_{nm}\}$ entre os mesmos, de forma a obter um índice para ponderar a avaliação das médias $\{w_{mn}\}$, para então subtraí-las dos valores originais $\{x_{nm}\}$ e assim obter $\{y_{nm}\}$. A função CAR, como opera ponto a ponto, não é influenciada pelo comprimento da janela de dados; a função TWAR, por outro lado, depende desse tamanho devido ao mencionado coeficiente. Isso faz com que o domínio de atuação da última necessite de uma vizinhança de pontos mínima para funcionar adequadamente.

Tabela 3.4: Algoritmo da função TWAR.

```

Input: splitted data  $\{x_{nm}\}$  for each channel  $n = 1, 2, \dots, N$  and
       each window  $m = 1, 2, \dots, M$ .

Output: TWAR data  $\{y_{nm}\}$ .

1  begin
2    for each  $m$ 
3       $\{c_{nm}\} \leftarrow$  correlation coefficients between  $\{x_{nm}\}$ 
4       $\{w_{mn}\} \leftarrow \{x_{nm}\} \cdot \{c_{nm}\} / N$ 
5      for each  $n$ 
6         $y_{nm} \leftarrow x_{nm} - w_{nm}$ 
7      end
8    end
9    return  $\{y_{nm}\}$ 
10 end

```

A extração de características, por sua vez, está (resumidamente) atrelada à necessidade de redução do volume de dados (para posterior inspeção do seletor e do classificador) e, mais do que isso, à oportunidade de evidenciar informações relevantes. No caso de SSVEPs, a primeira tentativa evidente é extrair os conteúdos espectrais nas frequências de evocação. Para tanto, duas funções foram implementadas: uma com o uso de FFT e a outra com o uso da técnica de Welch. Os pseudocódigos delas estão mostrados nas Tabelas 3.5 e 3.6, na sequência da exposição. Ambas as funções apresentam como entrada uma estrutura $\{x_{nm}\}$ proveniente da filtragem espacial e como saída, $\{y_{nml}\}$, uma estrutura quadridimensional, em que a dimensão extra se refere às L extrações do conteúdo espectral em harmônicos (1.º e 2.º geralmente) das frequências de estimulação. A FFT tem a peculiaridade de apresentar valores complexos e, nesse caso, apenas o módulo deles foi levado em conta. No caso do

método de Welch, o módulo não está explícito no algoritmo porque é avaliado diretamente no cômputo do periodograma.

Tabela 3.5: Algoritmo da função de extração por FFT.

Input: CAR (TWAR) data $\{x_{nm}\}$ for each channel $n = 1, 2, \dots, N$ and each window $m = 1, 2, \dots, M$ and frequency attributes $\{a_l\}$, where $l = 1, 2, \dots, L$.

Output: FFT extraction data $\{y_{nml}\}$.

```

1  begin
2     $\{t_{nm}\} \leftarrow$  fast Fourier transform of  $\{x_{nm}\}$ 
3    for each  $n$ 
4      for each  $m$ 
5        for each  $l$ 
6           $y_{nml} \leftarrow |t_{nm}(a_l)|$ 
7        end
8      end
9    end
10   return  $\{y_{nml}\}$ 
11 end

```

Tabela 3.6: Algoritmo da função de extração por periodograma de Welch.

Input: CAR (TWAR) data $\{x_{nm}\}$ for each channel $n = 1, 2, \dots, N$ and each window $m = 1, 2, \dots, M$ and frequency attributes $\{a_l\}$, where $l = 1, 2, \dots, L$.

Output: Welch extraction data $\{y_{nml}\}$.

```

1  begin
2     $\{p_{nm}\} \leftarrow$  Welch periodogram of  $\{x_{nm}\}$ 
3    for each  $n$ 
4      for each  $m$ 
5        for each  $l$ 
6           $y_{nml} \leftarrow p_{nm}(a_l)$ 
7        end
8      end
9    end
10   return  $\{y_{nml}\}$ 
11 end

```

De qualquer forma, nas duas situações, trabalha-se apenas com características espectrais de valores positivos, pois o sistema deve identificar, sobretudo, as frequências de evocação. As amplitudes da FFT e da PSD costumam fornecer resultados convenientes. No entanto, como as energias do sinal de SSVEP são extremamente baixas, essas quantidades (principalmente as referentes à técnica de Welch) são extremamente diminutas e, por causa disso, pode-se ficar tentado a normalizá-las. Contudo, esse tipo de procedimento deve ser aplicado com bastante cautela e só quando realmente apresentar um ganho substancial no desempenho, pois normalizações indiscriminadas podem incorrer em perda de informação (muitas vezes úteis) para as etapas de processamento seguintes.

Tabela 3.7: Algoritmo da função para organização dos atributos.

```

Input: extracted data  $\{x_{nml}\}$  for each channel  $n = 1, 2, \dots, N$ ,
      each window  $m = 1, 2, \dots, M$  and each attribute  $l = 1, 2, \dots, L$ .
Output:  $M$ -by- $L \cdot N$  matrix of attributes  $\{y\}$ .

1  begin
2    for each  $n$ 
3      for each  $m$ 
4        for each  $l$ 
5           $\{y\} \leftarrow$  concatenate  $x_{nml}$  on a  $M$ -by- $L \cdot N$  matrix
6        end
7      end
8    end
9    return  $\{y\}$ 
10 end

```

Por fim, a organização da matriz de atributos é o último estágio do módulo de processamento. Essa formatação é essencial para criar uma espécie de padronização dos dados para aplicação dos métodos de seleção e classificação. Até o momento, os atributos foram arranjados em uma estrutura indexada que facilita o reconhecimento dos dados e a rápida aplicação dos processamentos de sinais até aqui apresentados. No entanto, nas etapas que envolvem a classificação, seja para o treinamento ou para a inspeção de dados novos, essa forma de apresentar os atributos é inadequada. Uma maneira conveniente de reorganizá-los, com tal finalidade, é a concatenação deles em uma matriz com a seguinte forma: cada linha representa uma janela de extração e cada coluna representa um atributo de canal. Neste estudo, convencionou-se chamar essa estrutura como matriz de atributos. Se, por exemplo, para uma estimulação específica (entre duas possíveis), obtém-se um registro de 60 segundos gravado com 16

eletrodos para o qual as janelas de análise devam ser de 3 segundos e não ter sobreposições entre si, então os dados de cada canal seriam segmentados em 20 blocos e, para cada um destes, 4 atributos (1.º e 2.º harmônicos de cada frequência) seriam extraídos. Isso levaria a uma matriz de atributos (para esse estímulo específico) com 20 linhas e 64 colunas. Para um caso geral, em que há N eletrodos, M janelas e L atributos, o pseudocódigo da Tabela 3.7 sugere um algoritmo de concatenação que recebe como entrada uma estrutura $\{x_{nml}\}$ com os atributos e devolve uma matriz $\{y\}$ com M linhas e $L \cdot N$ colunas.

Da forma como foi estruturada, essa matriz representa os dados concatenados para uma única frequência de estimulação, ou seja, é uma matriz de atributos para um só estado. Nesse sentido, para um procedimento de treino, como será visto na seção 3.6, o módulo de processamento deve ser chamado e executado sequencialmente S vezes, em que S representa o número de estados (ou classes) que se deseja distinguir. Dessa forma, uma matriz de atributos geral, proveniente da concatenação das matrizes de atributos para as S classes, deve conter informações de todos os estados e, portanto, apresentar $S \cdot M$ linhas e $L \cdot N$ colunas. Por outro lado, durante a execução *online*, o módulo pré-processamento fornece uma matriz de atributos com 1 linha e $L \cdot N$ colunas, que basicamente reúne todos os atributos da janela de dados para a qual o classificador, em tempo hábil de realizar uma aplicação, decide por alguma das S classes possíveis. Por fim, convém notar que são igualmente válidas as versões transpostas dessas matrizes e que a partir de uma estruturação final delas (a maneira pela qual os atributos estão dispostos) facilmente se constroem os vetores de rótulos (em caso de treinamento).

3.3.2 Funcionamento do Módulo de Processamento

As funções do módulo de processamento atuam de maneira sequencial, o que possibilita a avaliação delas a partir de suas saídas. Nesse sentido, para ajudar a compreender o impacto que o processamento exerceu sobre os registros de EEG nas situações em que um usuário foi exposto à figura simples, ao padrão reverso 1 e ao padrão reverso 2, adiante estão discutidas as análises de três tipos de gráficos: (1) a comparação entre os sinais no tempo e na frequência, (2) a comparação entre diferentes segmentações de dados e (3) a comparação entre os espaços de atributos dos 1.º e 2.º harmônicos. Se por um lado, cada um desses gráficos aborda diferentes aspectos de configuração do sistema e, por isso, leva a considerações específicas, por outro lado, todos foram confeccionados de forma a permitir uma avaliação geral, ao menos qualitativa, sobre a influência causada pela aplicação do módulo de processamento. Além disso, para um mesmo indivíduo, a inspeção deles curiosamente possibilita confrontar

as diferenças entre as evocações de cada um dos estímulos.

O primeiro conjunto de imagens basicamente exibe e compara, para janelas de 3 segundos de dados registrados no eletrodo Oz, os sinais no tempo (parte superior) e os espectros resultantes do método de Welch (parte inferior), antes (à esquerda) e após (à direita) a filtragem espacial CAR, nas situações em que um voluntário fixava a visão em RVSS de 12 Hz (sinais em azul) e de 15 Hz (sinais em vermelho) e também nos momentos em que o mesmo, como meio de repousar, direcionava o olhar para o centro da tela (sinais em verde).




Figura 3.5: Para janelas de 3 segundos de dados registrados no eletrodo Oz, os gráficos compararam os sinais no tempo (parte superior) e os espectros (parte inferior), antes (à esquerda) e depois (à direita) da filtragem espacial CAR, nas situações em que um voluntário fixava a visão em figuras simples de 12 Hz e de 15 Hz e quando o mesmo repousava.

A Figura 3.5, referente à figura simples, já deixa evidente a relevância da análise em frequência, em detrimento da análise no tempo, pelo menos quanto à inspeção visual. Isso não significa que não existam algoritmos que apreendam informações exclusivamente temporais, apenas indica que o sinal nesse domínio não apresenta um aspecto informacional tão evidente (à primeira vista parece um ruído branco). Já os espectros claramente mostram que, durante a estimulação nas frequências de 12 e 15 Hz, os respectivos registros de EEG exibem dois picos (bem distintos) nos primeiros harmônicos ligados a essas evocações e a ausência deles no estado de repouso. Para esse RVS em particular, que aparentemente estimulou ati-

vamente a região occipital, a simples transformação espectral torna o SSVEP detectável e mostra que a filtragem espacial (nesse caso) seria praticamente dispensável.

A Figura 3.6, relativa ao padrão reverso 1, também ajuda a reforçar a importância do conteúdo espectral para a identificação de SSVEPs. Além disso, a partir dela, é possível notar (diferente do estímulo anterior) a importância da filtragem espacial. As evocações em 12 e 15 Hz, produzidas a partir do mencionado padrão, não foram intensas como as da figura simples. De fato, se comparadas com alguns picos no sinal do estado de repouso, elas tiveram amplitudes da ordem de outras manifestações eletroencefalográficas (possivelmente cerebrais). Com a aplicação do CAR, por outro lado, os conteúdos nos 1.º e 2.º harmônicos da incitação ficam pronunciados e passíveis de realizar adequadamente a extração de atributos.




Figura 3.6: Os gráficos comparam os sinais no tempo e os espectros nas situações em que um voluntário fixava a visão em padrões reversos 1 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são as mesmas da Figura 3.5.

A última imagem desse bloco, a Figura 3.7, igualmente contribui com as impressões já levantadas sobre o conteúdo espectral e sobre a filtragem espacial. Distinta dos casos precedentes, porém, os espectros revelam uma informação adicional: existem situações em que curiosamente a amplitude do 2.º harmônico pode ser maior que a do 1.º (comportamento explicitamente não linear). Embora não se saiba ao certo o motivo desse fenômeno, este (ao

menos) ilustra a importância da inclusão dessas frequências na extração de características.




Figura 3.7: Os gráficos comparam os sinais no tempo e os espectros nas situações em que um voluntário fixava a visão em padrões reversos 2 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são as mesmas da Figura 3.5.

O segundo conjunto de imagens, por sua vez, exibe e compara, para o mesmo eletrodo Oz, e igualmente antes (à esquerda) e após (à direita) a filtragem espacial CAR, os espectros resultantes do método de Welch aplicado a uma janela de sinal segmentado ora com $\frac{1}{2}$, 1, 2 e 3 segundos (de cima para baixo, respectivamente), para as mesmas situações experimentais (sinais em azul, verde e vermelho) e para o mesmo voluntário do caso antecedente. Na Figura 3.8, os gráficos mostram que a resolução do espectro é fortemente influenciada pelo tamanho da janela de dados. Esse comportamento previsível se deve ao fato de que tal comprimento limita, para uma mesma taxa de amostragem, a quantidade de pontos disponíveis para calcular a FFT e estimar a densidade espectral de potência. Em geral, quanto menor for o número de amostras, menor a qualidade da estimativa. A importância disso indica, de certa forma, um limiar em que a detecção de SSVEPs se torna cada vez mais imprecisa. Evidentemente, essa fronteira pode se modificar entre os indivíduos, devido às variadas intensidades de evocação que cada um deles possa manifestar; contudo, ainda assim, espera-se que sempre exista uma resolução espectral máxima e que, por isso, esta seja um importante parâ-

metro de ajuste para customizar o sistema.




Figura 3.8: Para dados registrados no eletrodo Oz, antes (à esquerda) e depois (à direita) da filtragem espacial CAR, os gráficos comparam os espectros resultantes de janelas com $\frac{1}{2}$, 1, 2 e 3 segundos (de cima para baixo, respectivamente), para as situações em que um voluntário fixava a visão em figuras simples de 12 Hz e de 15 Hz e quando o mesmo repousava.

A Figura 3.8 mostra que, no caso da figura simples, o voluntário exibiu uma evocação suficientemente identificável nos 1.º harmônicos de todas as janelas, mesmo que de intensidades proporcionais ao montante de dados. Nesse caso, valeria testar o uso da SSVEP-BCI com blocos de processamento menores, em favor de uma velocidade de resposta maior, em detrimento de uma possível redução na taxa de acerto do estímulo, desde que isso não venha a prejudicar o desempenho geral da aplicação do sistema. Já a Figura 3.9, referente ao padrão reverso 1, indica que, para esse usuário, janelas menores que dois segundos tendem a prejudicar a detecção do estímulo de 15 Hz, enquanto os de 12 Hz, mesmo com a redução do

bloco de dados, mantêm uma certa consistência. Por outro lado, a Figura 3.10, associada ao padrão reverso 2, aponta para situação inversa: em janelas menores, são as amplitudes ocasionadas pela incitação em 12 Hz que se tornam cada vez mais indistinguíveis.




Figura 3.9: Os gráficos comparam os espectros resultantes de janelas com $\frac{1}{2}$, 1, 2 e 3 segundos, para as situações em que um voluntário fixava a visão em padrões reverso 1 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são idênticas as da Figura 3.8.

Essas informações qualitativas sugerem que, mesmo para estimulações de frequências iguais, as estampas levam a padrões de evocação bem distintos, inclusive não-lineares (como visto para o 2.º harmônico do potencial originariamente estimulado em 12 Hz, nas Figuras 3.7 e 3.10). Isso, por sua vez, só reforça a necessidade de investigar esse fenômeno: embora amplamente reportado na literatura de SSVEPs, ainda muito pouco entendido. Outra observação interessante é que a filtragem espacial CAR parece dissociar o potencial

evocado dos conteúdos espectrais vizinhos, o que consubstancia a sua reconhecida capacidade de realçar a referida manifestação cerebral; no entanto, isso se dá ao custo de (muitas vezes) reduzir a amplitude aparente da evocação. Logo, para blocos de dados muito pequenos, existem circunstâncias em que realizar a extração com os dados brutos pode, sim, ter maior eficiência, principalmente quando os SSVEPs já exibem intensidades relativamente altas.




Figura 3.10: Os gráficos comparam os espectros resultantes de janelas com 1/2, 1, 2 e 3 segundos, para as situações em que um voluntário fixava a visão em padrões reverso 2 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são idênticas as da Figura 3.8.

Por fim, o terceiro conjunto de imagens exhibe e compara, para várias extrações feitas com janelas de 3 segundos de dados registrados no eletrodo Oz, os espaços de atributos (eixo horizontal para as amplitudes espectrais evocadas com o estímulo de 12 Hz e eixo vertical para as evocadas com o de 15 Hz) referentes aos conteúdos espectrais do 1.º (parte superi-

or) e do 2.º (parte inferior) harmônicos, também antes (à esquerda) e depois (à direita) da filtragem espacial CAR, para as mesmas condições experimentais (sinais em azul, verde e vermelho) e para o mesmo voluntário dos casos abordados anteriormente.




Figura 3.11: Para várias extrações em janelas de 3 segundos de dados registrados no eletrodo Oz, os gráficos comparam os espaços de atributos referentes ao conteúdo espectral do 1.º (parte superior) e do 2.º (parte inferior) harmônicos, antes (à esquerda) e depois (à direita) da filtragem espacial CAR, nas situações em que um voluntário fixava a visão em figuras simples de 12 Hz e de 15 Hz e quando o mesmo repousava.

A Figura 3.11 revela que, ao longo de vários blocos de aquisição, a figura simples foi o estímulo que, para esse usuário em particular, suscitou os SSVEPs com as maiores amplitudes e que deu origem ao espaço de estados com a maior separação entre as classes, sobretudo para o 1.º harmônico. Inclusive, a filtragem espacial CAR pode ser considerada irrelevante nessas circunstâncias. Os conteúdos espectrais de cada estado se agrupam em distribuições bem definidas e linearmente separáveis, de forma que um classificador linear executa a tarefa de discriminação sem percalços.

Já para o caso do padrão reverso 1, exibido na Figura 3.12, os espaço de atributos (1.º e 2.º harmônicos) originalmente se revelaram difusos. Nesse ensaio, a filtragem espacial (visualmente) teve um papel crucial para tornar linearmente separáveis (ao menos aproximadamente) as três distribuições de classe mostradas. Em situações como essa, as informações de ambos os harmônicos acabam sendo necessárias para aumentar a taxa de acerto do classificador. A Figura 3.13, por sua vez, reforça as conclusões obtidas com a Figura 3.12 e também reforça a importância de se incluir o 2.º harmônico para a análise espectral, uma vez que, no

caso do estímulo em questão (padrão reverso 2), o conteúdo em 24 Hz, durante a estimulação de 12 Hz, aparentemente foi o que apresentou a maior amplitude energética e, por isso, o que (em princípio) teria a maior capacidade de discriminação.




Figura 3.12: Os gráficos comparam os espaços de atributos referentes aos conteúdos espectrais do 1.º e do 2.º harmônicos nas situações em que um voluntário fixava a visão em padrões reversos 1 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são idênticas as da Figura 3.11.




Figura 3.13: Os gráficos comparam os espaços de atributos referentes aos conteúdos espectrais do 1.º e do 2.º harmônicos nas situações em que um voluntário fixava a visão em padrões reversos 2 de 12 Hz e de 15 Hz e quando o mesmo repousava. As configurações e convenções são idênticas as da Figura 3.11.

Obviamente, as análises vistas não são conclusões gerais sobre os diferentes estímulos (até porque foram expostas a partir da observação dos dados de um único voluntário), elas apenas fornecem uma intuição de como o módulo de processamento opera e mostram que este deve ser suficientemente flexível para tratar e evidenciar os diversos (e imprevisíveis, de certa forma) padrões evocados visualmente.

3.4 TREINAMENTO

Para que a SSVEP-BCI inspecione e identifique corretamente novas entradas, alguns algoritmos de seleção e classificação são utilizados para, respectivamente, decidir os eletrodos mais informativos e estabelecer um conjunto de coeficientes que reconheça os estímulos. Tal como os métodos do módulo de processamento, parte desses algoritmos já foi apresentada no capítulo 2: LSD, FDA, coeficiente de correlação de Pearson e número de Fisher. Nessa seção, então, será trabalhado como utilizá-los para a obtenção de um módulo que receba a matriz de atributos completa, oriunda do módulo de processamento, e devolva (1) um vetor com os eletrodos selecionados e (2) uma matriz de coeficientes para o reconhecimento de estados (potenciais evocados). Esses procedimentos são geralmente realizados uma única vez no início de uma experiência e servem para ajustar a operação durante a fase de aplicação. Por isso, reuni-los modularmente torna-os fácil de executar. Como no caso do módulo de processamento, depois de esboçar a sua estrutura, para ajudar a compreender como ele opera, serão analisadas algumas imagens que capturam a essência de seu funcionamento.

3.4.1 Módulo de Treinamento

O módulo de treinamento deve ser visto como um conjunto de funções que, a partir dos dados pré-processados, determina os coeficientes de um classificador para atuar na etapa de reconhecimento de estímulos, durante a fase de comunicação e controle (aplicação *online*). Ele inicialmente recebe a matriz de atributos completa ($\mathbf{S} \cdot \mathbf{M}$ linhas e $\mathbf{L} \cdot \mathbf{N}$ colunas) – a qual resulta (como visto anteriormente) de $\mathbf{S}$ chamadas consecutivas do módulo de pré-processamento – e também recebe os vetores de rótulos associados a essa matriz. Esta então é dividida em duas, de forma que uma parte dos dados (75%, por exemplo) seja utilizada para o treino (matriz de treino – $\mathbf{S} \cdot \mathbf{M}_1$ linhas e $\mathbf{L} \cdot \mathbf{N}$ colunas) e a outra parte (os 25% restantes) seja usada para a validação (matriz de validação – $\mathbf{S} \cdot \mathbf{M}_2$ linhas e $\mathbf{L} \cdot \mathbf{N}$ colunas). Note que $\mathbf{M} = \mathbf{M}_1 + \mathbf{M}_2$. Os vetores de rótulos também são particionados de forma equivalente e com

a mesma finalidade. Na sequência, o módulo de treinamento realiza essencialmente quatro procedimentos centrais: o cálculo do índice de relevância, a determinação dos coeficientes do classificador, a aplicação da função de classificação e a tomada de decisão. Evidentemente, os dois primeiros (exclusivos desse módulo) são executados com os dados de treino e os dois posteriores com os de validação. Estes últimos (igualmente tratados na próxima seção) também aparecem no módulo de comunicação e controle.

Tabela 3.8: Algoritmo da função do índice de relevância por Pearson.

Input: $S \cdot M_1$ -by- $L \cdot N$ matrix of attributes $\{x\}$ and
 $S \cdot M_1$ -by- S matrix of labels $\{r\}$.

Output: vector of channel indexes y ordered by ranking.

```

1  begin
2  for each  $ln = 1, 2, \dots, L \cdot N$ 
3    for each  $s = 1, 2, \dots, S$ 
4       $c_{lns} \leftarrow$  Pearson's coefficient between  $x(:, n)$  and  $r(:, s)$ 
5    end
6  end
7   $p_n \leftarrow$  sum all the  $c_{lns}$  belonging the same channels
8   $y \leftarrow$  channel indexes of  $p_n$  sorted in decreasing order
9  return  $y$ 
10 end

```

Os índices de relevância, como os fornecidos pelos filtros de seleção trabalhados no capítulo 2, servem para estabelecer uma pontuação e posterior ordenação dos eletrodos. Determinar uma sequência de canais informativos (no sentido de satisfazer as características do discriminante) depois permite a criação e o teste de um classificador por meio de um processo de adição paulatina (por ordem de relevância) dos atributos. Estão expostas nos pseudocódigos das Tabelas 3.8 e 3.9 as funções criadas para calcular e dispor em forma decrescente esses índices: a primeira baseada no coeficiente de correlação de Pearson e a segunda no número de Fisher. As duas funções têm como variável de entrada a matriz de treinamento (porção maior da matriz de atributos completa) e como saída um vetor com os índices (de cada eletrodo) ordenados decrescentemente. O algoritmo que faz os cálculos com o uso do coeficiente de Pearson necessita da matriz de rótulos para estimar os índices de relevância e, por isso, recebe-a como variável de entrada também. Já o outro algoritmo, o que utiliza o número de Fisher, avalia as médias e as variâncias dentro das classes, ou seja, necessita somente conhecer a distribuição matricial dos dados de acordo com os rótulos.

Tabela 3.9: Algoritmo da função do índice de relevância por Fisher.

Input: $S \cdot M_1$ -by- $L \cdot N$ training matrix $\{x\}$ and.
Output: vector of channel indexes y ordered by ranking.

```

1  begin
2    for each  $ln = 1, 2, \dots, L \cdot N$ 
3      for each  $s = 1, 2, \dots, S$ 
4         $\mu_{ln \pm s} \leftarrow$  within class's mean
5         $\sigma_{ln \pm s}^2 \leftarrow$  within class's variance
6         $c_{lns} \leftarrow \mu_{ln+s} - \mu_{ln-s} / \sigma_{ln+s} + \sigma_{ln-s}$ 
7      end
8    end
9     $f_n \leftarrow$  sum the  $c_{lns}$  belonging the same channels
10    $y \leftarrow$  channel indexes of  $f_n$  sorted in decreasing order
11   return  $y$ 
12 end

```

Os métodos vistos para calcular os coeficientes de um classificador linear foram o LSM e o FLD. Esses coeficientes, em conjunto com os eletrodos que os geraram, representam o conhecimento que a máquina pode adquirir sobre os dados e, além disso, sintetizam a informação que a máquina pode utilizar para discriminar entradas novas. As Tabelas 3.10 (LSM) e 3.11 (FLD) mostram os algoritmos para calculá-los. Como no caso do índice de relevância, ambos têm como variável de entrada a matriz de atributos e como saída a matriz de coeficientes de classificação. No entanto, enquanto a função do LSM tem acesso direto à matriz de rótulos para realizar o cômputo dos pesos do classificador, a função do FLD, por sua vez, tem acesso à distribuição matricial destes para avaliar as médias e as covariâncias dentro das classes – estatísticas depois usadas para determinar os pesos do discriminante.

Tabela 3.10: Algoritmo da função de cálculo dos coeficientes do LSM.

Input: $S \cdot M_1$ -by- $L \cdot N$ training matrix $\{x\}$ and
 $S \cdot M_1$ -by- S training labels $\{r\}$.
Output: $(L \cdot N + 1)$ -by- S matrix of LSM coefficients $\{y\}$.

```

1  begin
2     $\{x_{bias}\} \leftarrow \{x\}$  concatenated with a column vector of bias
3     $\{y\} \leftarrow (\text{pseudoinverse of } \{x_{bias}\}) \cdot \{r\}$ 
4    return  $\{y\}$ 
5  end

```

Além das especificidades dos cálculos, uma diferença importante entre esses métodos é que o LSM utiliza uma matriz de atributos acrescida com uma coluna de uns (os w_{k0}), ao passo que o FLD usa a matriz de atributos original (redução de dimensionalidade).

Tabela 3.11: Algoritmo da função de cálculo dos coeficientes do FLD.

```

Input:  $S \cdot M_1$ -by- $L \cdot N$  training matrix  $\{x\}$ .
Output:  $L \cdot N$ -by- $S$  matrix of FLD coefficients  $\{y\}$ .
1  begin
2    for each  $s = 1, 2, \dots, S$ 
3       $\mu_{\pm s} \leftarrow$  within class's mean
4       $\{c_{\pm s}\} \leftarrow$  within class's covariance
5       $\{w_s\} \leftarrow \{c_{+s}\} + \{c_{-s}\}$ 
6       $\{y\} \leftarrow (\text{inverse of } \{w_s\}) \cdot (\mu_{+s} - \mu_{-s})$ 
6    end
7    return  $\{y\}$ 
8  end

```

A aplicação da função de classificação utiliza os coeficientes determinados anteriormente para avaliar as novas entradas. Os algoritmos das Tabelas 3.12 (LSM) e 3.13 (FLD) mostram as funções projetadas para realizar esse cômputo. Elas recebem duas variáveis de entrada, a matriz de validação e a matriz de coeficientes, e retornam uma matriz de resultados. No caso do LSM, a matriz de atributos deve ser acrescida com a coluna de uns (da mesma forma que se fez para calcular os pesos – vide Tabela 3.10). Já para o FLD, é importante avaliar as médias de todos os atributos e com estas compor uma matriz de médias, usada para subtrair a matriz de validação.

Tabela 3.12: Algoritmo da função de classificação por LSM.

```

Input:  $S \cdot M_2$ -by- $L \cdot N$  validation matrix  $\{x\}$  and
       $(L \cdot N + 1)$ -by- $S$  matrix of LSM coefficients  $\{w\}$ .
Output:  $S \cdot M_2$ -by- $S$  matrix of LSM results  $\{y\}$ .
1  begin
2     $\{x_{bias}\} \leftarrow \{x\}$  concatenated with a column vector of bias
3     $\{y\} \leftarrow \{x_{bias}\} \cdot \{w\}$ 
4    return  $\{y\}$ 
5  end

```

A aplicação dos dois métodos basicamente representa a operação de um conjunto de funções lineares (coeficientes vezes variáveis) cujos resultados devem ser positivos, em caso de identificação das classes, ou devem ser negativos, caso contrário.

Tabela 3.13: Algoritmo da função de classificação por FLD.

Input: $S \cdot M_2$ -by- $L \cdot N$ validation matrix $\{x\}$ and
 $L \cdot N$ -by- S matrix of FLD coefficients $\{w\}$.
Output: $S \cdot M_2$ -by- S matrix of FLD results $\{y\}$.

```

1  begin
2       $\{\mu\} \leftarrow$  assessing the average of  $\{x\}$ 
3       $\{y\} \leftarrow (\{x\} - \{\mu\}) \cdot \{w\}$ 
4      return  $\{y\}$ 
5  end

```

As funções de classificação, porém, não bastam para decidir por uma única classe, devido à possibilidade de redundância que elas carregam.

Tabela 3.14: Algoritmo da função de tomada de decisão.

Input: $S \cdot M_2$ -by- S matrix of results $\{x\}$.
Output: decision vector y .

```

1  begin
2      for each  $n = 1, 2, \dots, L \cdot M_2$ 
3           $y \leftarrow$  maximum value between  $\{x(n, :)\}$ 
4      end
5      return  $y$ 
6  end

```

Logo, tem que existir um algoritmo (Tabela 3.14) para decidir, em última instância, caso mais de uma saída forneça um resultado positivo, o que representaria a identificação de duas classes simultaneamente. Para evitar esse tipo de situação, uma função de decisão foi projetada para escolher o resultado de classificação mais positivo (vide capítulo 2, página 69). Isso basicamente encerra a etapa de identificação, o que para a SSVEP-BCI significa a atribuição de uma única frequência de evocação para um bloco de dados de EEG. No entanto, para ajudar a avaliar todas as saídas, é conveniente designar rótulos associados a cada uma delas. Com estes, por sua vez, é possível quantificar os erros e acertos de classificação, de forma que isso possa ajudar a decidir o melhor classificador entre um conjunto de discriminantes possíveis.

3.4.2 Funcionamento do Módulo de Treinamento

As funções do módulo de treinamento atuam de maneira específica: ora sequencial e ora circular. Da parte sequencial, primeiro, determina-se o índice de relevância (seja por Pearson ou por Fisher) dos eletrodos e estes, através da avaliação recebida, são ordenados decrescentemente. Depois, essa orientação é utilizada para reorganizar as matrizes de treinamento e validação, de forma que os canais com as maiores pontuações fiquem nas primeiras colunas e os com as menores sejam alocados nas últimas. Com isso, tem início a parte circular do módulo. As novas matrizes são usadas para treinar, de forma recorrente e aditiva, 16 classificadores lineares (seja por LSM ou por FLD): o primeiro discriminante apenas com os atributos do eletrodo considerado mais relevante; o segundo agora com os atributos dos dois eletrodos mais relevantes; e assim por diante, até o décimo sexto classificador que utiliza os atributos dos 16 eletrodos. Ao final, verifica-se, entre todos os classificadores, o que tem o melhor desempenho. Então, os coeficientes deste e o sequenciamento de eletrodos que o gerou são fornecidos, respectivamente, para o módulo de comunicação e controle e para o módulo de processamento, que usufruem desses conhecimentos para atuar *online*.




Figura 3.14: Para atributos extraídos dos dois primeiros harmônicos (pontos vermelhos) e da frequência principal apenas (pontos azuis), os gráficos comparam, para um usuário sadio, as evoluções do desempenho de classificação (LSM) conforme se acrescenta os eletrodos ordenados de acordo com o coeficiente de Pearson. O estímulo em questão foi a figura simples.

Para ajudar a visualizar esse procedimento, nas situações em que um usuário foi exposto à figura simples, ao padrão reverso 1 e ao padrão reverso 2 (como no caso do módulo de processamento), adiante estão expostas as análises de três gráficos (um para cada estímulo). Os três representam as evoluções da taxa de acerto de um classificador, treinado por LSM, conforme se adiciona (um por um) os eletrodos ordenados de acordo com o coeficiente de Pearson – para dados divididos em janelas de 3 segundos, sobrepostos em blocos de 1 segundo, filtrados espacialmente com CAR e dos quais se extraiu atributos, por FFT, ora com as características dos dois primeiros harmônicos (pontos vermelhos) ora com as características da frequência principal apenas (pontos azuis). O discriminante devia distinguir entre duas frequências de evocação possíveis, 12 e 15 Hz. Cada ponto exibe o desempenho médio entre a distinção das duas.




Figura 3.15: Para atributos extraídos dos dois primeiros harmônicos (pontos vermelhos) e da frequência principal apenas (pontos azuis), os gráficos comparam, para um usuário sadio, as evoluções do desempenho de classificação (LSM) conforme se acrescenta os eletrodos ordenados de acordo com o coeficiente de Pearson. O estímulo em questão foi o padrão reverso 1.

A Figura 3.14 (anterior) mostra uma situação em que a informação extraída do 2.º harmônico acrescentou muito pouco ao desempenho de classificação, uma vez que a diferença entre as curvas é relativamente pequena. Para essa evolução, o módulo de treinamento selecionaria apenas o eletrodo Oz para agir *online*, ou seja, o primeiro classificador (entre os 16

projetados) que utiliza apenas os atributos do eletrodo considerado mais relevante. Adicionar mais características (eletrodos), nesse caso, do ponto de vista da estimativa otimista, não ajudaria porque, a cada soma de um novo canal, a taxa de classificação decai pouco a pouco. Já a Figura 3.15 (posterior) evidencia um comportamento bem diferente. Nessa circunstância, os atributos do 2.º harmônico desempenharam um papel fundamental para melhorar o acerto de classificação, dada a diferença evidente entre as curvas. Para essa tendência, o módulo de treinamento escolheria os eletrodos Oz e O2 para atuar *online*. Esse gráfico também deixa claro que o excesso de eletrodos não informativos pode prejudicar substancialmente a classificação, uma vez que evidencia uma queda acentuada na curva vermelha, a partir do quinto canal adicionado. A Figura 3.16, por sua vez, também confirma a importância do conteúdo espectral do 2.º harmônico. Nesse caso, mais do que os outros, a diferença entre as curvas é extremamente significativa: não há um só ponto dos gráficos em que o desempenho de classificação tenha sido melhor apenas com atributos do 1.º harmônico. De acordo com essa inclinação, o módulo de treinamento selecionaria os eletrodos Oz, O2 e Cz para operar junto à aplicação da BCI.




Figura 3.16: Para atributos extraídos dos dois primeiros harmônicos (pontos vermelhos) e da frequência principal apenas (pontos azuis), os gráficos comparam, para um usuário sadio, as evoluções do desempenho de classificação (LSM) conforme se acrescenta os eletrodos ordenados de acordo com o coeficiente de Pearson. O estímulo em questão foi o padrão reverso 2.

Uma informação importante, e ao mesmo tempo curiosa, que os três gráficos apontam é que a sequência de eletrodos relevantes, para atributos só do 1.º harmônico, e a sequência de eletrodos relevantes, para atributos dos 1.º e 2.º harmônicos, não são idênticas. Apresentam algumas similaridades (evidentemente), mas costumam divergir a partir do terceiro eletrodo. Isso, de certa forma, também sugere comportamento não linear entre os atributos extraídos. Outro fato interessante é a presença de eletrodos não occipitais (geralmente da região central) em posições significativas: Cz e C2 apareceram com frequência entre os quatro eletrodos com maior índice de relevância.¹⁶ Para o caso do padrão reverso 2, Cz (muito provavelmente devido à presença de conteúdo relevante no 2.º harmônico) inclusive seria selecionado para atuar *online*, como visto há pouco. Enfim, os eletrodos da região occipital, sobretudo Oz, sempre figuram com as maiores pontuações; no entanto, eles nem sempre alcançam, sozinhos, as maiores taxas de classificação. Isso particularmente justifica a utilização de métodos de seleção de características, em detrimento de utilizar apenas os eletrodos classicamente aceitos (O1, O2 e Oz).

3.5 COMUNICAÇÃO E CONTROLE

Enviar uma mensagem de comunicação – derivada imediatamente após a aquisição, o processamento e a identificação de uma manifestação cerebral intencional – para controlar um dispositivo externo é uma das tarefas mais surpreendentes que uma BCI costuma proporcionar. Deve ser por causa disso, inclusive, que se popularizou uma visão um tanto quanto futurística de que esse sistema seja capaz de traduzir pensamentos, ou ler mentes, entre outras interpretações similares. Parte dessa tipificação foi construída principalmente por literatura não científica, como é de se esperar. No entanto, tamanha é a admiração por esse feito, que às vezes até mesmo alguns textos técnicos da área se arriscam em utilizar tais analogias. Por outro lado, como visto até este ponto da exposição, tentar associar atividades do cérebro com possíveis estados mentais é, sim, uma busca desafiante e, de certa forma, bastante enigmática (porque ainda existem muitos questionamentos em aberto), mas (sobretudo) uma conquista advinda da capacidade de se programar as máquinas para reconhecer padrões emergentes de atributos extraídos de registros encefálicos. Não distante desse conceito, o módulo de comunicação e controle partilha desse mesmo preceito e, portanto, com o uso dos conhecimentos provenientes do módulo de treinamento, procura (1) identificar o estímulo que um usuário arbitrariamente escolhe e, de acordo com o resultado dessa supervisão, (2) enviar adequadamente um sinal de comando para a aplicação.

3.5.1 Módulo de Comunicação e Controle: Estrutura e Funcionamento

O módulo de comunicação e controle, em termos de composição, não passa de uma versão sintética do módulo de treinamento: ele igualmente apresenta versões das funções de classificação, por LSM e FLD (Tabelas 3.12 e 3.13), e da função de tomada de decisão (Tabela 3.14). O único algoritmo adicional é a codificação da saída final do discriminante em um sinal para enviar para a aplicação. Pode-se associar cada classe a um código específico e enviá-lo de acordo com um protocolo bem determinado. É comum, por exemplo, algumas BCIs transmitirem os comandos por meio de Protocolos de Transferência de Hipertexto (HTTP, *Hypertext Transfer Protocol*) – padrão para sistemas de comunicação distribuídos e colaborativos (como o caso da internet, por exemplo). Em outros casos, quando a aplicação está no próprio computador da BCI, o sinal de comando às vezes demanda uma única linha de instrução. Enfim, não há uma forma canônica de elaborar o algoritmo de geração desse sinal porque, em geral, esta depende do uso que este terá para controlar um dispositivo externo ou, às vezes, simplesmente comunicar uma decisão.

Além de uma estrutura concisa, entre todos os módulos vistos, ele também é o que tem o funcionamento mais simples, até porque já recebe dados formatados do módulo de processamento e, além disso, é contemplado com informações privilegiadas do módulo de treinamento. Ele é inicialmente configurado com a matriz de coeficientes, oriundo do melhor classificador projetado durante o treino, e, basicamente, atua a cada chamada de execução, feita pelo relógio do sistema, ao longo da operação *online*. Apesar dessa aparente simplicidade, esse módulo impõe fortes restrições de projeto, pois todos os processamentos realizados por ele precisam ser algoritmos de rápida execução. Em geral, primeiro se verifica a agilidade e a praticidade do método em atuar junto à aplicação, para só depois integrá-lo dentro do escopo de possibilidades. Não adianta utilizar uma técnica excepcional para identificar as classes, se esta não o faz em poucos segundos. Ela até pode ser útil para investigação da atividade cerebral (BCI *offline*), mas pode tornar um sistema *online* demasiado lento e instável.

3.6 INTEGRAÇÃO DO SISTEMA

Até aqui, foram apresentadas a estrutura e a execução dos módulos de maneira independente. No entanto, a SSVEP-BCI, para funcionar como um sistema unificado, depende da integração entre os mesmos sob uma perspectiva operacional. Para isso, convém lembrar que toda interface cérebro-computador, além dos três constituintes conceituais básicos (entra-

da, processamento e saída), os quais são (inclusive) satisfatoriamente representados pelos cinco módulos vistos, também necessita de um protocolo de operação. Esse protocolo, por sua vez, está intimamente relacionado com a atividade cerebral que se deseja monitorar – no caso deste estudo, SSVEPs. Portanto, a integração e a operação dos módulos propostos, para conseguir executar tarefas de comunicação e controle, precisam ser organizadas em torno de um tempo de processamento hábil para realizar com sucesso essa monitoração, tanto na etapa de treinamento quanto na de aplicação. Por exemplo, a fase de treino não deve ser muito sucinta, para não reduzir em demasia a quantidade de dados fornecida ao classificador, e ao mesmo tempo não deve ser excessivamente longa, para não entediar e fadigar o usuário. Em relação à fase de aplicação, outro exemplo, a associação entre os módulos precisa ocorrer de forma recorrente e automática para que o sistema, sem atrasar ou acavalar processos, dê conta de adquirir, identificar e enviar os sinais pertinentes. Ou seja, pode-se dizer que colocar os módulos para trabalhar adequadamente em conjunto é uma questão de ajuste fino e é uma situação particular para cada tipo de BCI. Nesse sentido, as soluções propostas adiante foram pensadas no contexto de SSVEPs.

3.6.1 Integração dos Módulos e Funcionamento do Sistema

O funcionamento experimental do sistema pode ser dividido em cinco etapas: a montagem geral, a inicialização dos estímulos, a aquisição dos dados de treino, o treinamento e a aplicação. Na primeira delas, um voluntário é posicionado confortavelmente diante de um monitor e distanciado de aparelhos eletrônicos que possam causar interferência. Na sequência, ocorre a preparação da touca de eletrodos e o módulo de aquisição realiza as calibrações, as verificações e as configurações necessárias para mensurar a atividade cerebral adequadamente. Depois, o módulo de estimulação simplesmente inicia a exibição dos RVSs – estabelecidos previamente de acordo com a necessidade do ensaio.

Com os estímulos devidamente carregados, pode-se, então, prosseguir com a aquisição dos dados de treino. Para isso, é necessário haver um procedimento de registro. Neste estudo, o protocolo padrão envolvia a aquisição de 8 sessões de 12 segundos para cada estado (classe) que o classificador posteriormente precisaria discriminar. Por exemplo, se dois estímulos (comandos) forem utilizados, 12 e 15 Hz, mais o repouso, ao todo devem ser adquiridas 3x8 sessões de EEG: 8 enquanto o participante olha fixamente para o RVS de 12 Hz, 8 para o de 15 Hz e 8 para o centro da tela (onde não havia qualquer estímulo). Para evitar o cansaço e a fadiga visual, as sessões de cada estado costumam ser preferencialmente interca-

ladas e espaçadas com um tempo de espera. O voluntário é instruído (visualmente ou sonoramente) sobre os instantes de início de cada bloco e, também, sobre o estímulo (ou região da tela) em que ele precisa concentrar a atenção. O módulo de aquisição deve ser precisamente inicializado em fase com todos os começos de sessão, de forma a se obter uma rotulação correta. Ao fim dessa etapa, os dados são organizados em uma única estrutura.

Em seguida, tem início a fase de treino. O módulo de processamento recebe os registros de todas as sessões de aquisição e gera, a partir deles, uma matriz de atributos completa. Esta, por sua vez, é subdividida em duas outras matrizes, a de treinamento e a de validação. Além destas, são criadas as respectivas matrizes de rótulos. Todas essas matrizes são transferidas para o módulo de treinamento. Este, então, realiza o cômputo do melhor classificador que encontrar a partir dos dados fornecidos e disponibiliza uma matriz de coeficientes e um vetor com a sequência de eletrodos mais relevantes – o que marca o fim dessa etapa.

Por fim, a fase de aplicação envolve a utilização simultânea de três módulos, o de aquisição, o de processamento e o de comunicação e controle. O primeiro deles é acionado para registrar a atividade cerebral de forma continuada, até que o mesmo receba um sinal de saída (geralmente disparado por um dispositivo mecânico ou por um tempo máximo de execução). Conforme os dados são registrados e armazenados, o relógio do sistema, a cada intervalo de amostras bem estabelecido, chama sequencialmente o módulo de processamento e o módulo de comunicação e controle. Dessa forma, de tempos em tempos, um sinal é gerado para controlar uma aplicação ou comunicar uma decisão. Esse intervalo de amostras não pode exceder um tempo máximo – que geralmente representa um compromisso entre a capacidade de processamento do sistema e a agilidade para atuar *online*.

3.7 AVALIAÇÃO DO SISTEMA

Ao longo do desenvolvimento da SSVEP-BCI, três tipos de testes foram praticados: o sistêmico, o procedimental e o geral. O primeiro deles, o teste sistêmico, está associado com a capacidade de articulação dos módulos durante a execução *online*. Por exemplo: verificar se o módulo de aquisição mensura, salva e transfere sinais corretamente (sem travar); se o módulo de processamento extrai e organiza os atributos antes de receber a nova batelada de amostras; se o módulo de treinamento é capaz de obter uma solução ótima em tempo hábil; se o módulo de comunicação e controle, antes de ser solicitado novamente, toma uma decisão a partir dos dados correntes e envia um comando; se o relógio do sistema que coordena todas as operações não apresenta atrasos significativos; entre outras conferências similares. Para reali-

zar esses testes, utilizaram-se sinais de calibração gerados com o amplificador g.USBamp, que permite, para tal finalidade, a configuração de ondas dente-de-serras (ou ondas quadradas) de frequências e amplitudes características. Com isso, pôde-se produzir artificialmente sinais *online* e, assim, verificar o funcionamento dos módulos em conjunto.

Já o segundo tipo de teste, o procedimental, está relacionado com a habilidade das sequências metodológicas, tanto de processamento de sinais quanto de aprendizagem de máquina e reconhecimento de padrões, em destacar a presença de SSVEPs. Evidentemente, todas as técnicas foram testadas *offline*, antes de integrar a BCI *online*. Para isso, utilizou-se um banco de dados de SSVEPs adquirido com dez voluntários saudáveis – em concordância com os procedimentos experimentais previamente aprovados pelo CEP da Unicamp (vide o início do capítulo 3). Cada participante teve a atividade cerebral monitorada durante 16 sessões de 12 segundos: metade destas registradas enquanto ele olhava para um estímulo (figura simples 2) de 12 Hz e a outra metade para um de 15Hz. As configurações do aparelho de EEG e a marcha do protocolo de aquisição foram realizadas de forma a simular o funcionamento do sistema. Posteriormente, com o conjunto de amostras produzido (partes separadas para o treinamento e a validação), diferentes procedimentos analíticos puderam ser testados. As taxas de acerto dos principais deles estão nas Tabelas 3.15 e 3.16.

Tabela 3.15: Desempenho de classificação do par Pearson-LSM.

Voluntário	Dados Brutos		CAR		TWAR	
	FFT	Welch	FFT	Welch	FFT	Welch
1	0,75	0,75	0,80	0,77	0,84	0,82
2	0,93	0,84	0,93	0,91	0,98	0,93
3	0,70	0,64	0,73	0,66	0,84	0,84
4	0,86	0,77	0,86	0,86	0,89	0,82
5	0,84	0,80	1,00	0,98	1,00	0,98
6	0,86	0,86	1,00	0,98	0,98	0,95
7	0,77	0,80	0,89	0,89	0,84	0,84
8	0,95	1,00	0,98	1,00	1,00	1,00
9	0,95	0,91	0,93	0,93	0,95	0,95
10	0,68	0,66	0,95	0,95	1,00	0,93
Média	0,83	0,80	0,91	0,89	0,93	0,91
Desvio	0,08	0,08	0,07	0,08	0,06	0,06

A Tabela 3.15 resume os desempenhos de classificação do par seletor-discriminante composto pelo coeficiente de Pearson e o LSM, para dados sem filtragem espacial e dados filtrados com CAR e TWAR, bem como para a extração por FFT e por periodograma de Welch. A Tabela 3.16, por sua vez, sintetiza os resultados de classificação do par seletor-discriminante formado pelo número de Fisher e o FLD, para as mesmas especificações

do caso anterior. Em cada linha (voluntário), os números em negrito mostram o melhor resultado de cada par seletor-discriminante e as células destacadas com hachura indicam o melhor dentre os dois pares. Esses valores sugerem possíveis configurações para ajustar os coeficientes do classificador e decidir os eletrodos mais informativos. Essas quantias podem ser interpretadas como estimativas otimistas do desempenho da BCI durante a operação *online*, para os métodos de processamento, seleção e classificação que as originaram. De certa forma, elas revelam, para esse grupo de voluntários, que a filtragem espacial (seja CAR ou TWAR) teria um papel preponderante para o funcionamento da aplicação e a extração por FFT seria a mais utilizada. Outro fato interessante é que, para um mesmo indivíduo, a árvore de processos frequentemente leva a mais de um nó ótimo, inclusive com o uso das duas estratégias de seleção e classificação, o que mostra a vantagem de adotar um treinamento com múltiplas técnicas. De certa forma, isso também permite a personalização do sistema de acordo com as idiosincrasias do usuário.¹⁷

Tabela 3.16: Desempenho de classificação do par Fisher-FLD

Voluntário	Dados Brutos		CAR		TWAR	
	FFT	Welch	FFT	Welch	FFT	Welch
1	0,80	0,68	0,89	0,77	0,82	0,84
2	0,89	0,84	0,98	0,95	0,98	0,93
3	0,70	0,66	0,73	0,75	0,84	0,75
4	0,86	0,82	0,84	0,91	0,93	0,86
5	0,84	0,64	1,00	0,98	1,00	0,91
6	0,86	0,91	0,98	0,93	0,98	0,86
7	0,77	0,82	0,91	0,82	0,91	0,86
8	0,95	1,00	0,95	0,93	1,00	1,00
9	0,95	0,82	0,95	0,95	0,93	0,93
10	0,66	0,64	0,93	0,84	0,98	0,82
Média	0,83	0,78	0,92	0,88	0,94	0,88
Desvio	0,08	0,10	0,06	0,07	0,05	0,05

Enfim, o último teste, o geral, avalia todo o funcionamento da SSVEP-BCI aco-
plada a uma aplicação. Houve apenas três ocasiões preliminares (cada uma com um usuário diferente) em que o sistema foi testado dessa forma. Na primeira, um participante realizou o treinamento (nos mesmos moldes dos protocolos vistos) com dois estímulos (padrão reverso 2): um de 12 Hz e outro de 15 Hz. Com o sistema configurado para reconhecer as evocações, o usuário conseguiu guiar um carrinho de controle remoto (adaptado para receber os coman-
dos da interface) para frente (12 Hz) e para trás (15 Hz). O classificador *online* só conseguiu acertar de forma razoável quando as janelas de dados foram fixadas em 3 segundos. Para blo-
cos de amostras cada vez menores, o sistema visivelmente tendia para um comportamento

randômico. Nas outras duas circunstâncias, dois usuários foram capazes de guiar um protótipo de cadeira de rodas assistiva, mas ainda sem o uso de controle compartilhado e sem estarem sentados na mesma. Eles treinaram três comandos com figuras simples de 10, 12 e 15 Hz (respectivamente, virar a esquerda, deslocar para frente e virar para a direita). Nesses testes, o classificador, além das três evocações, também teve que distinguir o estado de repouso (ou seja, embora três comandos, quatro classes no total). Ambos os voluntários, expostos a pressão, deixaram de obter o controle da cadeira. Adiante, segue a Tabela 3.17, que mostra o desempenho alcançado para o treinamento durante esses ensaios.

Tabela 3.17: Desempenho de classificação para 4 estados.

Voluntário	Dados Brutos		CAR		TWAR	
	FFT	Welch	FFT	Welch	FFT	Welch
LSM						
1	0,91	0,86	0,98	0,90	0,99	0,90
2	0,88	0,70	0,83	0,70	0,88	0,78
FLD						
1	0,89	0,81	0,94	0,84	0,93	0,86
2	0,83	0,63	0,85	0,73	0,90	0,63

¹ World Medical Association. World Medical Association Declaration of Helsinki. Ethical Principles for Medical Research Involving Human Subjects. *Bulletin of the World Health Organization*, v. 79, n. 4, p. 373-374, 2001.

² CONEP. *SISNEP - Sistema Nacional de Ética em Pesquisa*. Disponível em: <<http://portal2.saude.gov.br/sisnep/pesquisador/>>. Acesso em: 04 jan. 2016.

³ Mario Kleiner et al. Overview. *Psychtoolbox-3*. Disponível em: <<http://psychtoolbox.org/overview/>>. Acesso em: 04 ago. 2015.

⁴ OpenGL Overview. *OpenGL - The Industry's Foundation for High Performance Graphics*. Disponível em: <<https://www.open-gl.org/about/>>. Acesso em: 04 ago. 2005.

⁵ Mario Kleiner et al. Op. cit.

⁶ g.tec medical engineering GmbH. *g.USBamp, USB Biosignal Amplifier: Instruction for use V2.11.03*. Schiedlberg: g.tec, 2011. p. 6.

⁷ Babak A. Taheri, Robert T. Knight, Rosemary L. Smith. A dry electrode for EEG recording. *Electroencephalography and Clinical Neurophysiology*, v. 90, n. 5, p. 377-378, 1994.

⁸ g.tec medical engineering GmbH. *g.SAHARAsys, Active Dry Electrode System: Instructions for use V1.11.01*. Schiedlberg: g.tec, 2011. p. 6.

⁹ Edward L. Reilly. EEG recording and operation of the apparatus. In: Ernst Niedermeyer, Fernando Lopes da Silva. *Electroencephalography: basic principles, clinical applications, and related fields*. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005. p. 141-142.

¹⁰ Sarah N. Carvalho et al. Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs. *Biomedical Signal Processing and Control*, v. 21, n. 1, p. 36, 2015.

¹¹ Dezhong Yao et al. The effect of reference choices on the spatio-temporal analysis of brain evoked potentials: the use of infinite reference. *Computers in Biology and Medicine*, v. 37, n. 11, p. 1529, 2007.

¹² g.tec medical engineering GmbH. *g.SAHARAsys, Active Dry Electrode System: Instructions for use V1.11.01*. Schiedlberg: g.tec, 2011. p. 13-14.

¹³ William Clusin, Duilio Giannitrapani, Peter Roccaforte. A numerical approach to matching amplification for the spectral analysis of recorded EEG. *Electroencephalography and Clinical Neurophysiology*, v. 28, n. 6, p. 639-641, 1970.

¹⁴ Raymond C. Vasko Jr et al. Power spectral analysis of EEG in a multiple-bedroom, multiple-polygraph sleep laboratory. *International Journal of Medical Informatics*, v. 46, n. 3, p. 177-178, 1997.

¹⁵ Emily S. Kappenman, Steven J. Luck. The effects of electrode impedance on data quality and statistical significance in ERP recordings. *Psychophysiology*, v. 47, n. 5, p. 889-890, 2010.

¹⁶ Sarah N. Carvalho et al. Op. cit., p. 41-42, 2015.

¹⁷ Sarah N. Carvalho et al. *Effect of the combination of different numbers of flickering frequencies in an SSVEP-BCI for healthy volunteers and stroke patients*. 7th Annual International IEEE EMBS Conference on Neural Engineering. Montpellier: [s.n.]. 2015. p. 78-81.

CONCLUSÕES E PERSPECTIVAS

O principal objetivo deste estudo, que era planejar e projetar uma interface cérebro-computador a partir de alguma manifestação eletroencefalográfica, foi cumprido. O paradigma escolhido se baseou em potenciais evocados visualmente em regime estacionário e possibilitou que alguns voluntários enviassem sinais de controle com o uso de estímulos visuais repetitivos em 10, 12 e 15 Hz (embora outras tenham sido testadas, as frequências mencionadas foram as que melhor funcionaram). Além desse intuito, o sistema foi construído de forma modular para que fosse conveniente testar novas técnicas de processamento: tanto para remoção de artefatos e extração de atributos quanto para a seleção e classificação de padrões. Inclusive, em parte, a SSVEP-BCI foi projetada com alguns dos algoritmos mais simples e clássicos disponíveis na literatura, para que estes se tornem uma base de comparação mínima quando novos métodos forem propostos.

Apesar dessas características, o sistema (ainda preliminar) carece de uma série de testes e melhoramentos. Por exemplo, o módulo de estimulação não possibilita (sem que demande um tempo adicional para programar) a confecção de um variado leque de padrões de estimulação. Além disso, o mesmo ainda tem severas limitações de comunicação com os demais módulos, o que dificulta o estudo de tarefas e estímulos que requisitam atualizações de tela sincronizadas com o registro de EEG. Já o módulo de aquisição é pouco flexível, pois foi criado com uma API fornecida pela empresa que fabrica o amplificador de sinais biológicos. Por causa disso, o sistema, como um todo, está restrito a um sistema operacional Windows 7 de 32 bits. Para tornar a BCI compatível com outros sistemas, uma tarefa importante a ser realizada futuramente é a adaptação da mencionada API, de forma que os sinais eletroencefalográficos possam ser medidos e salvos em outras plataformas computacionais. Quanto às técnicas selecionadas para identificar os SSVEPs, ainda há muito por fazer e descobrir. A maior parte delas funciona apenas em circunstâncias ideais: o usuário não pode se mexer em demasia, o ambiente não pode estar repleto de interferentes eletromagnéticos, o usuário precisa se concentrar plenamente na tarefa e não estar exposto a distrações ou situações de pressão (excesso de informação), entre outras. Fora dessa alçada, a detecção de atividades cerebrais se torna altamente desafiante e, por carência de métodos mais robustos, o sistema de comunicação começa a transmitir com muitos erros, o que costuma inviabilizar a execução de tarefas. Apesar disso, com o sistema construído já é possível pensar a integração com o módulo compartilhado de uma cadeira de rodas assistiva, embora, provavelmente, uma série de novos

problemas provavelmente surgirá, para os quais a BCI ainda não está adaptada. No entanto, existe um programa suficientemente flexível para, daqui em diante, iniciar essa etapa.

A construção da BCI baseada em SSVEPs também levou a várias indagações sobre a relação entre os RVSS e as evocações subsequentes. Constatou-se que não existem muitos estudos sobre esse tema e que, além das características de fase e frequência, sabe-se pouco sobre a emergência de padrões de evocação, sobre a previsibilidade (ou não) das não linearidades do sinal, sobre as condições em que a manifestação desaparece (mesmo com o usuário olhando fixamente para o estímulo) e sobre o motivo (ou motivos) de alguns estímulos (padrão e frequência) evocarem mais do que outros. É necessário pensar todo um conjunto de experimentos que ajudem a responder, pelo menos em parte, esses levantamentos. Afinal, a SSVEP-BCI, além de evidentemente se beneficiar desses estudos em perspectiva, também é uma ferramenta prática de investigação dos mesmos e, por isso, tem valor para a área de neurociências.

REFERÊNCIAS

ABOUT GNU Octave. **GNU Octave**. Disponível em: <<https://www.gnu.org/software/octave/about.html>>. Acesso em: 02 ago. 2015.

ADRIAN, E. D.; MATTHEWS, B. H. C. The Berger rhythm: potential changes from the occipital lobes in man. **Brain**, v. 57, n. 4, p. 355-385, 1934.

ALARCON, G.; GUY, C. N.; BINNIE, C. D. A simple algorithm for a digital three-pole Butterworth filter of arbitrary cut-off frequency: application to digital electroencephalography. **Journal of Neuroscience Methods**, v. 104, n. 1, p. 35-44, 2000.

ALLISON, B. Z. et al. How many (and what kinds of) people can use an SSVEP BCI? **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 18, n. 2, p. 107-116, 2010.

ALLISON, B. Z.; NEUPER, C. Could anyone use a BCI? In: TAN, D. S.; NIJHOLT, A. **Brain-computer interfaces**. 1. ed. London: Springer, 2010. p. 35-54.

ANDERMANN, F. Herbert Henri Jasper 1906-1999. **Epilepsia**, v. 41, n. 1, p. 113-120, 2000.

BAIN, J. S. **Barriers to New Competition**. 1. ed. Cambridge: Harvard University Press, 1956.

BAUER, G.; GERSTENBRAND, F.; RUMPL, E. Varieties of the locked-in syndrome. **Journal of Neurology**, v. 221, n. 2, p. 77-91, 1979.

BERGER, H. Über das elektrenkephalogramm des menschen. **European Archives of Psychiatry and Clinical Neuroscience**, v. 87, n. 1, p. 527-570, 1929.

BIRBAUMER, N. Breaking the silence: brain-computer interfaces (BCI) for communication and motor control. **Psychophysiology**, v. 43, n. 6, p. 517-532, 2006.

BIRBAUMER, N. et al. A spelling device for the paralysed. **Nature**, v. 398, n. 1, p. 297-298, 1999.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. 1. ed. New York: Springer, 2006.

BLANKERTZ, B. et al. The non-invasive Berlin brain-computer interface: fast acquisition of effective performance in untrained subjects. **NeuroImage**, v. 37, n. 2, p. 539-550, 2007.

BLANKERTZ, B. et al. Optimizing spatial filters for robust EEG single-trial analysis. **IEEE Signal Processing Magazine**, v. 25, n. 1, p. 41-56, 2008.

BLUM, A. L.; LANGLEY, P. Selection of relevant features and examples in machine learning. **Artificial Intelligence**, v. 97, n. 1, p. 245-271, 1997.

BODENSTEIN, G.; PRAETORIUS, H. M. Feature extraction from the electroencephalogram by adaptive segmentation. **Proceedings of the IEEE**, v. 65, n. 5, p. 642-652, 1977.

BONITA, R. Epidemiology of stroke. **The Lancet**, v. 339, n. 8789, p. 342-344, 1992.

BRAIN Initiative. **Wikipedia, the free encyclopedia**. Disponível em: <https://en.wikipedia.org/wiki/BRAIN_Initiative>. Acesso em: 04 jan. 2016.

BURKITT, G. R. et al. Steady-state visual evoked potentials and travelling waves. **Clinical Neurophysiology**, v. 111, n. 2, p. 246-258, 2000.

BUTTERWORTH, S. On the theory of filter amplifiers. **Wireless Engineer**, v. 7, n. 6, p. 536-541, 1930.

CARVALHO, S. N. et al. Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs. **Biomedical Signal Processing and Control**, v. 21, n. 1, p. 34-42, 2015.

CARVALHO, S. N. et al. **Effect of the combination of different numbers of flickering frequencies in an SSVEP-BCI for healthy volunteers and stroke patients**. 7th Annual International IEEE EMBS Conference on Neural Engineering. Montpellier: [s.n.]. 2015. p. 78-81.

CATON, R. Electrical currents of the brain. **The Journal of Nervous and Mental Disease**, v. 2, n. 4, p. 610, 1875.

CHENG, M.; GAO, S. **An EEG-based cursor control system**. Proceedings of The First Joint BMES/EMBS Conference. Atlanta: [s.n.]. 1999. p. 669.

CHENG, M.; GAO, X.; GAO, S. Design and implementation of a brain-computer interface with high transfer rates. **IEEE Transactions on Biomedical Engineering**, v. 49, n. 10, p. 1181-1186, 2002.

CINCOTTI, F. et al. Non-invasive brain-computer interface system: towards its application as assistive technology. **Brain research bulletin**, v. 75, n. 6, p. 796-803, 2008.

CLUSIN, W.; GIANNITRAPANI, D.; ROCCAFORTE, P. A numerical approach to matching amplification for the spectral analysis of recorded EEG. **Electroencephalography and Clinical Neurophysiology**, v. 28, n. 6, p. 639-641, 1970.

CONEP. **SISNEP - Sistema Nacional de Ética em Pesquisa**. Disponível em: <<http://portal2.saude.gov.br/sisnep/pesquisador/>>. Acesso em: 04 jan. 2016.

COOLEY, J. W.; TUKEY, J. W. An algorithm for the machine calculation of complex Fourier series. **Mathematics of Computation**, v. 19, n. 90, p. 297-301, 1965.

DALY, J. J.; WOLPAW, J. R. Brain-computer interfaces in neurological rehabilitation. **The Lancet Neurology**, v. 7, n. 11, p. 1032-1043, 2008.

DAWSON, G. D. A summation technique for the detection of small evoked potentials. **Electroencephalography and Clinical Neurophysiology**, v. 6, n. 1, p. 65-84, 1954.

DI RUSSO, F. et al. Spatiotemporal analysis of the cortical sources of the steady-state visual evoked potential. **Human Brain Mapping**, v. 28, n. 4, p. 323-334, 2007.

- DONCHIN, E.; COHEN, L. Averaged evoked potentials and intramodality selective attention. **Electroencephalography and Clinical Neurophysiology**, v. 22, n. 6, p. 537-546, 1967.
- DONNAN, G. A. et al. Stroke. **The Lancet**, v. 371, n. 9624, p. 1612-1623, 2008.
- DORNHEGE, G. et al. General signal processing and machine learning tools for BCI analysis. In: DORNHEGE, G., et al. **Toward Brain-Computer Interfacing**. 1. ed. Cambridge: The MIT Press, 2007. p. 207-233.
- DREYFUS, G.; GUYON, I. Assessment methods. In: GUYON, I., et al. **Feature Extraction: Foundations and Applications**. 1. ed. New York: Springer, 2006. p. 65-88.
- DUCH, W. Filter methods. In: GUYON, I., et al. **Feature Extraction: Foundations and Applications**. 1. ed. New York: Springer, 2006. p. 89-117.
- DUDA, R.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2. ed. New York: John Wiley & Sons, 2001.
- DUHAMEL, P.; MARTINI, V. Fast Fourier transforms: a tutorial review and a state of the art. **Signal Processing**, v. 19, n. 4, p. 259-299, 1990.
- FARWELL, L. A.; DONCHIN, E. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. **Electroencephalography and Clinical Neurophysiology**, v. 70, n. 6, p. 510-523, 1988.
- FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of Eugenics**, v. 7, n. 2, p. 179-188, 1936.
- FISHER, R. S. et al. Photic-and pattern-induced seizures: a review for the Epilepsy Foundation of America Working Group. **Epilepsia**, v. 46, n. 9, p. 1426-1441, 2005.
- FOX, C. The conditions which arouse mental images in thought. **British Journal of Psychology**, v. 6, n. 3-4, p. 420-431, 1914.
- FREEMAN, C.; SOETE, L. **A Economia da Inovação Industrial**. 1. ed. Campinas: Unicamp, 2008.
- GALÁN, F. et al. A brain-actuated wheelchair: asynchronous and non-invasive brain-computer interfaces for continuous control of robots. **Clinical Neurophysiology**, v. 119, n. 9, p. 2159-2169, 2008.
- GARCIA-MOLINA, G.; ZHU, D. **Optimal spatial filtering for the steady state visual evoked potential: BCI application**. Proceedings of the 5th International IEEE EMBS Conference on Neural Engineering. Cancun: [s.n.]. 2011. p. 156-160.
- GASTAUT, H. J. Etude électrocorticographique de la réactivité des rythmes rolandiques. **Revue Neurologique**, v. 87, n. 2, p. 176-182, 1952.
- GHEZ, C.; KRAKAUER, J. The Organization of Movement. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. **Principles of Neural Science**. 4. ed. New York: McGraw-Hill, 2000. p. 653-673.

- GMBH, G. T. M. E. **g.SAHARAsys, Active Dry Electrode System**: Instructions for use V1.11.01. Schiedlberg: g.tec, 2011.
- GMBH, G. T. M. E. **g.USBamp, USB Biosignal Amplifier**: Instruction for use V2.11.03. Schiedlberg: g.tec, 2011.
- GOLLA, F.; HUTTON, E. L.; GREY WALTER, W. The objective study of mental imagery. I. Physiological concomitants. **Journal of Mental Science**, v. 89, n. 1, p. 216–223, 1943.
- GUGER, C. et al. How many people are able to operate an EEG-based brain-computer interface (BCI)? **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 11, n. 2, p. 145-147, 2003.
- GUGER, C. et al. How many people are able to control a P300-based brain-computer interface (BCI)? **Neuroscience Letters**, v. 462, n. 1, p. 94-98, 2009.
- GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. **Journal of Machine Learning Research**, v. 3, n. 1, p. 1157-1182, 2003.
- GUYON, I.; ELISSEEFF, A. An introduction to feature extraction. In: GUYON, I., et al. **Feature Extraction: Foundations and Applications**. 1. ed. New York: Springer, 2006. p. 1-25.
- HAAS, L. F. Hans Berger (1873-1941), Richard Caton (1842-1926), and electroencephalography. **Journal of Neurology, Neurosurgery & Psychiatry**, v. 74, n. 1, p. 9, 2003.
- HILLYARD, S. A.; KUTAS, M. Electrophysiology of cognitive processing. **Annual Review of Psychology**, v. 34, n. 1, p. 33-61, 1983.
- HUMAN Brain Project. **Wikipedia, the free encyclopedia**. Disponível em: <https://en.wikipedia.org/wiki/Human_Brain_Project>. Acesso em: 04 jan. 2016.
- INSTITUTO de Pesquisa sobre Neurociências e Neurotecnologia. **CEPID Centros de Pesquisa, Inovação e Difusão**. Disponível em: <<http://cepid.fapesp.br/centro/11/>>. Acesso em: 21 abr. 2015.
- JASPER, H. H. The ten-twenty electrode system of the International Federation. **Electroencephalography and Clinical Neurophysiology**, v. 10, n. 1, p. 371-375, 1958.
- JASPER, H. H.; CARMICHAEL, L. Electrical potentials from the intact human brain. **Science**, v. 81, n. 1, p. 51-53, 1935.
- JASPER, H. H.; PENFIELD, W. Electrocorticograms in man: effect of the voluntary movement upon the electrical activity of the precentral gyrus. **Archiv für Psychiatrie und Nervenkrankheiten**, v. 183, n. 1, p. 163-174, 1949.
- JEANNEROD, M. Mental imagery in the motor context. **Neuropsychologia**, v. 33, n. 11, p. 1419-1432, 1995.
- KANDEL, E. R. Nerve cells and behavior. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. **Principles of Neural Science**. 4. ed. New York: McGraw-Hill, 2000. p. 19-35.

KANDEL, E. R.; SIEGELBAUM, S. A. Synaptic integration. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. **Principles of Neural Science**. 4. ed. New York: McGraw-Hill, 2000. p. 207-228.

KAPPENMAN, E. S.; LUCK, S. J. The effects of electrode impedance on data quality and statistical significance in ERP recordings. **Psychophysiology**, v. 47, n. 5, p. 888-904, 2010.

KLEINER, M. et al. Overview. **Psychtoolbox-3**. Disponível em: <<http://psychtoolbox.org/overview/>>. Acesso em: 04 ago. 2015.

KOBAL, G.; HUMMEL, C. Cerebral chemosensory evoked potentials elicited by chemical stimulation of the human olfactory and respiratory nasal mucosa. **Electroencephalography and Clinical Neurophysiology**, v. 71, n. 4, p. 241-250, 1988.

KOESTER, J.; SIEGELBAUM, S. A. Membrane potencial. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. **Principles of Neural Science**. 4. ed. New York: McGraw-Hill, 2000. p. 125-139.

KOESTER, J.; SIEGELBAUM, S. A. Propagated signaling: the action potential. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. **Principles of Neural Science**. 4. ed. New York: McGraw-Hill, 2000. p. 150-170.

KOHAVI, R. **A study of cross-validation and bootstrap for accuracy estimation and model selection**. International Joint Conference on Artificial Intelligence. Montreal: [s.n.]. 1995. p. 1137-1145.

KOHAVI, R.; JOHN, G. H. Wrappers for feature subset selection. **Artificial intelligence**, v. 97, n. 1, p. 273-324, 1997.

KRAUSS, G. L.; WEBBER, W. R. S. Digital EEG. In: NIEDERMEYER, E.; LOPES DA SILVA, F. **Electroencephalography: basic principles, clinical applications, and related fields**. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005. p. 797-813.

KÜBLER, A.; MÜLLER, K.-R. An introduction to brain-computer interfacing. In: DORNHEGE, G., et al. **Toward Brain-Computer Interfacing**. 1. ed. Cambridge: The MIT Press, 2007. p. 1-25.

KUHLMAN, W. N. Functional topography of the human mu rhythm. **Electroencephalography and Clinical Neurophysiology**, v. 44, n. 1, p. 83-93, 1978.

LAPLANTE, M. P.; HENDERSHOT, G. E.; MOSS, A. J. Assistive technology devices and home accessibility features: prevalence, payment, need, and trends. **Advance Data from Vital and Health Statistics**, v. 217, n. 1, p. 1-12, 1992.

LEEB, R. et al. Self-paced (asynchronous) BCI control of a wheelchair in virtual environments: a case study with a tetraplegic. **Computational intelligence and neuroscience**, p. 1-8, 2007.

LENIN, V. **Imperialismo: fase superior do Capitalismo**. 4. ed. São Paulo: Global, 1987.

LISTA das definições da ISO 9999:2007. **Catálogo Nacional de Produtos de Tecnologia Assistiva**. Disponível em: <<http://assistiva.mct.gov.br/lista-das-definicoes-da-iso-9999->>

2007>. Acesso em: 05 maio 2015.

LYONS, R. G. **Understanding Digital Signal Processing**. 2. ed. New Jersey: Prentice Hall PTR, 2004.

MACDONALD, J. W.; SADOWSKY, C. Spinal-cord injury. **The Lancet**, v. 359, n. 1, p. 417-425, 2002.

MAK, J. N.; WOLPAW, J. R. Clinical applications of brain-computer interfaces: current state and future prospects. **IEEE Reviews in Biomedical Engineering**, v. 2, n. 1, p. 187-199, 2009.

MATLAB Product Description. **MathWorks**. Disponível em: <http://www.mathworks.com/help/matlab/learn_matlab/product-description.html>. Acesso em: 04 jun. 2015.

MCFARLAND, D. J. et al. Spatial filter selection for EEG-based communication. **Electroencephalography and Clinical Neurophysiology**, v. 103, n. 3, p. 386-394, 1997.

MELLINGER, J.; SCHALK, G. BCI2000: a general-purpose software platform for BCI research. In: DORNHEGE, G., et al. **Toward Brain-Computer Interfacing**. 1. ed. Cambridge: The MIT Press, 2007. p. 359-368.

MILLÁN, J. D. R. et al. Combining brain-computer interfaces and assistive technologies: state-of-the-art and challenges. **Frontiers in Neuroscience**, v. 4, n. 1, p. 1-15, 2010.

MILLÁN, J. D. R.; FERREZ, P. W.; BUTTFIELD, A. The IDIAP brain-computer interface: an asynchronous multiclass approach. In: DORNHEGE, G., et al. **Toward Brain-Computer Interfacing**. 1. ed. Cambridge: The MIT Press, 2007. p. 103-121.

NAKANISHI, T.; TAKITA, K.; TOYOKURA, Y. Somatosensory evoked responses to tactile tap in man. **Electroencephalography and Clinical Neurophysiology**, v. 34, n. 1, p. 1-6, 1973.

NIEDERMEYER, E. The normal EEG of the waking adult. In: NIEDERMEYER, E.; LOPES DA SILVA, F. **Electroencephalography: basic principles, clinical applications, and related fields**. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005. p. 167-192.

NIJHOLT, A.; TAN, D. Brain-computer interfacing for intelligent systems. **IEEE Intelligent Systems**, v. 23, n. 3, p. 72-79, 2008.

NUWER, M. R. et al. IFCN standards for digital recording of clinical EEG. **Electroencephalography and Clinical Neurophysiology**, v. 106, n. 3, p. 259-261, 1998.

OBITUARY. Richard Caton, C.B.E., M.D., F.R.C.P. **The British Medical Journal**, v. 1, n. 1, p. 71-72, 1926.

ODOM, J. V. et al. Visual evoked potentials standard (2004). **Documenta Ophthalmologica**, v. 108, n. 2, p. 115-123, 2004.

ODOM, J. V. et al. ISCEV standard for clinical visual evoked potentials (2009 update). **Documenta Ophthalmologica**, v. 120, n. 1, p. 111-119, 2010.

OGAWA, S. et al. Brain magnetic resonance imaging with contrast dependent on blood oxygenation. **Proceedings of the National Academy of Sciences**, v. 87, n. 24, p. 9868-9872, 1990.

OPENGL Overview. **OpenGL - The Industry's Foundation for High Performance Graphics**. Disponível em: <<https://www.opengl.org/about/>>. Acesso em: 04 ago. 2005.

OPENVIBE: The first French software programme enabling "action through thought". **Inria Inventors for the Digital World**, 2009. Disponível em: <<https://www.inria.fr/en/news/mediacentre/openvibe>>. Acesso em: 18 maio 2015.

PATTERN. **Wikipedia, the free encyclopedia**. Disponível em: <<https://en.wikipedia.org/wiki/Pattern>>. Acesso em: 18 ago. 2015.

PENROSE, R. A generalized inverse for matrices. **Mathematical Proceedings of the Cambridge Philosophical Society**, v. 51, n. 3, p. 406-413, 1955.

PFURTSCHELLER, G. et al. Current trends in Graz brain-computer interface (BCI) research. **IEEE Transactions on Rehabilitation Engineering**, v. 8, n. 2, p. 216-219, 2000.

PFURTSCHELLER, G.; LOPES DA SILVA, F. H. Event-related EEG/MEG synchronization and desynchronization: basic principles. **Clinical Neurophysiology**, v. 110, n. 11, p. 1842-1857, 1999.

PFURTSCHELLER, G.; NEUPER, C. Motor imagery activates primary sensorimotor area in humans. **Neuroscience Letters**, v. 239, n. 2, p. 65-68, 1997.

PFURTSCHELLER, G.; NEUPER, C. Motor imagery and direct brain-computer communication. **Proceedings of the IEEE**, v. 89, n. 7, p. 1123-1134, 2001.

PICTON, T. W. The P300 wave of the human event-related potential. **Journal of Clinical Neurophysiology**, v. 9, n. 4, p. 456-479, 1992.

PICTON, T. W. et al. Human auditory evoked potentials. I: Evaluation of components. **Electroencephalography and Clinical Neurophysiology**, v. 36, n. 1, p. 179-190, 1974.

PLATÃO. Parmênides. In: IGLÉSIAS, M.; RODRIGUES, F. **Parmênides. Texto grego estabelecido e anotado por John Burnet**. 3. ed. Rio de Janeiro & São Paulo: PUC-Rio & Loyola, 2003. p. 20-129.

POLICH, J. Updating P300: an integrative theory of P3a and P3b. **Clinical Neurophysiology**, v. 118, n. 10, p. 2128-2148, 2007.

RAUERN, C. V. **Mudanças técnicas e políticas públicas: experiências internacionais na difusão da banda larga e o caso brasileiro**. Tese (Doutorado em Teoria Econômica). Instituto de Economia. Universidade Estadual de Campinas. Campinas. 2013.

REGAN, D. An effect of stimulus colour on average steady-state potentials evoked in man. **Nature**, v. 210, n. 1, p. 1056 - 1057, 1966.

REGAN, D. Some characteristics of average steady-state and transient responses evoked by modulated light. **Electroencephalography and Clinical Neurophysiology**, v. 20, n. 3, p.

238-248, 1966.

REGAN, D. Comparison of transient and steady-state methods. **Annals of the New York Academy of Sciences**, v. 338, n. 1, p. 45-71, 1980.

REILLY, E. L. EEG recording and operation of the apparatus. In: NIEDERMEYER, E.; LOPES DA SILVA, F. **Electroencephalography: basic principles, clinical applications, and related fields**. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005. p. 139-159.

RENARD, Y. et al. OpenViBE: An Open-Source Software Platform to Design, Test and Use Brain-Computer Interfaces in Real and Virtual Environments. **Presence: Teleoperators and Virtual Environments**, v. 19, n. 1, p. 35-56, 2010.

RITTER, W.; VAUGHAN, H. G. Averaged evoked responses in vigilance and discrimination: a reassessment. **Science**, v. 164, n. 1, p. 326-328, 1969.

RITTER, W.; VAUGHAN, H. G.; COSTA, L. D. Orienting and habituation to auditory stimuli: a study of short terms changes in average evoked responses. **Electroencephalography and Clinical Neurophysiology**, v. 25, n. 6, p. 550-556, 1968.

ROWLAND, L. P.; SHNEIDER, N. A. Amyotrophic lateral sclerosis. **New England Journal of Medicine**, v. 344, n. 22, p. 1688-1700, 2001.

SCHALK, G. et al. BCI2000: A General-Purpose Brain-Computer. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 6, p. 1034-1043, 2004.

SCHLÖGL, A. et al. BioSig: an open-source software library for bci research. In: DORNHEGE, G., et al. **Toward Brain-Computer Interfacing**. 1. ed. Cambridge: The MIT Press, 2007. p. 347-358.

SHANNON, C. E. A Mathematical Theory of Communication. **The Bell System Technical Journal**, v. 27, n. 1, p. 379-423, 623-656, 1948.

SHORT, P. L. The objective study of mental imagery. **British Journal of Psychology**, v. 44, n. 1, p. 38-51, 1953.

SIGNAL Processing Toolbox. **MathWorks**. Disponível em: <<http://www.mathworks.com/help/signal/index.html>>. Acesso em: 15 jun. 2015.

SINGER, W. Synchronization of cortical activity and its putative role. **Annual Review of Physiology**, v. 55, n. 1, p. 349-374, 1993.

SLATTER, K. H. Alpha rhythms and mental imagery. **Electroencephalography and Clinical Neurophysiology**, v. 12, n. 4, p. 851-859, 1960.

SMITH, D. B. D. et al. Auditory averaged evoked potentials in man during selective binaural listening. **Electroencephalography and Clinical Neurophysiology**, v. 28, n. 2, p. 146-152, 1970.

SMITH, E.; DELARGY, M. Locked-in syndrome. **British Medical Journal**, v. 330, n. 7488, p. 406-409, 2005.

SPECKMANN, E. J.; ELGER, C. E. Introduction to the neurophysiological basis of the EEG and DC potentials. In: NIEDERMEYER, E.; LOPES DA SILVA, F. **Electroencephalography: basic principles, clinical applications, and related fields**. 5. ed. Philadelphia: Lippincott Williams & Wilkins, 2005. p. 17-29.

SRINIVASAN, R.; BIBI, F. A.; NUNEZ, P. L. Steady-state visual evoked potentials: distributed local sources and wave-like dynamics are sensitive to flicker frequency. **Brain Topography**, v. 18, n. 3, p. 167-187, 2006.

STEWART, I. **What shape is a snowflake?** 1. ed. London: Weidenfeld & Nicolson, 2001.

SUTTER, E. E. **The visual evoked response as a communication channel**. Proceedings of the IEEE Symposium on Biosensors. Los Angeles: [s.n.]. 1984. p. 95-100.

SUTTER, E. E. The brain response interface: communication through visually-induced electrical brain responses. **Journal of Microcomputer Applications**, v. 15, n. 1, p. 31-45, 1992.

SUTTON, S.; BRAREN, M.; ZUBIN, J. Evoked-potential correlates of stimulus uncertainty. **Science**, v. 150, n. 1, p. 1187-1188, 1965.

SUTTON, S.; TUETING, P.; ZUBIN, J. Information delivery and the sensory evoked potential. **Science**, v. 155, n. 1, p. 1436-1439, 1967.

TAHERI, B. A.; KNIGHT, R. T.; SMITH, R. L. A dry electrode for EEG recording. **Electroencephalography and Clinical Neurophysiology**, v. 90, n. 5, p. 376-383, 1994.

URIBE, L. F. S. **Desenvolvimento de uma interface homem-máquina baseada em potenciais evocados visuais em regime estacionário**. Dissertação (Mestrado em Engenharia Elétrica). Faculdade de Engenharia Elétrica e de Computação. Universidade Estadual de Campinas. Campinas. 2013.

VASKO JR., R. C. et al. Power spectral analysis of EEG in a multiple-bedroom, multiple-polygraph sleep laboratory. **International Journal of Medical Informatics**, v. 46, n. 3, p. 175-184, 1997.

VAUGHAN, H. G.; RITTER, W. The sources of auditory evoked responses recorded from the human scalp. **Electroencephalography and Clinical Neurophysiology**, v. 28, n. 4, p. 360-367, 1970.

VIALATTE, F.-B. et al. Steady-state visually evoked potentials: focus on essential paradigms and future perspectives. **Progress in Neurobiology**, v. 90, n. 4, p. 418-438, 2010.

VIDAL, J. J. Toward direct brain-computer communication. **Annual Review of Biophysics and Bioengineering**, v. 2, n. 1, p. 157-180, 1973.

VIDAL, J. J. Real-time detection of brain events in EEG. **Proceedings of the IEEE**, v. 65, n. 5, p. 633-641, 1977.

VIDAL, J. J. Jacques J. VIDAL. **Jacques Vidal Private Page**. Disponível em: <<http://www.cs.ucla.edu/~vidal/vidal.html>>. Acesso em: 30 mar. 2014.

VILLRINGER, A. et al. Near infrared spectroscopy (NIRS): a new tool to study hemodynamic changes during activation of brain function in human adults. **Neuroscience Letters**, v. 154, n. 1, p. 101-104, 1993.

VINTIADIS, E. Emergence. **Internet Encyclopedia of Philosophy**. Disponível em: <<http://www.iep.utm.edu/emergenc/>>. Acesso em: 18 ago. 2015.

VOLOSYAK, I. et al. BCI demographics II: how many (and what kinds of) people can use a high-frequency SSVEP BCI? **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 19, n. 3, p. 232-239, 2011.

WALTER, V. J.; GREY WALTER, W. The central effects of rhythmic sensory stimulation. **Electroencephalography and Clinical Neurophysiology**, v. 1, n. 1, p. 57-86, 1949.

WANG, Y. et al. Brain-computer interfaces based on visual evoked potentials. **IEEE Engineering in Medicine and Biology Magazine**, v. 27, n. 5, p. 64-71, 2008.

WELCH, P. D. The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. **IEEE Transactions on Audio and Electroacoustics**, v. 15, n. 2, p. 70-73, 1967.

WESTBROOK, G. L. Seizures and epilepsy. In: KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. **Principles of Neural Science**. 4. ed. New York: McGraw-Hill, 2000. p. 910-935.

WOLPAW, J. R. et al. An EEG-based brain-computer interface for cursor control. **Electroencephalography and Clinical Neurophysiology**, v. 78, n. 3, p. 252-259, 1991.

WOLPAW, J. R. et al. Brain-computer interface technology: a review of the first international meeting. **IEEE Transactions on Rehabilitation Engineering**, v. 8, n. 2, p. 164-173, 2000.

WOLPAW, J. R. et al. Brain-computer interfaces for communication and control. **Clinical Neurophysiology**, v. 113, n. 6, p. 767-791, 2002.

WOLPAW, J. R. et al. BCI meeting 2005 - workshop on signals and recording methods. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 14, n. 2, p. 138-141, 2006.

WOLPAW, J. R.; MCFARLAND, D. J.; VAUGHAN, T. M. Brain-computer interface research at the Wadsworth Center. **IEEE Transactions on Rehabilitation Engineering**, v. 8, n. 2, p. 222-226, 2000.

WOOTEN, B. R. Photopic and scotopic contributions to the human visually evoked cortical potential. **Vision Research**, v. 12, n. 10, p. 1647-1660, 1972.

WORLD MEDICAL ASSOCIATION. World Medical Association Declaration of Helsinki. Ethical Principles for Medical Research Involving Human Subjects. **Bulletin of the World Health Organization**, v. 79, n. 4, p. 373-374, 2001.

YAO, D. et al. The effect of reference choices on the spatio-temporal analysis of brain evoked potentials: the use of infinite reference. **Computers in Biology and Medicine**, v. 37, n. 11, p. 1529-1538, 2007.

ZHU, D. et al. A survey of stimulation methods used in SSVEP-based BCIs. **Computational Intelligence and Neuroscience**, v. 210, n. 1, p. 1-12, 2010.

ZICKLER, C. et al. A brain-computer interface as input channel for a standard assistive technology software. **Clinical EEG and Neuroscience**, v. 42, n. 4, p. 236-244, 2011.

ANEXO – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Voluntários saudáveis

DESTINE: Desenvolvimento de Tecnologia de Informação para Neurologia

Pesquisadores responsáveis: Prof. Dr. Li Li Min e Profa. Dra. Gabriela Castellano

Você está sendo convidado a participar da pesquisa “Desenvolvimento de Tecnologia de Informação para Neurologia”, que tem como objetivo geral avaliar o uso de sistemas de computadores em pacientes com lesão do cérebro para a reabilitação. Espera-se com esta pesquisa desenvolver novos sistemas de computadores e equipamentos que auxiliem pessoas com algum tipo de lesão cerebral ou paralisia para que tenham a possibilidade de se mover ou se comunicar novamente com esses equipamentos. Para isso, serão feitos experimentos também com voluntários saudáveis, como é o seu caso.

Você poderá ser submetido a três tipos de exames: ressonância magnética (RM), eletroencefalografia (EEG) e tomografia de luz próximo da faixa de infravermelho (NIRS), para avaliar as estruturas cerebrais e seu funcionamento. Você poderá ser convidado mais de uma vez para realizar esses exames para aumentar a precisão dos resultados. Além disso, você poderá ser solicitado para testar alguns equipamentos em desenvolvimento, neste caso seriam realizados os exames de EEG e/ou NIRS com o intuito de captar sinais cerebrais para comandar os equipamentos, por exemplo, comandar uma cadeira de rodas à distância, sem estar sentado nela e sem fazer esforço físico. Todos esses exames são não invasivos, e nenhum deles utiliza radiação ionizante.

No exame de RM, você entrará na máquina de RM e lá permanecerá, deitado e imóvel, por volta de 30 a 60 minutos. Durante esse tempo a máquina medirá sinais provenientes do seu cérebro e fará imagens do mesmo. O exame não causa nenhuma dor e também não possui nenhum efeito nocivo para o corpo humano – em particular, nesta pesquisa não será feito nenhum exame de RM usando contraste. No entanto, você poderá sentir desconforto devido ao grande barulho que a máquina faz (para isso serão fornecidos tampões de ouvido), e ao fato de que você deverá permanecer o mais imóvel possível dentro da máquina, para que os sinais possam ser medidos de forma correta. Além disso, devido a que o campo magnético usado na máquina de RM é alto (como um forte ímã), caso você possua algum metal dentro do seu corpo (como pinos, marca-passos, próteses metálicas, balas de revólver), não

poderá, de nenhuma maneira, realizar o exame, e **NÃO DEVE DEIXAR DE AVISAR** o pesquisador responsável (que estiver realizando os exames). Por esse motivo também, antes de entrar na sala da RM, você deverá remover do corpo qualquer objeto metálico, como anéis, brincos, pulseiras e óculos, etc. Também é importante que você remova objetos magnetizados como cartões de crédito, pois eles podem ser apagados ou danificados pelo campo magnético.

No caso dos exames de EEG e NIRS, uma touca com vários sensores será colocada sobre sua cabeça, para a medida dos seus sinais cerebrais. Esses exames também não possuem nenhum efeito nocivo para o corpo humano, mas você poderá sentir dor e desconforto devido ao contato apertado e prolongado dos sensores sobre o couro cabeludo, devido a que a touca deve ser colocada bem apertada para poder medir bem o sinal. Para evitar ou minimizar esse desconforto, é importante que você avise a pessoa que estiver colocando a touca em você, sobre qualquer desconforto que sentir no momento da colocação da mesma. Você também poderá, se quiser, interromper a aquisição em qualquer momento que deseje e os sensores serão retirados, sem que isso acarrete nenhum prejuízo para sua pessoa.

A sua participação nesta pesquisa não implicará em nenhum benefício pessoal, não é obrigatória e não trará riscos previsíveis. Os riscos possíveis são mínimos, relacionados aos procedimentos clínicos não invasivos, descritos acima. Você não receberá nenhum pagamento por sua participação nesta pesquisa, mas caso venha a ter despesas de transporte ou alimentação para poder realizar estes exames, elas serão ressarcidas.

Caso queira, você poderá desistir da sua participação a qualquer momento, sem que isso lhe cause prejuízo. Você será acompanhado e assistido pelo pesquisador responsável e a sua equipe durante esses procedimentos, podendo fazer perguntas sobre qualquer dúvida que apareça durante todo o estudo. Os dados coletados estarão sob o resguardo científico e o sigilo profissional, e contribuirão para o alcance dos objetivos deste trabalho e para posteriores publicações dos dados.

Para quaisquer dúvidas, você pode contactar os pesquisadores responsáveis deste projeto: o Dr. Li Li Min, no ambulatório de Neurologia (tel: 19 3521 7754, email: li-min@fcm.unicamp.br, endereço: Departamento de Neurologia, Faculdade de Ciências Médicas, UNICAMP, Rua Tessália Vieira de Camargo, 126, CEP 13083-887, Campinas, SP), ou a Dra. Gabriela Castellano (tel: 19 3521 5519, email: gabriela@ifi.unicamp.br, endereço: Departamento de Raios Cósmicos e Cronologia, Instituto de Física Gleb Wataghin, UNICAMP, Rua Sérgio Buarque de Holanda, 777, CEP 13083-859, Campinas, SP).

Para denúncias ou reclamações referentes aos aspectos éticos você pode contactar o Comitê de Ética em Pesquisa da UNICAMP (tel: 3521-8936, email: cep@fcm.unicamp.br,

endereço: Rua Tessália Vieira de Camargo, 126, CEP 13083-887, Campinas, SP).

Você receberá uma cópia deste termo de consentimento esclarecido.

Eu li, entendi, e aceito participar voluntariamente desta pesquisa.

Nome legível do participante

Idade

Assinatura do participante

Assinatura do responsável

Assinatura do pesquisador

Campinas, ____/____/20____