

Universidade Federal de Ouro Preto Instituto de Ciências Exatas e Aplicadas Departamento de Engenharia Elétrica



Efeito das técnicas de filtragem espacial no desempenho de sistemas BCI-SSVEP: um estudo de caso

THIAGO VIEIRA TAVARES

Trabalho de Conclusão de Curso

João Monlevade, MG

2017

Thiago Vieira Tavares

Efeito das técnicas de filtragem espacial no desempenho de sistemas BCI-SSVEP: um estudo de caso

Orientadora Prof.^a Dr.^a Sarah Negreiros de Carvalho Leite Coorientador Prof. Dr. Glauco Ferreira Gazel Yared

> Trabalho de conclusão de curso apresentado à Universidade Federal de Ouro Preto como parte dos requisitos exigidos para obtenção do título de Bacharel em Engenharia Elétrica.

Universidade Federal de Ouro Preto João Monlevade, MG 2017

T231e Tavares, Thiago.

Efeito das técnicas de filtragem espacial no desempenho de sistemas BCI-SSVEP [manuscrito]: um estudo de caso / Thiago Tavares. - 2017.

50f.: il.: color; grafs; tabs.

Orientador: Prof. Dr. Sarah Leite. Coorientador: Prof. Dr. Glauco Yared.

Monografia (Graduação). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Departamento de Engenharia Elétrica.

1. Interação homem-máquina. 2. Interfaces de usuario (Sistema de computador). 3. Processamento de linguagem natural (Computação). I. Leite, Sarah. II. Yared, Glauco. III. Universidade Federal de Ouro Preto. IV. Titulo.

CDU: 004.5

Catalogação: ficha@sisbin.ufop.br



MINISTÉRIO DA EDUCAÇÃO Universidade Federal de Ouro Preto – UFOP Instituto de Ciências Exatas e Aplicadas Colegiado do Curso de Engenharia de Elétrica



ANEXO IV - ATA DE DEFESA

Aos 29 dias do mês de março de 2017, às 20h horas, no bloco H deste instituto, foi realizada a defesa de monografia pelo (a) formando (a) Thiago Vieira Tavares, sendo a comissão examinadora constituída pelos professores: Sarah Negreiros de Carvalho, Glauco Ferreira Gazel Yared, Fabrício Javier Erazo Costa e Romeu Yukio Takeda. O (a) candidato (a) apresentou a monografia intitulada: Efeito das técnicas de filtragem espacial no desempenho de sistemas BCI-SSVEP: Um estudo de caso. A comissão examinadora deliberou, por unanimidade, pela <u>oprovação</u> do(a) candidato(a), com a nota média <u>9,25</u>, de acordo com a tabela 1. Na forma regulamentar foi lavrada a presente ata que é assinada pelos membros da comissão examinadora e pelo (a) formando(a).

Tabela T – Nolas de avaliação da banca examinadora	Tabela 1	- Notas de	avaliação da	a banca	examinadora
--	----------	------------	--------------	---------	-------------

Banca Examinadora	Nota
Sarah Negreiros de Carvalho	9.5
Glauco Ferreira Gazel Yared	9.0
Fabrício Javier Erazo Costa	9,5
Romeu Yukio Takeda	9.0
Média	9.25

João Monlevade, 29 de março de 2017.

Professor(a) Orientador(a)

Professor(a) Convidado(a)

Professor(a) Coorientador(a)

Komar

Professor(a) Convidado(a)

Aluno (a)



MINISTÉRIO DA EDUCAÇÃO Universidade Federal de Ouro Preto – UFOP Instituto de Ciências Exatas e Aplicadas Colegiado do Curso de Engenharia de Elétrica



ANEXO X - TERMO DE RESPONSABILIDADE

O texto do trabalho de conclusão de curso intitulado "Efeito das técnicas de filtragem espacial no desempenho de sistemas BCI-SSVEP: um estudo de caso" é de minha inteira responsabilidade. Declaro que não há utilização indevida de texto, material fotográfico ou qualquer outro material pertencente a terceiros sem a devida citação ou consentimento dos referidos autores.

João Monlevade, 29 de março de 2017

1230 290 Tavares Thiago Vieira

Agradecimentos

Agradeço primeiramente a Deus, por ter me concedido o vigor necessário para transpor os desafios durante a graduação, sem Ele nada é possível.

Agradeço ao meu pai por ter me inspirado a buscar o meu engrandecimento profissional e por todo o apoio financeiro ao longo desses anos, custeando meus estudos. Minha mãe, por todo o carinho e amor incondicional demonstrados em toda minha vida. A toda a minha família, pelo apoio que me deram para sair de casa, mudar de cidade e alcançar meus objetivos.

Agradeço a todos os professores do Instituto de Ciências Exatas e Aplicadas.

Agradeço de forma especial ao professor Glauco Ferreira, pela confiança e ensinamentos durante a orientação em dois diferentes projetos de Iniciação Científica e pela coorientação neste Trabalho de Conclusão de Curso.

Agradeço de forma especial à professora Sarah Negreiros por ter aceitado ser minha orientadora neste Trabalho de Conclusão de Curso, agradeço pela paciência e conselhos indispensáveis para a conclusão desta monografia.

"Somos o que repetidamente fazemos. A excelência, portanto, não é um feito, mas um hábito." (Aristóteles)

Resumo

Interfaces Cérebro-Computador (BCI, do inglês: Brain Computer Interface) permitem aos usuários uma interação com dispositivos eletrônicos sem que seja necessário a movimentação de qualquer membro de seu corpo. Sinais de comandos originados diretamente no cortéx cerebral são utilizados para o controle das BCIs. Neste trabalho foram desenvolvidas todas as etapas de processamento necessárias para a construção de uma interface cérebro-computador baseada na abordagem SSVEP (do inglês: Steady-State Visually Evoked Potentials). O processamento de sinais cerebrais foi dividido em cinco etapas: 1. Segmentação dos dados; 2. Pré-processamento; 3. Extração de Características através da estimativa da Densidade Espectral de Potência; 4. Seleção de Atributos através da técnica de forward wrappers; 5. Classificação por meio de um classificador linear baseado no método de mínimos quadrados. Os objetivos deste trabalho foram estabelecer a comparação entre três técnicas de pré-processamento: CAR (do inglês: Common Average Reference), MEC (do inglês: Minimum Energy Combination) e MCC (do inglês: Maximum Contrast Combination); e avaliar o efeito da seleção de atributos. Todas as análises foram balizadas pela taxa de acerto do sistema. Os resultados comprovam a importância do pré-processamento e da seleção de atributos na implementação de uma BCI. Utilizando-se a filtragem espacial CAR juntamente com a seleção de atributos foi possível obter uma melhora no desempenho do sistema, podendo levar a uma taxa de acerto superior a 98,48%, considerando duas classes. Esse valor representa um ganho de 24% em relação ao cenário inicial, quando nenhuma técnica de filtragem e seleção são utilizadas.

Palavras-chave: BCI. Potencial Visual Evocado. Pré-Processamento. Filtragem Espacial. Classificação.

Abstract

Brain Computer Interface (BCI) allow users to interact with electronic devices without the need to move any member of their body. The brain signal can be directly employed to control a BCI. In this study all stages of signal processing were developed in order to design a BCI based on Steady State Visually Evoked Potential (SSVEP). The brain signal processing module was divided into five stages: 1. Data segmentation, 2. Pre-processing, 3. Features extraction, 4. Features Selection, 5. Classification. The objectives of this study were to establish a comparison between three techniques of pre-processing: CAR and MEC and MCC and evaluate the effect of the feature selection stage. All analyses were based on the accuracy of the system. The results showed the importance of the stages of pre-processing and feature selection for the implementation of a BCI. The combination of the spatial filter CAR with the features selection by forward wrappers resulted in an accuracy of 98,48 %, considering two classes. This value represents a gain of 24 % in relation to the initial scenario, where no filtering and selection techniques are used.

Keywords: BCI. Visually Evoked Potentials. Pre-processing. Spatial Filtering. Classification.

Lista de ilustrações

—	Regiões cerebrais: lobo frontal, parietal, occipital e temporal	5
—	Espectro de frequência típico para um sinal EEG adquirido durante	
	estimulação visual com frequência de 12 Hz	7
—	Sistema internacional de posicionamento de eletrodos (a) 10-20 e (b) $\hfill =$	
	10-10	9
. –	Sistema genérico de uma BCI baseada no paradigma SSVEP	10
—	Módulos de uma BCI padronizada	10
—	Tela com tabuleiros usados para gerar estímulos visuais em 12 e 15 Hz.	12
· _	Disposição dos eletrodos utilizados na aquisição do sinal cerebral. $\ .$.	13
—	Representação da segmentação dos dados	14
—	Seleção dos atributos por <i>forward wrappers</i>	21
0 -	Desempenho do classificador - 12 Hz e 15 Hz	26
1 –	Desempenho do classificador - 12 Hz e 15 Hz	27
2 -	Efeito da aplicação da filtragem CAR no tempo	27
3 -	Espectro do sinal coletado	28
4 –	Espectro do sinal filtrado.	28
		 Regiões cerebrais: lobo frontal, parietal, occipital e temporal Espectro de frequência típico para um sinal EEG adquirido durante estimulação visual com frequência de 12 Hz Sistema internacional de posicionamento de eletrodos (a) 10-20 e (b) 10-10 Sistema genérico de uma BCI baseada no paradigma SSVEP. Módulos de uma BCI padronizada. Tela com tabuleiros usados para gerar estímulos visuais em 12 e 15 Hz. Disposição dos eletrodos utilizados na aquisição do sinal cerebral. Representação da segmentação dos dados. Seleção dos atributos por <i>forward wrappers</i>. Desempenho do classificador - 12 Hz e 15 Hz. Efeito da aplicação da filtragem CAR no tempo. Espectro do sinal filtrado.

Sumário

1	INTRODUÇÃO	1
1.1	Objetivos	2
1.2	Publicação	2
1.3	Estrutura do Trabalho	3
2	REVISÃO BIBLIOGRÁFICA	4
2.1	Conceitos Fundamentais	4
2.1.1	Abordagem Experimental	5
2.1.2	Monitorando a Atividade Cerebral	7
2.1.3	BCI Baseada na Abordagem EEG-SSVEP	9
3	MATERIAIS E MÉTODOS	12
3.1	Pré-Processamento	13
3.1.1	Segmentação dos Dados	13
3.1.2	Common Average Reference	14
3.1.3	Minimum Energy Combination	15
3.1.4	Maximum Contrast Combination	18
3.2	Extração de Características	19
3.3	Seleção de Atributos	20
3.4	Classificador Linear	20
4	RESULTADOS	25
5	CONCLUSÃO	29
	REFERÊNCIAS	30
	ANEXOS	35

1 Introdução

De acordo com o censo demográfico publicado em 2010 pelo Instituto Brasileiro de Geografia e Estatística (IBGE) aproximadamente 4,5 milhões de brasileiros afirmaram possuir alguma deficiência severa. Essas pessoas afirmaram não possuir capacidade alguma na área específica da deficiência ou possuíam um elevado comprometimento funcional. Sendo que 23,6% (20,3 milhões) de toda a população que afirmou possuir uma deficiência física, severa ou não, estão inseridas no mercado de trabalho (DEMOGRÁFICO, 2010). Vale ressaltar, que o IBGE não leva em consideração laudos e avaliações de profissionais especializados.

Nos últimos anos, o Brasil têm intensificado o grau de investimento em ciência e tecnologia, de maneira a contribuir para a evolução da sociedade (CIÊNCIA TECNOLOGIA, 2016). Entre essas novas tecnologias estão aquelas denominadas de Tecnologias Assistivas (TA), que possuem o objetivo de melhorar e ampliar as habilidades funcionais dessa parcela da população, afim de promover à pessoa com deficiência maior independência, qualidade de vida e inclusão social, por meio da ampliação da sua mobilidade e capacidade de comunicação (BERSCH, 2010), contribuindo também para o aumento do número de pessoas com deficiência inseridas no mercado de trabalho. Dentre o público alvo dessas tecnologias estão pacientes com algum tipo de paralisia no controle voluntário dos músculos causado por lesões na medula espinhal, traumas cranianos ou doenças neurológicas degenerativas. As pessoas mais severamente afetadas podem perder o movimento dos membros periféricos, dos olhos e até o controle da respiração. Desse modo, esse trabalho está inserido neste novo campo de pesquisas que têm mostrado resultados animadores e que impacta as Tecnologias Assistivas

Na tentativa de poder ajudar pessoas que sofrem de alguma deficiência que incapacita o controle dos membros, novas técnicas de interação entre humanos e máquinas estão sendo desenvolvidas, por exemplo, LaCourse e Jr (1990) aproveita o movimento dos olhos para gerar sinais de comandos. Outro exemplo, é apresentado em Kilgore *et al.* (1997) que relata um estudo feito com pacientes com lesão na medula espinhal que utilizam a atividade muscular acima do nível da lesão na medula espinhal para conseguir controlar o excitamento elétrico dos músculos paralisados, restaurando parte do movimento.

Interfaces cérebro-computador são abordagens que permitem aos usuários interagir e controlar dispositivos eletrônicos com comandos cerebrais. Essas interfaces podem melhorar a qualidade de vida de muitos indivíduos que possuam um comprometimento funcional em algum membro ou até mesmo um comprometimento funcional de todo o seu corpo. A abordagem SSVEP (do inglês: *Steady-State Visually Evoked Potentials*) possibilita que

o usuário realize o controle da interface a partir de estímulos que cintilam com uma frequência constante.

As BCIs (do inglês: *Brain-Computer Interfaces*) têm habitado o imaginário de pesquisadores do mundo todo ao longo do último século. Esses vislumbram as possíveis aplicações dessas tecnologias que, certamente, mudam a comunicação entre humanos e dispositivos eletrônicos.

1.1 Objetivos

A partir do contexto do desenvolvimento de uma interface cérebro-computador baseada na abordagem experimental SSVEP, os objetivos desse trabalho são:

- Desenvolver toda a etapa de processamento de sinais de uma BCI, implementando as partes de pré-processamento, extração de características, seleção de características e classificação;
- 2. Comparar o impacto sobre o desempenho da BCI quando seis diferentes procedimentos de filtragem espacial são utilizadas na etapa de pré-processamento:
 - CAR (Common Average Reference)
 - MEC (Minimum Energy Combination)
 - MCC (Maximum Contrast Combination)
 - CAR combinado com MEC
 - CAR combinado com MCC
 - Sem Filtragem
- 3. Analisar a efetividade da seleção de atributos agregada ao sistema, comparando a técnica de *wrappers* com o caso em que não há seleção.

Em todos os cenários utilizaram-se janelas temporais de 3 s de modo a avaliar a viabilidade de empregar essas técnicas em sistemas BCI online.

1.2 Publicação

Os principais resultados deste trabalho foram apresentados e publicados nos Anais do VII Simpósio de Instrumentação e Imagens Médicas (SIIM) / VI Simpósio de Processamento de Sinais da UNICAMP - ISSN 2359-3334. Uma cópia do artigo está disponível no Anexo.

1.3 Estrutura do Trabalho

Essa monografia está dividida em cinco capítulos. O Capítulo 1, introdutório, menciona os aspectos gerais que correspondem à motivação e justificativa do trabalho.

O Capítulo 2 descreve os principais modos de desenvolvimento de uma interface cérebro-computador, expondo as ventagens e desvantagens das principais técnicas utilizadas na coleta e registro dos sinais provenientes do córtex cerebral. O estado da arte também é apresentado.

O Capítulo 3 apresenta toda a metodologia de desenvolvimento utilizada, uma detalhada descrição das técnicas de filtragem espacial empregadas no pré-processamento, assim como um relatório de todo o procedimento de extração das características, seleção de atributos e classificação.

No Capítulo 4 são retratados os resultados em diversos cenários de análise das técnicas de pré-processamento. Também é feita uma discussão crítica sobre os resultados e comentários sobre a performance apresentada pela BCI.

No Capítulo 5 é apresentado a conclusão do trabalho e também são feitas sugestões para trabalhos futuros.

2 Revisão Bibliográfica

2.1 Conceitos Fundamentais

De acordo com Wolpaw e Birbaumer (2006) as BCIs são mecanismos que possibilitam uma comunicação não muscular, uma interface direta entre o cérebro e o computador para a transmissão de mensagens e comandos para o mundo externo. Uma BCI precisa ser capaz de reconhecer dentre as atividades cerebrais do usuário aquelas relacionadas à sua intenção e convertê-la no comando correspondente. Dependendo da abordagem utilizada, esse controle pode ser obtido sem qualquer movimento físico promovendo um meio alternativo para reparar ou aumentar a cognição humana. A definição do termo BCI está diretamente ligada ao controle de uma interface e não apenas ao registro das atividades cerebrais, sendo que, este termo é adotado na literatura quando se trata de uma abordagem de comunicação unidirecional, em que a atividade mensurada origina no cérebro e segue para a interface.

Os pesquisadores têm usado diferentes tipos de estratégias BCIs nos mais variados grupos de indivíduos, desde de pessoas sem problemas físicos até pessoas que sofrem com disfunções severas que as tornam incapazes de realizar movimentos físicos, tais como a paralisia, o acidente vascular cerebral (AVC), a lesão da medula e a esclerose lateral amiotrófica (ELA). Existem trabalhos que mostram a possibilidade de comunicação com o mundo externo de pessoas em estado vegetativo (MONTI *et al.*, 2010).

Além do desenvolvimento de tecnologias BCIs ligadas à área clínica, recentemente muitos trabalhos envolvendo controle mental e games tem surgido. Em Ron-Angevin *et al.* (2009) as pessoas puderam utilizar a BCI para explorar a realidade virtual. Já em Krepki *et al.* (2007) e em Tangermann *et al.* (2008) o usuário utiliza o comando mental para controlar algum aspecto do jogo. Entretanto ainda existe um longo caminho e muitos desafios até que uma pessoa utilize essas tecnologias sem ajuda especializada.

Para entender como uma BCI opera é preciso antes conhecer como a atividade cerebral pode ser mensurada, levando em consideração os padrões fisiológicos do cérebro, e que tipo de estímulos são empregados. As estratégias comumentes utilizadas são a imagética motora (BAI *et al.*, 2010), potencias P300 (VERLEGER, 1988) e SSVEP (WANG *et al.*, 2008), entre outras. A estratégia mental determina as ações que o usuário deve seguir para produzir os padrões específicos que a BCI consegue interpretar e associar a um comando.

2.1.1 Abordagem Experimental

O movimento de um membro ou a simples imaginação do movimento de um membro modifica a atividade cerebral, mais especificamente a atividade cerebral localizada no córtex motor e somatossensorial, lobo frontal e lobo parietal (ver Figura 1)(PFURTSCHELLER; NEUPER, 2001). O movimento imaginário da mão direita pode ser facilmente detectado sob o lado esquerdo do córtex motor. O movimento imaginário da mão esquerda produz uma modificação na atividade cerebral mais proeminente sob o lado direito do córtex motor. Já o movimento imaginário de ambas as pernas é protuberante na parte central do córtex motor (GRAIMANN *et al.*, 2010). Dependendo da técnica utilizada para a aquisição dos sinais, a distinção entre os movimentos das pernas é praticamente impossível, por isso, geralmente o movimento imaginário de ambas as pernas é caracterizado como o mesmo comando (SCHLÖGL *et al.*, 2005). Os pesquisadores tem utilizado essas características da imagética motora para controlar as BCIs.

Figura 1 – Regiões cerebrais: lobo frontal, parietal, occipital e temporal.



Uma importante observação sobre as BCIs baseadas na imagética motora é o fato delas não precisarem de nenhum estímulo externo, sendo seus padrões gerados voluntariamente. Essa abordagem também é totalmente independente da necessidade de movimento do pescoço ou dos olhos. Entretanto, essa estratégia mental deve ser exaustivamente treinada pelos usuários até serem aprendidas. Frequentemente muitas seções de treinamento são necessárias para que a pessoa atinja um nível suficiente de controle da interface, geralmente esse tempo de treinamento prossegue por semanas ou até meses (WOLPAW; MCFARLAND, 2004). Além disso, a performance no controle das BCIs baseadas na imagética motora varia bastante de usuário para usuário. Mesmo assim, essa técnica tem apresentado resultados satisfatórios (KÜBLER *et al.*, 2005).

Existem os paradigmas para BCI baseado na atenção seletiva. Eles requerem que o usuário volte sua atenção para um estímulo externo. Esse estímulo pode ser visual (BAKARDJIAN *et al.*, 2010), auditivo (KLOBASSA *et al.*, 2009), ou somatossensorial (MULLER-PUTZ *et al.*, 2006). Em uma BCI típica, vários estímulos são colocados a disposição do usuário, sendo que, cada um está relacionado a um comando. Assim, para selecionar o comando desejado o usuário deve apenas focar sua atenção no estímulo correspondente. Uma vez que, o usuário coloque sua atenção em algum desses estímulos automaticamente surge um padrão na parte do cérebro desse indivíduo resposável por reconhecer essa informação. No caso de estímulos visuais esse padrão surge com mais proeminência no lobo occipital (ver Figura 1) (MIDDENDORF *et al.*, 2000). O tempo de treinamento é menor quando comparado as demais técnicas, uma vez que esses padrões aparecem automaticamente (BELL *et al.*, 2008). Entretanto, fixar a sua atenção nesses estímulos por um longo período pode ser cansativo e desconfortável para algumas pessoas.

Uma abordagem que utiliza a estratégia da atenção seletiva é a chamada P300, ela evoca um sinal cerebral que surge cerca de 300 ms após a ocorrência de um evento inesperado, por exemplo, quando o usuário fixa sua atenção em um símbolo que pisca aleatoriamente, em detrimento de outros que também piscam aleatoriamente na mesma tela. Este sinal consiste em uma forma de onda positiva que surge mais proeminente na parte central posterior do lobo parietal. As BCIs baseadas em potenciais evocados, como o P300, requerem pouco ou nenhum treinamento por parte do usuário, entretanto o sistema exige que o indivíduo preste atenção nos estímulos, o que pode ser cansativo (BELL *et al.*, 2008).

O SSVEP é outra abordagem para as BCIs. Ele se baseia na atenção seletiva de estímulos visuais que piscam constantemente e com diferentes frequências. Esses estímulos que cintilam em diferentes frequências são colocados de frente para usuário, eles podem partir de diodos emissores de luz ou de figuras que cintilam no monitor de um computador (LYSKOV *et al.*, 1998). Quando o usuário direciona sua atenção para um desses estímulos os neurônios localizados no córtex visual (lobo occipital), geram um padrão periódico com a mesma frequência da fonte do estímulo, essa resposta torna-se estacionária em poucos segundos (PASTOR *et al.*, 2003), ver Figura 2. O padrão SSVEP pode ser visto no espectro de frequência em torno da região de 12 Hz. Assim, é possível reconhecer qual estímulo possui a atenção do usuário e realizar o comando correspondente. Esse fenômeno pode ser caracterizado por frequências que variam de 1 Hz até 100 Hz (HERRMANN, 2001). Desta forma, é possível gerar uma interface com um extenso número de comandos, a exemplo de Gao *et al.* (2003), em que, 48 estímulos diferentes foram usados. Essa abordagem também

possui a vantagem de ser facilmente aprendida pelos usuários. Contudo, é preciso que as pessoas mantenham o olhar fixo no estímulo, assim, essa abordagem fica restrita às pessoas que não possuem dificuldade na movimentação ocular.





2.1.2 Monitorando a Atividade Cerebral

Atualmente, existem muitas técnicas utilizadas no monitoramento e registro das atividades cerebrais, geralmente essas técnicas medem as atividades elétricas ou magnéticas geradas pelo cérebro durante o processo de formação e deslocamento das sinapses. A magnetoencefalografia (MEG) é um exemplo de uma técnica que detecta o campo magnético associado com a atividade cerebral, ela possui uma boa resolução temporal, mas possui uma aparelhagem pesada e volumosa e um custo elevado que dificulta sua utilização nos sistemas BCIs (GEORGOPOULOS et al., 2005). A imagem por ressonância magnética funcional (fMRI) é uma técnica que mede o chamado BOLD (do inglês: Blood Oxygen Level Dependent), esse sinal está associado a pequenas mudanças na oxigenação do sangue. Ela possui uma boa resolução espacial, mas uma pobre resolução temporal, além de ser uma técnica complexa e possuir um custo elevado (YOO et al., 2004; WEISKOPF et al., 2004). A espectroscopia do infravermelho próximo (NIRS) também é uma técnica que mensura as pequenas mudanças no nível de oxigênio presente no sangue. Esta técnica proporciona uma baixa resolução espacial (COYLE et al., 2004). A eletroencefalografia (EEG) é a técnica mais utilizada para o desenvolvimento de BCIs, isso se deve ao fato dessa técnica possuir uma boa resolução temporal, equipamentos leves e pouco volumosos, de fácil manuseio e baixo custo. Apesar de possuir uma resolução espacial limitada (WOLPAW et al., 2006).

A eletroencefalografia é um método que vem sendo utilizado por décadas, não apenas para a construção das BCIs, mas também com finalidades clínicas. O EEG atua na captação das oscilações elétricas diretamente sobre a superfície craniana. Essas oscilações são classificadas de acordo com sua relação a um estímulo ou não. Oscilações espontâneas não estão relacionadas a algum estímulo externo e as oscilações evocadas estão diretamente ligadas a um estímulo externo (HERRMANN, 2001). Deste modo, a detecção desses padrões, tanto dos potenciais evocados quanto dos potenciais espontâneos, podem gerar um sinal de controle para um sistema BCI. No intuito de padronizar e de se obter gravações consistentes de regiões específicas da cabeça, os pesquisadores desenvolveram um sistema de posicionamento preciso dos eletrodos, conhecido como Sistema Internacional 10-20 mostrado na Figura 3.

Com a necessidade de se captar o sinal do EEG simultaneamente em diferentes áreas do escalpo, em 1958 Herbert Jasper sugeriu o método denominado Sistema Internacional (SI) de Posicionamento de Eletrodos 10-20, utilizado até hoje (DEMARRE *et al.*, 1983). Nesse sistema os eletrodos são posicionados utilizando-se como referência os marcos padrões do crânio (násio, ínion e os pontos pré auriculares), permitindo uma cobertura uniforme de toda a região do escalpo. A nomenclatura dos eletrodos é definida de acordo com a região anatômica em que se localizam, ou seja, O (occipital), P (parietal), T (temporal), C (central), F (frontal) e Fp (fronto-polar). Os números indicam o hemisfério, sendo que, os eletrodos colocados no hemisfério esquerdo recebem números ímpares, os colocados no hemisfério direito recebem números pares e os eletrodos colocados sobre a linha central recebem o índice "z" (TAVARES *et al.*, 2011).

Recentemente, com o intuito de melhorar a resolução espacial do Sistema Internacional 10-20, novas derivações foram criadas definindo o padrão 10-10, como mostrado na Figura 3. Essas derivações foram nomeadas como: PO (parieto-occipital), CP (centroparietal), TP (temporo-parietal), FC (fronto-central), FT (fronto-temporal) e AF (anterofrontal). Logo, o número de derivações para a colocação de eletrodos aumentou de 21 para 71.

Os potenciais espontâneos coletados pelo EEG geralmente possuem uma amplitude da ordem de dezenas de microvolts, em contrapartida, os potenciais evocados gerados por estimulação visual apresentam uma amplitude de cerca de 10 a 50 vezes menor que os potenciais espontâneos (SCHOMER; SILVA, 2012). Por esse motivo, o sinal coletado é susceptível a elementos indesejáveis gerados por fontes fisiológicas e não fisiológicas, como movimentos musculares, movimentos oculares, atividade cardíaca, respiração, interferência eletromagnética da rede e interferências do próprio equipamento (KLASS, 1995). Esses elementos são comumente chamados de artefatos e podem apresentar uma amplitude maior que as dos sinais de interesse, o que, normalmente, impossibilita sua análise sem o emprego de técnicas avançadas de processamento de sinais e aprendizado de máquina.



Figura 3 – Sistema internacional de posicionamento de eletrodos (a) 10-20 e (b) 10-10.

As técnicas apresentadas (EEG, NIRS, fMRI, MEG) são todas não invasivas, isto é, nenhuma delas necessita de procedimento cirúrgico para ser realizada. Existem técnicas invasivas, métodos que necessitam de procedimento cirúrgico, como a eletrocorticografia (ECoG). Nela os eletrodos são implantados na superfície do córtex cerebral. Essa técnica fornece um sinal com boa relação sinal ruído e boa resolução espacial (MILAN; CARMENA, 2010). Apesar das vantagens dos métodos invasivos sobre os não invasivos, o fato de ser necessário a realização de uma cirurgia dificulta o seu emprego em pesquisas.

2.1.3 BCI Baseada na Abordagem EEG-SSVEP

As BCIs são sistemas dotados da capacidade de interpretar, em tempo de execução, determinados padrões fisiológicos, oriundos do córtex cerebral, que refletem a intenção do usuário. Sua primeira etapa consiste na coleta de dados, em seguida ocorre a amplificação e a conversão do sinal cerebral de analógico para digital, para então, ser processado digitalmente. O processamento do sinal é divido em quatro estágios: pré-processamento, extração de características, seleção de características e classificação. A etapa de préprocessamento é responsável pelo janelamento do sinal e por melhorar a relação sinal-ruído, através da remoção dos artefatos. A etapa de extração de características consiste na análise das informações mais importantes do sinal coletado. Neste trabalho, foi utilizado a abordagem SSVEP, deste modo, a extração de características consiste em conseguir visualizar no sinal coletado qual é a fonte luminosa que possui a atenção do usuário. O classificador relaciona cada estímulo com o seu devido sinal de controle. O esquema completo de uma interface cérebro-máquina pode ser observado na Figura 4:



Figura 4 – Sistema genérico de uma BCI baseada no paradigma SSVEP.

Devido às limitações tecnológicas e computacionais, o aperfeiçoamento das interfaces cérebro-computador avançou lentamente até o fim do século XX. O desenvolvimento no desempenho dos sistemas computacionais facilitou o aprimoramento das pesquisas relacionadas a neurotecnologia. Schalk *et al.* (2004) apresentam um modelo que visa descrever qualquer sistema BCI com quatro módulos que se comunicam entre si: fonte (aquisição e armazenamento de dados), processamento do sinal, interface de controle e aplicação, conforme mostra a Figura 5. Os módulos devem se comunicar através de um único protocolo, assim, cada um pode ser projetado de maneira individual utilizando-se qualquer linguagem de programação, minimizando a dependência entre eles.

Figura 5 – Módulos de uma BCI padronizada.



Mak e Wolpaw (2009) evidenciam o esforço multidisciplinar envolvido no desenvolvimento de uma BCI, requerendo profissionais de diferentes áreas, como: neurocientistas, engenheiros, matemáticos aplicados, cientistas da computação, psicólogos, neurologistas e especialistas em reabilitação clínica. A incorporação de profissionais de diferentes áreas é fundamental para que essa tecnologia alcance o ápice do seu desenvolvimento. Segundo Millán *et al.* (2010), BCIs podem ser combinadas com TA, principalmente, as já existentes. Eles também identificam as principais áreas de aplicação em que as BCIs podem ter um real impacto para as pessoas com deficiência motora: comunicação e controle, substituição motora, entretenimento e recuperação motora.

Cecotti (2010) desenvolveu uma BCI baseada na detecção do SSVEP, na qual o sistema não necessita de nenhum treinamento por parte do usuário ou na etapa de processamento de sinais. O sistema se mantem pronto e alcança uma taxa de acerto de 92,25%, mesmo quando diferentes usuários utilizam a BCI. Müller-Putz *et al.* (2005) investigaram a utilização e a influência das primeiras harmônicas no processo de classificação de uma BCI baseada no SSVEP. O estudo revelou que quando usadas as três primeiras harmônicas em conjunto, o sistema obteve uma precisão significativamente maior do que quando usado apenas uma ou duas harmônicas.

Apesar dos avanços, os sistemas BCIs ainda precisam ser utilizados sob supervisão e assistência especializada. Uma possível solução para melhorar essa questão é utilizar um sistema BCI híbrido (hBCI), onde mais de uma abordagem experimental é utilizada, reforçando o controle por parte do usuário. Outra questão importante é a auto iniciação, ou seja, cada vez que um usuário quiser se comunicar ele deve ser capaz de ligar e desligar o sistema autonomamente. Scherer *et al.* (2007) combinaram a abordagem SSVEP com uma chave *liga/desliga* controlada pela variação do batimento cardíaco, induzida por uma inspiração rápida. Assim, o usuário adquire a habilidade de usar o sistema somente quando lhe convêm. Um segundo exemplo é mostrado por Allison *et al.* (2010), em que a abordagem SSVEP foi combinada com a imagética motora aumentando o rendimento, melhorando a precisão, reduzindo o tempo de seleção e aumentando o número de comandos possíveis.

Os principais desafios para as futuras interfaces cérebro computador, conforme Graimann *et al.* (2010), é fazer com que elas atinjam uma elevada taxa de acerto nos comandos desejados acompanhada de uma minimização no tempo de resposta. Outro desafio é fazer que o usuário consiga completar uma tarefa sem que haja um esforço mental excessivo. Por isso, pesquisas recentes têm focado no reconhecimento do estado mental do usuário (nível de estresse, cansaço, nível de atenção) e nos processos cognitivos (consciência dos erros cometidos pelo BCI), em situações nas quais o estado de alerta operacional e elevada concentração são cruciais. Assim, quando detectado uma fadiga mental avançada, momento em que a capacidade na realização das tarefas diminui, o sistema informaria ao usuário e desligaria automaticamente, fornecendo uma maior segurança. Kohlmorgen *et al.* (2007) mostraram que a detecção da fadiga mental em tempo real e em ambientes operacionais reais é possível e pode levar a um melhor desempenho no controle da interface. Por fim, Hamadicharef *et al.* (2009) desenvolveram um sistema robusto de medição do nível de atenção, executado em tempo quase real e requerendo apenas 15 eletrodos.

3 Materiais e Métodos

Os sinais cerebrais utilizados neste trabalho pertencem ao grupo de pesquisa do laboratório DSPCom da Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas (CARVALHO *et al.*, 2015). Empregou-se o sinal de um voluntário estimulado visualmente através de um monitor utilizando-se dois padrões xadrez que cintilavam nas frequências de 12 e 15 Hz, como mostrado na Figura (6). Essas frequências foram escolhidas por serem múltiplos da frequência de atualização do monitor (60 Hz). Deste modo, foi solicitado que ele se concentrasse em um dos padrões visuais que havia na tela.

Figura 6 – Tela com tabuleiros usados para gerar estímulos visuais em 12 e 15 Hz.



O voluntário foi exposto a cada estímulo durante 12 s, repetindo esse procedimento oito vezes, com um apropriado intervalo de descanso entre cada coleta. A taxa de amostragem utilizada foi de 256 Hz. Os dados foram coletados por um EEG e filtrados por um filtro analógico passa-banda do tipo Butterworth na faixa de 5 a 60 Hz e um filtro *notch* na faixa de 58 a 62 Hz. Como mostrado na Figura (7), utilizou-se um total de dezesseis derivações posicionados em O1, O2, Oz, POz, Pz, PO4, PO3, PO8, PO7, P2, P1, Cz, C1, C2, CPz, e FCz, segundo o sistema internacional de posicionamento de eletrodos 10-10 (ver seção 2.1.2) (CARVALHO *et al.*, 2015). Utilizou-se o software MATLAB[®] R2013a no desenvolvimento da etapa de processamento de sinais.

Os dados foram segmentados em janelas temporais de 3 s com sobreposição de 2 s, de modo a simular um comportamento em tempo real. Os dados janelados foram submetidos a cada um dos seis cenários de pré-processamento (CAR, MEC, MCC, CAR+MEC, CAR+MCC, sem filtragem) e em seguida extraiu-se os atributos do sinal utilizando o método de estimação de potência espectral de Welch. Primeiramente, todos os atributos foram enviados ao classificador linear para a discriminação entre as classes. Em um segundo momento, aplicou-se a técnica de *forward wrappers* para selecionar os melhores atributos a serem enviados ao classificador. A taxa de acerto do classificador linear, ajustado por meio do método dos Mínimos Quadrados, foi definida como o critério de desempenho do sistema.

Figura 7 – Disposição dos eletrodos utilizados na aquisição do sinal cerebral.



3.1 Pré-Processamento

No momento da coleta, o sinal EEG fica susceptível a muitos artefatos. Os mais relevantes são aqueles resultantes do próprio equipamento, de fontes eletromagnéticas externas e da atividade elétrica do próprio corpo: batimento cardíaco, piscar de olhos e movimento dos membros. Esses artefatos comprometem a qualidade do sinal coletado e, consequentemente, a taxa de acerto do classificador. A detecção dos padrões SSVEP proveniente do EEG pode ser aperfeiçoada através de combinações lineares dos sinais coletados pelos eletrodos de maneira a cancelar grande parte dos artefatos (ZHANG *et al.*, 2014).

3.1.1 Segmentação dos Dados

A princípio, os dados coletados nos 16 eletrodos sofreram uma segmentação, como mostrado na Figura (8). Considerando X(j), j = 0, ..., N - 1 a sequência total de dados composta por N amostras coletadas durante o estímulo visual, essa sequência inicial de dados foi separada em K segmentos de mesmo comprimento, com sobreposição de 2 s, cada um desses segmentos tem comprimento L. Os pontos iniciais de cada um destes segmentos estão afastados um dos outros por D pontos. Sendo $X_1(j), j = 0, \ldots, L-1$ o primeiro desses segmentos, Tem-se:

$$X_1(j) = X(j)$$
 $j = 0, \dots, L-1;$ (3.1)

$$X_{2}(j) = X(j+D) \qquad j = 0, \dots, L-1; \qquad (3.2)$$
$$X_{K}(j) = X(j+(K-1)D) \qquad j = 0, \dots, L-1. \qquad (3.3)$$

$$X_K(j) = X(j + (K-1)D)$$
 $j = 0, \dots, L-1.$ (3.3)

O sinal de 12 s foi segmentado em janelas de 3 s e a taxa de amostragem utilizada na coleta foi de 256 Hz. Portanto, cada dado coletado possui um total de 3072 amostras e cada segmento criado um número de 768 amostras, resultando na fragmentação da sequência inicial em 10 novos segmentos. Utilizou-se uma sobreposição de 512 amostras (2 s). Pela Figura (8) é possível ver que para não acontecer perda de informação, os K segmentos devem cobrir toda a amostra dos dados. Após segmentados os dados foram filtrados, conforme descrito a seguir:



Figura 8 – Representação da segmentação dos dados.

Fonte: Adaptado de (WELCH, 1967).

3.1.2 Common Average Reference

A filtragem CAR consiste na subtração ponto a ponto do sinal coletado em um dos eletrodos pela média pontual dos sinais coletados pelos 16 eletrodos. Deste modo, na filtragem CAR considera-se que a média de todos os eletrodos é uma estimativa da atividade elétrica no eletrodo de referência, e essa atividade elétrica afeta igualmente as gravações de todos os outros eletrodos. Quando um ruído afeta a atividade elétrica coletada em todos os eletrodos, sendo esses eletrodos uniformemente espaçados por todo o córtex cerebral, esse ruído provavelmente é oriundo de alguma mudança na atividade elétrica do eletrodo de referência (DIEN, 1998). Calculando-se a média dos sinais coletados em todos os 16 eletrodos, um novo sinal é encontrado e esse novo sinal é transformado na referência. O sinal coletado por cada eletrodo é então subtraído pelo novo sinal de referência, retirando aquilo que é comum a todos eles. Matematicamente, a expressão que sintetiza a CAR é:

$$V_i^{\text{CAR}} = Y_i^{\text{eletrodo}} - \frac{1}{n} \sum_{j=1}^n Y_j^{\text{eletrodo}}$$
(3.4)

em que, Y_i^{eletrodo} é o potencial medido no *i*-ésimo eletrodo, *n* é o número total de eletrodos $(n = 16) \text{ e } V_i^{\text{CAR}}$ é o potencial no *i*-ésimo eletrodo após a filtragem. Essa é uma técnica que visa atenuar os ruídos que acometem os eletrodos de maneira simultânea, ela é uma abordagem simples, eficiente e de baixo custo computacional, portanto indicada para aplicações em tempo real (LUDWIG *et al.*, 2009). Quando o número de eletrodos utilizados na coleta dos dados é igual ou maior que 16, sendo esses eletrodos uniformemente espaçados na cabeça, a abordagem CAR leva a uma filtragem do sinal EEG quase ideal (GARCIA-MOLINA; ZHU, 2011).

3.1.3 Minimum Energy Combination

Outra abordagem de filtragem espacial utilizada nesse trabalho foi proposta por Friman *et al.* (2007). Considerando que o indivíduo enfoque sua atenção em uma fonte luminosa que pisca a uma frequência f. O seguinte modelo, caracterizado por uma senoide acrescida de ruídos, pode ser criado para o sinal $y_i(t)$ medido como a tensão entre o eletrodo de referência e o *i*-ésimo eletrodo no tempo t,

$$y_i(t) = \sum_{k=1}^{Nh} \left(a_{i,k} \sin(2\pi k f t) + b_{i,k} \cos(2\pi k f t) \right) + \sum_j c_{i,j} z_j(t).$$
(3.5)

O modelo é linear e decompõe o sinal $y_i(t)$ em duas partes. A primeira parte consiste no padrão evocado SSVEP, no qual, é composto por funções senos e cossenos com frequências dada pela frequência do estímulo e pela frequência da harmônica utilizada. Cada senoide possui uma amplitude específica no *i*-ésimo eletrodo, $a_{i,k}$, e cada cossenoide também possui uma amplitude específica no mesmo eletrodo, $b_{i,k}$. N_h é o número total de harmônicas. A segunda parte do modelo, $z_i(t)$, representa toda a informação que não é atribuída ao padrão SSVEP, por exemplo, os artefatos gerados pelo movimento dos olhos. Cada sinal ruidoso é acrescentado ao *i*-ésimo eletrodo multiplicado pela amplitude $c_{i,j}$. Neste trabalho considerou-se dois casos, um com 2 harmônicas $(N_h = 2)$ e um modelo empregando somente a frequência fundamental $(N_h = 1)$. Quando $N_h = 1$ a Equação (3.5) pode ser escrita como:

$$y_i(t) = \left(a_i \sin(2\pi f t) + b_i \cos(2\pi f t)\right) + \sum_j c_{i,j} z_j(t).$$
(3.6)

Para um segmento de tempo N_t , adquirido com uma frequência de amostragem f_s , o modelo pode ser expresso pela soma de vetores

$$\mathbf{y}_i = \mathbf{X}\mathbf{g}_i + \mathbf{Z}\mathbf{c}_i \tag{3.7}$$

onde, $\mathbf{y}_i = [y_i(1), \dots, y_i(N_t)]^T$ é um vetor $N_t \times 1$, que contêm o sinal EEG do *i*-ésimo eletrodo no segmento de tempo N_t . A matriz $\mathbf{X} = [\mathbf{X}_1 \ \mathbf{X}_2 \cdots \mathbf{X}_{N_h}]$ contêm as submatrizes \mathbf{X}_k , possui tamanho $N_t \times 2N_h$ e modela o padrão SSVEP. Cada submatriz engloba as funções senos e cossenos associadas com a harmônica N_h . Utilizando-se apenas a primeira harmônica, a matriz \mathbf{X} passa a conter apenas a primeira submatriz \mathbf{X}_1 e, consequentemente apenas uma função seno e uma função cosseno. O vetor \mathbf{g}_i de tamanho $2N_h \times 1$, engloba as amplitudes correspondentes $a_{i,k}$ e $b_{i,k}$. Generalizando a Equação 3.7 para todos os eletrodos $i = 1, \dots, N_y$, temos:

$$\mathbf{Y} = \mathbf{X}\mathbf{G} + \mathbf{Z}\mathbf{C} \tag{3.8}$$

em que, $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_{N_y}]$ engloba o sinal EEG amostrado de todos os eletrodos e possui tamanho $N_t \times N_y$. A matriz \mathbf{G} , de tamanho $2N_h \times N_y$, e a matriz \mathbf{C} englobam as amplitudes de todas as senoides e as amplitudes de todos os artefatos, para todos os eletrodos.

O objetivo da técnica MEC é criar uma combinação com os dados coletados em cada eletrodo de maneira a minimizar a energia do ruído, melhorando a relação sinal ruído do sinal EEG (GOLLEE *et al.*, 2010). A combinação formada por diferentes eletrodos é denominada de *canal* e denotada pela letra **s**. Assim, um vetor **s** de tamanho $N_t \times 1$ é obtido pela combinação do sinal dos eletrodos \mathbf{y}_i , com $i = 1, \ldots, N_y$

$$\mathbf{s} = \sum_{i=1}^{Ny} w_i \mathbf{y}_i = \mathbf{Y} \mathbf{w}$$
(3.9)

onde, $\mathbf{w} = [w_1, \ldots, w_{N_y}]$ é um vetor de pesos associado com o sinal dos eletrodos. Diversos canais podem ser criados fazendo-se diferentes combinações com os mesmos sinais dos

eletrodos. Assim, a Equação 3.9 pode ser generalizada para N_s canais:

$$\mathbf{S} = \mathbf{Y}\mathbf{W} \tag{3.10}$$

onde, **W** é uma matriz de tamanho $N_y \times N_s$ que contém todos os vetores de pesos **w** responsáveis pelas combinações lineares. **S** é uma matriz de tamanho $N_t \times N_s$ que contém os sinais EEG após a filtragem.

Após a definição do modelo para o sinal EEG é realizado uma projeção da matriz **Y** sobre o espaço ortogonal da matriz **X** com o propósito de remover qualquer potencial SSVEP dos sinais coletados. Primeiramente, uma projeção da matriz **Y** sobre o espaço da matriz **X** é realizado, $\operatorname{Proj}_{\mathbf{X}} \mathbf{Y} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$, essa projeção contém todos o padrões do sinal EEG que possuem relação com o modelo do sinal SSVEP criado anteriormente (ver Equação 3.6). Em seguida, subtrai-se do sinal EEG o resultado encontrado na projeção, originando na matriz $\tilde{\mathbf{Y}}$ que contém todos os padrões que não possuem relação com o sinal SSVEP.

$$\tilde{\mathbf{Y}} = \mathbf{Y} - \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}.$$
(3.11)

Após essa operação, a matriz $\tilde{\mathbf{Y}}$ conterá apenas os artefatos. Em seguida, surge um problema de otimização (Equação 3.12), no qual deseja-se encontrar o vetor de pesos $\hat{\mathbf{w}}$ com restrição de norma unitária de maneira a minimizar a energia resultante da matriz de artefatos $\tilde{\mathbf{Y}}$ (VOLOSYAK, 2011). Uma vez encontrado esse vetor de pesos $\hat{\mathbf{w}}$ que minimiza a energia dos artefatos, ele é utilizado na transformação linear descrita pela Equação 3.10. Essa transformação linear visa cancelar a maior quantidade de ruído possível presente nos dados iniciais

$$\min_{\hat{\mathbf{w}}} \|\tilde{\mathbf{Y}}\hat{\mathbf{w}}\|^2 = \min_{\hat{\mathbf{w}}} \hat{\mathbf{w}}^T \tilde{\mathbf{Y}}^T \tilde{\mathbf{Y}}\hat{\mathbf{w}}.$$
(3.12)

A matriz quadrada gerada por $\tilde{\mathbf{Y}}^T \tilde{\mathbf{Y}}$ é limitada pelo menor autovalor (λ_1) e pelo maior autovalor (λ_{N_y}) . A solução para o vetor de pesos, que depois da transformação linear resulta no canal de menor energia, é dada pelo menor autovetor \mathbf{v}_1 . A solução para o vetor de pesos, que depois da transformação linear resulta no segundo canal de menor energia, é dada pelo autovetor \mathbf{v}_2 , não correlacionado com o autovetor \mathbf{v}_1 . Sucessivamente, outros canais não correlacionados podem ser criados baseados nos autovetores ($\mathbf{v}_3, \ldots, \mathbf{v}_{N_y}$) e nos seus autovalores correspondentes ($\lambda_3, \ldots, \lambda_{N_y}$) (FRIMAN *et al.*, 2007). Por fim, a matriz de pesos \mathbf{W} é composta por:

$$\mathbf{W} = \begin{bmatrix} \mathbf{v}_1 & \cdots & \mathbf{v}_{N_s} \\ \frac{1}{\sqrt{\lambda_1}} & \cdots & \frac{1}{\sqrt{\lambda_{N_s}}} \end{bmatrix}.$$
 (3.13)

A normalização de cada autovetor pela raiz quadrada do seu autovalor correspondente é feita para que o sinal de todos os canais criados possuam a mesma quantidade de energia. Para determinar N_s , Friman *et al.* (2007), adotam a seguinte abordagem:

$$\frac{\sum_{i=1}^{N_s} \lambda_i}{\sum_{j=1}^{N_y} \lambda_j} > 0.1 \tag{3.14}$$

onde, o denominador é a energia somando-se todos os autovalores e o numerador é a energia quando N_s canais são empregados. Desta forma, quando a soma da energia dos autovalores de N_s canais supera 10% a energia da soma de todos os autovalores, o número de canais é selecionado descartando aproximadamente 90% da energia do ruído.

Para cada matriz de entrada, \mathbf{Y} , uma matriz de ruídos, \mathbf{Y} , diferente é encontrada e para cada matriz de ruídos, $\tilde{\mathbf{Y}}$, a Equação 3.14 define um número diferente de canais que satisfazem a resolução do problema. Esse aspecto eleva a complexidade na implementação do classificador, aumentando o seu custo computacional. Por isso, neste trabalho identificouse entre todas as matrizes de ruído, $\tilde{\mathbf{Y}}$, o número mínimo de canais que satisfazem a especificação feita pela Equação 3.14, com o intuito de padronizar o classificador. O número equivalente a $N_s = 8$ canais foi, então, fixado de maneira a padronizar o tamanho do classificador. Através da Equação 3.10 construiu-se a matriz de canais \mathbf{S} , formados a partir da combinação linear dos sinais coletados \mathbf{Y} e da matriz de pesos \mathbf{W} .

3.1.4 Maximum Contrast Combination

A técnica de filtragem espacial MCC é semelhante a MEC. O sinal SSVEP é inicialmente modelado pela Equação 3.6. Para um segmento de tempo Nt, adquirido com uma frequência de amostragem f_s , o modelo pode ser expresso pela Equação 3.7. Generalizando para um número de eletrodos N_y , o modelo final é representado pela Equação 3.8. Em seguida, a projeção ortogonal mostrada na Equação 3.11 é realizada, de maneira a se obter a matriz de artefatos $\tilde{\mathbf{Y}}$.

Após a projeção, se espera que a matriz $\tilde{\mathbf{Y}}$ contenha apenas a parte ruidosa dos sinais. Posteriormente surge o problema de otimização (Equação 3.15), no qual deseja-se encontrar o vetor de pesos $\hat{\mathbf{w}}$ com restrição de norma unitária, de maneira a maximizar a energia em torno das frequências relacionadas com o padrão SSVEP e, simultaneamente, minimizar a energia resultante em torno das frequências dos sinais de artefatos. Após encontrar o vetor de pesos $\hat{\mathbf{w}}$, ele é utilizado na transformação linear descrita na Equação 3.9.

$$\max_{\hat{\mathbf{w}}} \frac{\|\mathbf{Y}\hat{\mathbf{w}}\|^2}{\|\tilde{\mathbf{Y}}\hat{\mathbf{w}}\|^2} = \max_{\hat{\mathbf{w}}} \frac{\hat{\mathbf{w}}^T \mathbf{Y}^T \mathbf{Y} \hat{\mathbf{w}}}{\hat{\mathbf{w}}^T \tilde{\mathbf{Y}}^T \tilde{\mathbf{Y}} \hat{\mathbf{w}}}$$
(3.15)

O objetivo da filtragem espacial MCC é minizar a energia do ruído e, ao mesmo tempo, maximar a energia do potencial evocado. O problema de otimização é resolvido a partir da decomposição das matrizes $\mathbf{Y}^T \mathbf{Y} \in \tilde{\mathbf{Y}}^T \tilde{\mathbf{Y}}$. Após a decomposição, os autovetores e os autovalores derivados da multiplicação entre as matrizes $\mathbf{Y}^T \mathbf{Y}$, foram divididos pelos autovetores e autovalores derivados da multiplicação entre as matrizes $\tilde{\mathbf{Y}}^T \tilde{\mathbf{Y}}$, resultando nos autovetores $\mathbf{v}_1, \ldots, \mathbf{v}_{N_y}$ e nos autovalores correspondentes $\lambda_1, \ldots, \lambda_{N_y}$. Os autovetores relacionados aos maiores autovalores produzem os canais com as maiores relação sinal ruído (GRAIMANN *et al.*, 2010). A matriz de pesos \mathbf{W} é calculada de modo equivalente ao mostrado pela Equação 3.13. Friman *et al.* (2007) adota a seguinte abordagem para escolher o número de canais a serem utilizados:

$$\frac{N_t}{(N_t - 2N_h)} \tag{3.16}$$

Isso significa que apenas autovetores com autovalores maiores do que o valor encontrado na Equação 3.16 foram inclusos na matriz de pesos \mathbf{W} , produzindo canais onde a energia por dimensão no subespaço SSVEP é maior que a energia por dimensão no resto do sinal. Esse critério de seleção define um número de canais diferente para cada matriz de ruído $\tilde{\mathbf{Y}}$, impossibilitando a generalização na construção de um classificador. Por isso, neste trabalho identificou-se entre todas as matrizes de ruído $\tilde{\mathbf{Y}}$, o número mínimo de canais que satisfazem a especificação feita pela Equação 3.16. O número equivalente a $N_s = 12$ canais foi, então, fixado de maneira a padronizar o tamanho do classificador. Através da Equação 3.10 construiu-se a matriz de canais \mathbf{S} , formados a partir da combinação linear dos sinais coletados, \mathbf{Y} , e da matriz de pesos, \mathbf{W} .

3.2 Extração de Características

A etapa de extração de características é responsável por extrair do sinal as características que permitem discriminar uma classe de outra analisando determinados padrões que permitem diferenciar se o indivíduo está concentrado no estímulo de 12 ou 15 Hz. Para gerar as características que definem cada uma das classes, empregou-se o cálculo de estimativa da Densidade Espectral de Potência pelo método de Welch (WELCH, 1967).

O método de Welch possui como essência o emprego da FFT (*Fast Fourier Trans*form) para estimar a PSD. Os dados de cada leitura são separados em N segmentos com um determinado comprimento, calcula-se os periodogramas modificados destas seções via FFT e a estimativa da densidade espectral de potência é a média dos periodogramas de cada seção (WELCH, 1967). Com o intuito de realizar a extração de características utilizou-se a função pxx = pwelch(x,window,noverlap,f,fs) do MATLAB, passando como parâmetros: 1. O sinal filtrado (x); 2. O número total de amostras do sinal filtrado (window = 768); 3. A não utilização de sobreposição (noverlap = 0); 4. Range de 0.1 Hz (11.95 à 12.05) Hz e 14.95 à 15.05 Hz) entre as frequências de interesse, com uma resolução de f = 0.01Hz; 5. A frequência de amostragem ($f_s = 256Hz$). Como mencionado na Seção 3.1.1, os dados foram inicialmente segmentados em 3 s com sobreposição de 2 s e, por isso, a extração de características foi realizada sem sobreposição. Colocando na função *pwelch* essa combinação de parâmetros, a janela de Hamming é utilizada por definição e a estima da PSD nas frequências normalizadas, especificadas no vetor f (frequências de interesse), é feita usando o algoritmo de Goertzel (GOERTZEL, 1958). Por fim, é realizado a soma do vetor **pxx**, que contêm os valores da PSD, em torno das frequências de interesse.

3.3 Seleção de Atributos

Em geral, espera-se que todos os atributos (canais) possuam alguma relevância para o classificador, porém alguns atributos podem fornecer informação redundante ou sem relevância para a discriminação das classes. Deste modo, a seleção de atributos permite reduzir o número de atributos, o custo computacional do classificador e aumentar a precisão da classificação, garantindo uma maior capacidade de generalização (GUYON; ELISSEEFF, 2003). A técnica *forward wrappers* (KOHAVI; JOHN, 1997) seleciona os atributos que fornecem mais informações, definindo os canais não redundantes.

A Figura (9) ilustra um caso de aplicação dessa técnica e o seu critério de escolha dos atributos. A técnica de forward wrappers se inicia testando individualmente todos os atributos ({1},...,{ N_s }), o desempenho do classificador é avaliado e o atributo que fornecer a maior taxa de acerto é selecionado, no caso exemplificado é o atributo {2}. Na sequência, diferentes subconjuntos são formados com o atributo selecionado e cada um dos atributos restantes ({2,1}, {2,3},...,{2, N_s }). Novamente, o desempenho do classificador é avaliado e se houver ganho na taxa de acerto o subconjunto mais relevante é selecionado, no caso o par de atributos {2,3} apresenta o melhor desempenho. A iteração continua progressivamente até o fim das possíveis combinações dos conjuntos, ou até não se verificar mais melhoria no desempenho do classificador com a inclusão de nenhum outro elemento ao conjunto. Um critério robusto de parada considera mais de um passo consecutivo sem ganho de desempenho do classificador. Neste trabalho, em uma primeira análise, adotadou-se dois passos consecutivos sem ganho de desempenho e comparou-se com o desempenho obtido quando não houve seleção de atributos.

3.4 Classificador Linear

Os classificadores lineares são frequentemente utilizados na implementação de interfaces cérebro-computador, devido ao seu baixo custo computacional e a sua simplicidade matemática (THEODORIDIS, 2010). A estrutura do classificador é responsável por decidir o comando dado pelo usuário a partir do conjunto de atributos criados pela extração



Figura 9 – Seleção dos atributos por forward wrappers.

de características e separados pela seleção de atributos. Existem muitas técnicas para a implementação de um classificador linear, neste trabalho utilizou-se o Método de Mínimos Quadrados (KOHN, 1998), nele deseja-se encontrar a combinação linear para o vetor de pesos, **w**, que melhor separe as classes. A expressão do classificador que define a soma dos erros quadrados é:

$$J(\mathbf{w}) = \sum_{i=1}^{N} (y_i - \mathbf{x}_i^T \mathbf{w})^2 \equiv \sum_{i=1}^{N} e_i^2$$
(3.17)

x é o vetor de classes, $\mathbf{y}_i = [y_i(1), \dots, y_i(N)]^T$ é o vetor de rótulos (± 1) e **w** o vetor de parâmetros do classificador. Os erros entre o valor desejado e o valor verdadeiro são somados para todos os vetores de características disponíveis para o treinamento.

Minimizando a Equação 3.17 com relação ao vetor \mathbf{w} , obtém-se:

$$\sum_{i=1}^{N} \mathbf{x}_{i}(y_{i} - \mathbf{x}_{i}^{T} \mathbf{w}) = 0 \Rightarrow \left(\sum_{i=1}^{N} \mathbf{x}_{i} \mathbf{x}_{i}^{T}\right) \mathbf{w} = \sum_{i=1}^{N} (\mathbf{x}_{i} y_{i})$$
(3.18)

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_{1}^{T} \\ \mathbf{x}_{2}^{T} \\ \vdots \\ \mathbf{x}_{N}^{T} \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1l} \\ x_{21} & x_{22} & \cdots & x_{2l} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{Nl} \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_{1} \\ y_{2} \\ \vdots \\ y_{N} \end{bmatrix}$$
(3.19)

X é uma matriz $N \times l$, cujas linhas são os vetores de treinamento do classificador e **y** é o vetor de rótulos. N é o número de pontos a ser utilizado para o treinamento do classificador e l é o número de atributos levados em consideração para cada um destes pontos. Sendo $\sum_{i=1}^{N} \mathbf{x}_i \mathbf{x}_i^T = \mathbf{X}^T \mathbf{X}$ e $\sum_{i=1}^{N} \mathbf{x}_i y_i = \mathbf{X}^T \mathbf{y}$, a Equação 3.18 pode ser escrita como:

$$(\mathbf{X}^T \mathbf{X}) = \mathbf{X}^T \mathbf{y} \Rightarrow \mathbf{w} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$
 (3.20)

esses dados permitem definir o hiperplano \mathbf{w} que estabelece a melhor superfície de divisão entre as classes (THEODORIDIS, 2010).

Conforme descrito no início do Capítulo 3, os volutários foram expostos a cada estímulo durante 12 s, repetindo esse procedimento oito vezes. As sessões 1,2,4,5,6,8 foram utilizadas no treinamento do classificador. As matrizes de classes $\mathbf{X}_{12,12Hz}$, $\mathbf{X}_{15,12Hz}$,

 $\mathbf{X}_{12,15Hz}$ e $\mathbf{X}_{15,15Hz}$ for am construídas da seguinte forma:

$$\mathbf{X}_{12,12Hz} = \begin{bmatrix} \theta_{(1,1)\times(1)} & \theta_{(1,1)\times(2)} & \cdots & \theta_{(1,1)\times(N_s)} \\ \theta_{(1,2)\times(1)} & \theta_{(1,2)\times(2)} & \cdots & \theta_{(1,2)\times(N_s)} \\ \vdots & \vdots & \ddots & \vdots \\ \theta_{(1,N_j)\times(1)} & \theta_{(1,N_j)\times(2)} & \cdots & \theta_{(1,N_j)\times(N_s)} \\ \theta_{(2,1)\times(1)} & \theta_{(2,1)\times(2)} & \cdots & \theta_{(2,1)\times(N_s)} \\ \theta_{(2,2)\times(1)} & \theta_{(2,2)\times(2)} & \cdots & \theta_{(2,2)\times(N_s)} \\ \vdots & \vdots & \ddots & \vdots \\ \theta_{(N_t,N_j)\times(1)} & \theta_{(N_t,N_j)\times(2)} & \cdots & \theta_{(N_t,N_j)\times(N_s)} \end{bmatrix}$$
(3.21)

onde $\theta_{(t,j)\times(s)}$ é o valor estimado da PSD do sinal evocado no canal s, na sessão t e no segmento j. A matriz $\mathbf{X}_{12,12Hz}$ de tamanho $N_t N_j \times N_s$, foi construída a partir da extração de característica em torno da frequência de 12 Hz quando o sujeito foca a sua atenção no estímulo que pisca a 12 Hz. N_s é o número total de canais, N_t o número total de tentativas (sessões) utilizados no treinamento e N_j o número total de janelas (segmentos de 3 s).

$$\mathbf{X}_{f,f_e} = \begin{bmatrix} \theta_{(1,1)\times(1)} & \theta_{(1,1)\times(2)} & \cdots & \theta_{(1,1)\times(N_s)} \\ \theta_{(1,2)\times(1)} & \theta_{(1,2)\times(2)} & \cdots & \theta_{(1,2)\times(N_s)} \\ \vdots & \vdots & \ddots & \vdots \\ \theta_{(1,N_j)\times(1)} & \theta_{(1,N_j)\times(2)} & \cdots & \theta_{(1,N_j)\times(N_s)} \\ \theta_{(2,1)\times(1)} & \theta_{(2,1)\times(2)} & \cdots & \theta_{(2,1)\times(N_s)} \\ \theta_{(2,2)\times(1)} & \theta_{(2,2)\times(2)} & \cdots & \theta_{(2,2)\times(N_s)} \\ \vdots & \vdots & \ddots & \vdots \\ \theta_{(N_t,N_j)\times(1)} & \theta_{(N_t,N_j)\times(2)} & \cdots & \theta_{(N_t,N_j)\times(N_s)} \end{bmatrix}$$
(3.22)

Generalizando, \mathbf{X}_{f,f_e} é a matriz construída a partir da extração de característica em torno da frequência f dada em Hertz, quando o sujeito foca a sua atenção no estímulo que pisca a f_e Hz.

Concatenando todas as submatrizes relacionadas às frequências de 12 e 15 Hz em uma única matriz de treinamento \mathbf{X}_t e adicionando uma coluna de uns, com o objetivo de aumentar o grau de liberdade do classificador, tem-se:

A matriz \mathbf{X}_t possui tamanho $(2N_tN_j) \times (2N_s + 1)$. $\mathbf{y}_{12Hz} = [1_1, 1_2, \cdots, 1_{N_tN_j}]^T$ é o vetor de rótulos para a frequência de 12 Hz, de tamanho $N_tN_j \times 1$ e $\mathbf{y}_{15Hz} = [-1_1, -1_2, \cdots, -1_{N_tN_j}]^T$ é o vetor de rótulos para a frequência de 15 Hz, de tamanho $N_tN_j \times 1$. Concatenando os dois vetores em um único vetor de rótulos \mathbf{y} , tem-se:

$$\mathbf{y} = \begin{bmatrix} \mathbf{y}_{12Hz} | \mathbf{y}_{15Hz} \end{bmatrix}^T. \tag{3.24}$$

O cálculo do vetor de pesos \mathbf{w} é realizado conforme mostrado na Equação 3.20. Na validação outra matriz de classes \mathbf{X}_v é criada, mas utilizando-se as sessões 3 e 7. O vetor de resultados é encontrado através da multiplicação entre a matriz de classes \mathbf{X}_v e o vetor de pesos \mathbf{w} .

4 Resultados

Neste capítulo são apresentados e discutidos os resultados do classificador para cada uma das técnicas de filtragem espacial apresentadas no Capítulo 3. O objetivo era identificar dentre o par de frequências (12 e 15 Hz) aquela que detinha a atenção do usuário. Em todos os casos usou-se 120 segmentos (6 coletas \times 10 janelas \times 2 frequências) para treinar o classificador e 40 segmentos (2 coletas \times 10 janelas \times 2 frequências) para validá-lo. Foram realizados 28 iterações considerando todas as possíveis partições de conjuntos para treinamento e validação. A comparação entre as técnicas foi realizada a partir do desempenho do classificador, ou seja, a taxa de acerto do classificador para o par de frequências. Deste modo, o desempenho da BCI é definido como sendo a taxa de acerto do classificador. É válido ressaltar que apesar da análise ter sido feita off-line, considerou-se janelamentos de 3 s, permitindo uma simulação de desempenho em aplicações online. A Tabela (1) apresenta o desempenho médio da BCI considerando 28 iterações, quando apenas a frequência fundamental foi utilizada para modelar o sinal SSVEP nas filtragens MCC, MEC, CAR+MCC, CAR+MEC. É importante ressaltar que a taxa de acerto apresentado no caso da seleção de atributos para wrappers considerou derivações/canais distintos para cada partição analisada. A Figura (10) compara o desempenho do classificador quando não é utilizado a seleção de atributos e quando é utilizado a seleção de atributos.

Técnicas de	Desempenho da BCI (%)	
Pré-Processamento	Sem Seleção de	Forward
	Atributos	Wrappers
Sem Filtragem	74,02	85,36
CAR	91,43	$98,\!48$
MCC	61,88	74,82
MEC	88,39	$92,\!86$
CAR+MCC	87,32	$95,\!98$
CAR+MEC	89,37	$95,\!45$

Tabela 1 – Taxa de acerto do classificador na distinção entre 12 e 15 Hz quando utilizado apenas a fundamental.

Analisando conjuntamente a Tabela (1) e a Figura (10) é possível observar que os piores desempenho do classificador foram observados quando aplicou-se a técnica MCC (61,88 %) e quando não se efetuou nenhum processo de filtragem (74,02 %). No entanto, quando as técnicas de filtragem CAR, MEC, CAR+MCC e CAR+MEC foram empregadas o sistema apresentou taxas de acerto superiores a 85 %, sendo o melhor caso obtido com a filtragem CAR (91,43 %). A Figura (10) mostra de forma clara, que a aplicação da técnica de seleção de atributos resultou sempre num ganho de desempenho do sistema e que o melhor desempenho foi obtido utilizando a técnica de filtragem CAR juntamente



Figura 10 – Desempenho do classificador - 12 Hz e 15 Hz.

com a seleção de atributos por *wrappers*, resultando em uma taxa de acerto de 98,36%. Este resultado representa um ganho de desempenho superior a 24%, se comparado com o resultado obtido quando nenhuma técnica de filtragem foi utilizada.

A Tabela (2) apresenta o desempenho da BCI quando a frequência fundamental e a primeira harmônica são utilizadas para modelar o sinal SSVEP nas filtragens MCC, MEC, CAR+MCC, CAR+MEC. Através dela é possível observar que na abordagem MCC aconteceu um pequeno decremento na taxa de acerto do classificador. Já, nas demais abordagens o valor da taxa de acerto permaneceu praticamente o mesmo. É interessante enfatizar que quando o sinal é modelado utilizando-se a primeira harmônica juntamente com a fundamental, ocorre um aumento da complexidade do modelo e consequentemente um aumento do custo computacional. Entretanto, a taxa de acerto parece não refletir numa melhora que justifique esse procedimento, isso se deve provavelmente devido a baixa potência espectral da primeira harmônica. Na Figura (11) é possível observar que a aplicação da técnica de seleção de atributos resultou sempre numa melhora de desempenho do sistema.

Técnicas de	Desempenho da BCI (%)	
Pré-Processamento	Sem Seleção de	Forward
	Atributos	Wrappers
MCC	58,66	69,46
MEC	88,48	93,30
CAR+MCC	88,84	95,27
CAR+MEC	89,20	$95,\!98$

Tabela 2 – Taxa de acerto do classificador na distinção entre 12 e 15 Hz quando utilizado a fundamental e a primeira harmônica.



Figura 11 – Desempenho do classificador - 12 Hz e 15 Hz.

Aprofundando a análise sobre os resultados obtidos quando a filtragem CAR é realizada e demonstrando a importância do pré-processamento para a construção de uma BCI, a Figura (12) compara, no tempo, o efeito da aplicação do método CAR em um sinal coletado no eletrodo O1 a partir de uma excitação visual em 12 Hz. Nela é possível observar que o sinal antes da filtragem não possui um padrão na sua amplitude, mas após a filtragem CAR o sinal passa a ter uma amplitude mais constante e um padrão mais próximo ao de uma senoide, verifica-se também que o sinal sofreu uma atenuação.



Figura 12 – Efeito da aplicação da filtragem CAR no tempo.

Comparando as Figuras (13) e (14) é possível observar, no espectro de frequência,





Analisando o gráfico do espectro do sinal coletado (Figura (13)) e o gráfico do espectro do sinal filtrado (Figura (14)) é possível observar um aumento do pico na frequência em 12 Hz e uma redução da magnitude dos picos nas frequências vizinhas. Isto ocorreu devido à melhoria da relação sinal-ruído, eliminando grande parte das informações consideradas irrelevantes para o propósito deste trabalho.

5 Conclusão

Neste trabalho foram desenvolvidas todas as etapas de processamento de sinais de uma BCI: pré-processamento, extração de características, seleção de características e classificação. A base de sinais cerebrais utilizada foi coletada baseada no paradigma SSVEP pelo grupo de pesquisa do laboratório DSPCom da Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas. O principal objetivo era comparar seis procedimentos diferentes, envolvendo três diferentes métodos de filtragem espacial e, também, analisar o emprego da técnica de *forward wrappers* na seleção de atributos. Esta análise subsidia a indicação de uma configuração adequada para o desenvolvimento de um sistema BCI-SSVEP. Evidenciando que, além da taxa de acerto, também deve-se levar em consideração o comprimento de janela, o qual deve ser adequado para aplicações BCI *online*. Os algoritmos que usam classificadores lineares são atraentes para aplicação em sistemas *online*, onde deve se levar em consideração a velocidade de processamento, uma vez que o controle do sistema deve ser feito em questão de poucos segundos.

Os resultados corroboram a importância da filtragem dos sinais cerebrais e seleção de características para um melhor desempenho dos sistemas BCIs. A seleção de atributos se mostrou extremamente importante, apresentando ganho em todos os cenários. Dentre todas as duas técnicas empregadas, a filtragem mais eficiente foi a CAR, atingindo uma taxa de acerto superior a 98% quando a seleção de características foi empregada. Zhu *et al.* (2010) afirma que quando o número de eletrodos utilizados na coleta é igual ou maior que dezesseis, a abordagem CAR leva a uma filtragem quase ideal. Neste trabalho considerou-se a frequência fundamental e a primeira harmônica na modelagem do potencial evocado para as técnicas MCC e MEC, embora seja possível incluir outras sub-harmônicas no modelo. Como trabalho futuro, será investigada esta modelagem mais completa.

Referências

ALLISON, B. Z. *et al.* Toward a hybrid brain–computer interface based on imagined movement and visual attention. *Journal of neural engineering*, IOP Publishing, v. 7, n. 2, p. 026007, 2010. Citado na página 11.

BAI, O. *et al.* Towards a user-friendly brain–computer interface: initial tests in als and pls patients. *Clinical Neurophysiology*, Elsevier, v. 121, n. 8, p. 1293–1303, 2010. Citado na página 4.

BAKARDJIAN, H.; TANAKA, T.; CICHOCKI, A. Optimization of SSVEP brain responses with application to eight-command brain–computer interface. *Neuroscience letters*, Elsevier, v. 469, n. 1, p. 34–38, 2010. Citado na página 6.

BELL, C. J. *et al.* Control of a humanoid robot by a noninvasive brain–computer interface in humans. *Journal of neural engineering*, IOP Publishing, v. 5, n. 2, p. 214, 2008. Citado na página 6.

BERSCH, R. Introdução a tecnologia assistiva. 2008. Acesso em, v. 22, 2010. Citado na página 1.

CARVALHO, S. N. *et al.* Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs. *Biomedical Signal Processing and Control*, Elsevier, v. 21, p. 34–42, 2015. Citado na página 12.

CECOTTI, H. A self-paced and calibration-less SSVEP-based brain-computer interface speller. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE Engineering in Medicine and Biology Society, v. 18, n. 2, p. 127–133, 2010. Citado na página 11.

CIÊNCIA TECNOLOGIA, I. o. e. C. o. Ascom do Ministério da. Aumenta o investimento em C & T no Brasil. 2016. Disponível em: ">http://www.mcti.gov.br/noticia/-/asset_ 90B4F834D2B697CB9BF807D822CD611A>">http://www.mcti.gov.br/noticia/-/asset_ 90B4F834D2B697CB9BF807D822CD611A>">http://www.mcti.gov.br/noticia/-/asset_

COYLE, S. *et al.* On the suitability of near-infrared (NIR) systems for next-generation brain–computer interfaces. *Physiological measurement*, IOP Publishing, v. 25, n. 4, p. 815, 2004. Citado na página 7.

DEMARRE, D. A.; MICHAELS, D.; VALDEZ, R. Bioelectronic measurements. *Journal of Clinical Engineering*, LWW, v. 8, n. 3, p. 234, 1983. Citado na página 8.

DEMOGRÁFICO, I. C. características gerais da população, religião e pessoas com deficiência. *Rio de Janeiro*, 2010. Citado na página 1.

DIEN, J. Issues in the application of the average reference: Review, critiques, and recommendations. *Behavior Research Methods, Instruments, & Computers*, Springer, v. 30, n. 1, p. 34–43, 1998. Citado na página 15.

FRIMAN, O.; VOLOSYAK, I.; GRÄSER, A. Multiple channel detection of steady-state visual evoked potentials for brain-computer interfaces. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 54, n. 4, p. 742–750, 2007. Citado 4 vezes nas páginas 15, 17, 18 e 19.

GAO, X. *et al.* A BCI-based environmental controller for the motion-disabled. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 11, n. 2, p. 137–140, 2003. Citado na página 6.

GARCIA-MOLINA, G.; ZHU, D. Optimal spatial filtering for the steady state visual evoked potential: BCI application. In: IEEE. Neural Engineering (NER), 2011 5th International IEEE/EMBS Conference on. [S.l.], 2011. p. 156–160. Citado na página 15.

GEORGOPOULOS, A. P. *et al.* Magnetoencephalographic signals predict movement trajectory in space. *Experimental brain research*, Springer, v. 167, n. 1, p. 132–135, 2005. Citado na página 7.

GOERTZEL, G. An algorithm for the evaluation of finite trigonometric series. *The American Mathematical Monthly*, JSTOR, v. 65, n. 1, p. 34–35, 1958. Citado na página 20.

GOLLEE, H. *et al.* An SSVEP-based brain-computer interface for the control of functional electrical stimulation. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 57, n. 8, p. 1847–1855, 2010. Citado na página 16.

GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. Brain-computer interfaces: A gentle introduction. In: *Brain-Computer Interfaces*. [S.l.]: Springer, 2010. p. 1–27. Citado 3 vezes nas páginas 5, 11 e 19.

GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. *Journal of machine learning research*, v. 3, n. Mar, p. 1157–1182, 2003. Citado na página 20.

HAMADICHAREF, B. *et al.* Learning EEG-based spectral-spatial patterns for attention level measurement. In: IEEE. *2009 IEEE International Symposium on Circuits and Systems.* [S.l.], 2009. p. 1465–1468. Citado na página 11.

HERRMANN, C. S. Human EEG responses to 1–100 Hz flicker: resonance phenomena in visual cortex and their potential correlation to cognitive phenomena. *Experimental brain research*, Springer, v. 137, n. 3-4, p. 346–353, 2001. Citado 2 vezes nas páginas 6 e 8.

KILGORE, K. L. *et al.* An implanted upper-extremity neuroprosthesis. follow-up of five patients. *J Bone Joint Surg Am*, The American Orthopedic Association, v. 79, n. 4, p. 533–41, 1997. Citado na página 1.

KLASS, D. W. The continuing challenge of artifacts in the EEG. American Journal of EEG Technology, Taylor & Francis, v. 35, n. 4, p. 239–269, 1995. Citado na página 8.

KLEM, G. H. *et al.* The ten-twenty electrode system of the international federation. *Electroencephalogr Clin Neurophysiol*, v. 52, n. 3, 1999. Citado na página 9.

KLOBASSA, D. S. *et al.* Toward a high-throughput auditory P300-based brain–computer interface. *Clinical neurophysiology*, Elsevier, v. 120, n. 7, p. 1252–1261, 2009. Citado na página 6.

KOHAVI, R.; JOHN, G. H. Wrappers for feature subset selection. *Artificial intelligence*, Elsevier, v. 97, n. 1, p. 273–324, 1997. Citado na página 20.

KOHLMORGEN, J. *et al.* Improving human performance in a real operating environment through real-time mental workload detection. *Toward Brain-Computer Interfacing*, MIT press Cambridge, MA, p. 409–422, 2007. Citado na página 11.

KOHN, A. F. *Reconhecimento de padrões: uma abordagem estatística*. [S.l.]: PEE/EPUSP, 1998. Citado na página 22.

KREPKI, R. *et al.* The berlin brain-computer interface (BBCI)-towards a new communication channel for online control in gaming applications. *Multimedia Tools and Applications*, Springer, v. 33, n. 1, p. 73–90, 2007. Citado na página 4.

KÜBLER, A. *et al.* Patients with als can use sensorimotor rhythms to operate a brain-computer interface. *Neurology*, AAN Enterprises, v. 64, n. 10, p. 1775–1777, 2005. Citado na página 6.

LACOURSE, J. R.; JR, F. C. H. An eye movement communication-control system for the disabled. *IEEE transactions on bio-medical engineering*, v. 37, n. 12, p. 1215, 1990. Citado na página 1.

LUDWIG, K. A. *et al.* Using a common average reference to improve cortical neuron recordings from microelectrode arrays. *Journal of neurophysiology*, Am Physiological Soc, v. 101, n. 3, p. 1679–1689, 2009. Citado na página 15.

LYSKOV, E. *et al.* Steady-state visual evoked potentials to computer monitor flicker. *International Journal of Psychophysiology*, Elsevier, v. 28, n. 3, p. 285–290, 1998. Citado na página 6.

MAK, J. N.; WOLPAW, J. R. Clinical applications of brain-computer interfaces: current state and future prospects. *IEEE reviews in biomedical engineering*, NIH Public Access, v. 2, p. 187, 2009. Citado na página 10.

MIDDENDORF, M. *et al.* Brain-computer interfaces based on the steady-state visual-evoked response. *IEEE transactions on rehabilitation engineering*, IEEE, v. 8, n. 2, p. 211–214, 2000. Citado na página 6.

MILAN, J. d. R.; CARMENA, J. M. Invasive or noninvasive: Understanding brain-machine interface technology [conversations in bme]. *IEEE Engineering in Medicine and Biology Magazine*, IEEE, v. 29, n. 1, p. 16–22, 2010. Citado na página 9.

MILLÁN, J. d. R. *et al.* Combining brain–computer interfaces and assistive technologies: state-of-the-art and challenges. Frontiers Research Foundation, 2010. Citado na página 11.

MONTI, M. M. *et al.* Willful modulation of brain activity in disorders of consciousness. *New England Journal of Medicine*, Mass Medical Soc, v. 362, n. 7, p. 579–589, 2010. Citado na página 4.

MULLER-PUTZ, G. *et al.* Steady-state somatosensory evoked potentials: suitable brain signals for brain-computer interfaces? *IEEE transactions on neural systems and rehabilitation engineering*, IEEE, v. 14, n. 1, p. 30–37, 2006. Citado na página 6.

MÜLLER-PUTZ, G. R. *et al.* Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components. *Journal of neural engineering*, v. 2, n. 4, p. 123–130, 2005. Citado na página 11.

PASTOR, M. A. *et al.* Human cerebral activation during steady-state visual-evoked responses. *The journal of neuroscience*, Soc Neuroscience, v. 23, n. 37, p. 11621–11627, 2003. Citado na página 6.

PFURTSCHELLER, G.; NEUPER, C. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, IEEE, v. 89, n. 7, p. 1123–1134, 2001. Citado na página 5.

RON-ANGEVIN, R.; DÍAZ-ESTRELLA, A.; VELASCO-ALVAREZ, F. A two-class brain computer interface to freely navigate through virtual worlds/ein zwei-klassenbrain-computer-interface zur freien navigation durch virtuelle welten. *Biomedizinische Technik/Biomedical Engineering*, v. 54, n. 3, p. 126–133, 2009. Citado na página 4.

SCHALK, G. *et al.* BCI2000: a general-purpose brain-computer interface (BCI) system. *IEEE Transactions on biomedical engineering*, IEEE, v. 51, n. 6, p. 1034–1043, 2004. Citado na página 10.

SCHERER, R.; MÜLLER-PUTZ, G.; PFURTSCHELLER, G. Self-initiation of eeg-based brain-computer communication using the heart rate response. *Journal of neural engineering*, IOP Publishing, v. 4, n. 4, p. L23, 2007. Citado na página 11.

SCHLÖGL, A. *et al.* Characterization of four-class motor imagery EEG data for the BCI-competition 2005. *Journal of neural engineering*, IOP Publishing, v. 2, n. 4, p. L14, 2005. Citado na página 5.

SCHOMER, D. L.; SILVA, F. L. D. Niedermeyer's electroencephalography: basic principles, clinical applications, and related fields. [S.l.]: Lippincott Williams & Wilkins, 2012. Citado na página 8.

TANGERMANN, M. *et al.* Playing pinball with non-invasive BCI. In: *NIPS*. [S.l.: s.n.], 2008. p. 1641–1648. Citado na página 4.

TAVARES, M. C.; ENG, M.; BIOMÉDICA, E. EEG e Potenciais Evocados–Uma Introdução. *Contronic Sistemas Automáticos*, p. 1–13, 2011. Citado na página 8.

THEODORIDIS, K. K. S. *Pattern Recognition*. California: [s.n.], 2010. 91-150 p. Citado 2 vezes nas páginas 20 e 22.

VERLEGER, R. Event-related potentials and cognition: A critique of the context updating hypothesis and an alternative interpretation of p3. *Behavioral and brain sciences*, Cambridge Univ Press, v. 11, n. 03, p. 343–356, 1988. Citado na página 4.

VOLOSYAK, I. SSVEP-based Bremen–BCI interface—boosting information transfer rates. *Journal of neural engineering*, IOP Publishing, v. 8, n. 3, p. 036020, 2011. Citado na página 17.

WANG, Y. *et al.* Brain-computer interfaces based on visual evoked potentials. *IEEE Engineering in medicine and biology magazine*, IEEE, v. 27, n. 5, p. 64–71, 2008. Citado na página 4.

WEISKOPF, N. *et al.* Principles of a brain-computer interface (BCI) based on real-time functional magnetic resonance imaging (fMRI). *IEEE transactions on biomedical engineering*, IEEE, v. 51, n. 6, p. 966–970, 2004. Citado na página 7.

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. Citado 2 vezes nas páginas 14 e 19.

WOLPAW, J.; BIRBAUMER, N. Brain communication interfaces for communication and control. *Textbook of Neural Repair and Rehabilitation; Neural Repair and Plasticity*, 2006. Citado na página 4.

WOLPAW, J. R. *et al.* BCI meeting 2005-workshop on signals and recording methods. *IEEE Transactions on neural systems and rehabilitation engineering*, IEEE, v. 14, n. 2, p. 138–141, 2006. Citado na página 7.

WOLPAW, J. R.; MCFARLAND, D. J. Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the National Academy* of Sciences of the United States of America, National Acad Sciences, v. 101, n. 51, p. 17849–17854, 2004. Citado na página 6.

YOO, S.-S. *et al.* Brain–computer interface using fMRI: spatial navigation by thoughts. *Neuroreport*, LWW, v. 15, n. 10, p. 1591–1595, 2004. Citado na página 7.

ZHANG, Y. *et al.* Multivariate synchronization index for frequency recognition of SSVEP-based brain-computer interface. *Journal of neuroscience methods*, Elsevier, v. 221, p. 32–40, 2014. Citado na página 13.

ZHU, D. *et al.* A survey of stimulation methods used in SSVEP-based BCIs. *Computational intelligence and neuroscience*, Hindawi Publishing Corp., v. 2010, p. 1, 2010. Citado na página 29.

Anexos

Thiago V. Tavares¹, Thiago B. S. Costa², Luisa F. S. Uribe², Harlei M. A. Leite^{1,2}, Glauco F. G. Yared¹, Diogo C. Soriano³, Romis Attux², Sarah N. Carvalho^{1,2}

¹Universidade Federal de Ouro Preto (UFOP), ²Universidade Estadual de Campinas (UNICAMP), ³Universidade Federal do ABC (UFABC)

thiagovt2@yahoo.com, sarah@deelt.ufop.br

Resumo – Este trabalho apresenta uma análise do impacto que a aplicação de técnicas de pré-processamento tem sobre o desempenho de sistemas BCI-SSVEP. São analisados cinco cenários de filtragem espacial, além do caso sem filtragem. Para enriquecer a comparação, cada cenário foi testado na configuração com e sem seleção de características. Os resultados quantificam a melhora de desempenho em sistemas BCI quando tais estratégias são empregadas, podendo levar a um ganho na taxa de acerto superior a 37%.

Palavras-chave: Pré-Processamento, Sinais Cerebrais, MCC, MEC, CAR, BCI, SSVEP, EEG.

1. Introdução

De acordo com o censo demográfico publicado pelo Instituto Brasileiro de Geografia Estatística em 2010, mais de 45 milhões de brasileiros declararam ter ao menos um tipo de deficiência (visual, auditiva, motora ou mental) [1], sendo que 20,3 milhões deles estão inseridos no mercado de trabalho. O desenvolvimento de assistivas visa melhorar tecnologias as habilidades funcionais e promover maior inclusão social e tecnológica desta parcela da população. Uma possível estratégia é definida pelas chamadas interfaces cérebro-computador (BCI, do inglês Brain-Computer Interfaces) baseadas nos potenciais evocados visualmente em regime permanente (SSVEP, do inglês Steady State Visually Evoked Potential). As BCIs consistem em canais alternativos de comunicação que traduzem os sinais cerebrais em comandos para dispositivos externos [2]. O SSVEP pode ser registrado por meio do eletroencefalograma de superfície (EEG) e associa-se com o sincronismo da atividade elétrica do córtex visual mediante a estimulação visual externa em uma dada frequência [3]. Os BCI-SSVEP apresentam uma interface com um número determinado de fontes luminosas oscilando em diferentes frequências, sendo cada uma delas associada a um determinado comando externo. Considerando os diversos artefatos presentes no EEG (e.g. movimentação muscular, ruídos de fontes externas e interferências eletromagnéticas) é natural que a tarefa de pré-processamento implique em uma importante etapa na concepção do sistema BCI-SSVEP. Neste sentido, este trabalho apresenta uma análise de desempenho de um sistema BCI-SSVEP utilizando seis combinações de filtragem espacial [4-6]: (1) CAR (*Common Average Reference*), (2) MEC (*Minimum Energy Combination*), (3) MCC (*Maximum Contrast Combination*), (4) CAR combinado com MEC, (5) CAR combinado com MCC e (6) sem filtragem. Analisou-se também a efetividade da seleção de atributos agregada ao sistema, comparando a técnica de *wrappers* com o caso em que não há seleção. Em todos os cenários, utilizaram-se janelas temporais de 3 s de modo a avaliar a viabilidade de utilizá-las em sistemas BCI *online*.

2. Metodologia

Os sinais EEG foram coletados pelo grupo de pesquisa DSPCom da Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas (FEEC/UNICAMP) [6]. A estimulação visual foi feita utilizando um padrão xadrez cintilante nas frequências de 12 e 15 Hz. O indivíduo foi exposto a cada estímulo durante 12 s em oito repetições. A taxa de amostragem foi de 256 Hz. Os eletrodos foram posicionados em O₁, O₂, O_Z, PO_Z, P_Z, PO₄, PO₃, PO₈, PO₇, P₂, P₁, C_z, C₁, C₂, CP_z, e FC_z segundo o sistema internacional 10-20. Neste trabalho, utilizaram-se os sinais cerebrais de um único voluntário. Os dados brutos foram segmentados em janelas temporais de 3 s com sobreposição de 2 s, de modo a simular um comportamento em tempo real. Os dados janelados foram submetidos a cada um dos seis cenários de pré-processamento e em seguida extraiu-se os atributos do sinal utilizando o método de estimação de potência espectral de Welch [7]. Primeiramente, todos os atributos foram enviados ao classificador linear para a discriminação entre as classes. Em uma segunda abordagem, aplicou-se a técnica de *wrappers* [11] para selectionar os melhores atributos a serem enviados ao classificador. A

taxa de acerto do classificador linear, ajustado por meio do método dos mínimos quadrados, foi definida como o critério de desempenho do sistema.

2.1. CAR

Esta técnica consiste na subtração ponto a ponto de cada sinal pela média de todos os sinais coletados pelos dezesseis eletrodos. A expressão que sintetiza a CAR é:

$$Y_i^{CAR} = Y_i^{ER} - \frac{1}{n} \sum_{j=1}^n Y_j^{ER}$$
(1)

em que Y_i^{ER} é o sinal coletado no *i*-ésimo eletrodo e *n* é o número total de eletrodos. Ela visa retirar os ruídos coincidentes que aparecem em todos os eletrodos [4,8].

A Figura 1 apresenta o módulo da FFT (*Fast Fourier Transform*) de 3 s do sinal capturado pelo eletrodo posicionado em O_1 quando o indivíduo estava exposto ao estímulo de 12 Hz. A Figura 2 apresenta a FFT do mesmo sinal após a filtragem CAR.



Figura 1. Espectro sinal EEG sem filtragem.



Figura 2. Espectro do sinal EEG com CAR.

2.2. MEC

A ideia principal do MEC é criar combinações com os dados coletados em cada eletrodo, de modo a cancelar a maior quantidade de ruído possível [4-5]. O sinal SSVEP é modelado por uma senoide acrescida de ruídos (Z_i), conforme apresentado na expressão (2):

$$y_i(t) = a_i \sin(2\pi t f + \phi_i) + b_i Z_i(t) \quad (2)$$

sendo $y_i(t)$ o sinal lido por cada eletrodo, a_i a amplitude do sinal evocado, Φ_i a fase e b_i a amplitude do ruído. Em forma matricial, tem-se:

$$Y = XA + ZB \tag{3}$$

onde, X é uma matriz $N_t x^2$ que representa o potencial evocado do sinal, sendo N_t o número de amostras do sinal. Ela é formada por sen $(2\pi ft)$ na primeira coluna e cos $(2\pi ft)$ na segunda coluna. A matriz Y de dimensão $N_t \ge n$ contem as amostras capturadas pelos n eletrodos. O sinal Y é projetado ortogonalmente de modo a eliminar as componentes referentes ao sinal SSVEP, desta forma deseja-se que a matriz \tilde{Y} contenha somente ruído.

$$\tilde{Y} = Y - X \left(X^T X \right)^{-1} X^T Y \tag{4}$$

Em seguida, surge um problema de otimização [4-5], no qual se deseja encontrar o vetor de pesos \widehat{w} com restrição de norma unitária, de forma a minimizar a energia do sinal \widetilde{Y} .

$$\min_{\hat{w}} \left\| \tilde{Y} \, \hat{w} \right\|^2 = \min_{\hat{w}} \hat{w}^T \, \tilde{Y}^T \, \tilde{Y} \, \hat{w} \tag{5}$$

O vetor de pesos permite combinar os sinais originados dos eletrodos em canais, gerando a matriz S:

$$S = YW \tag{6}$$

O problema de otimização é resolvido pela decomposição em autovalores e autovetores da matriz $\mathbf{\tilde{Y}}^{T}\mathbf{\tilde{Y}}$ [5], sendo determinado por:

$$W = \left(\frac{v_1}{\sqrt{\lambda_1}} \dots \frac{v_{N_s}}{\sqrt{\lambda_{N_s}}}\right) \tag{7}$$

O número de canais S foi fixado em oito, garantindo que ao menos 90% da energia do ruído fosse eliminada.



Figura 3. Espectro do sinal EEG com MEC.

A Figura 3 apresenta o módulo da FFT de 3 s do sinal quando o indivíduo estava exposto a um

estímulo de 12 Hz, após a filtragem pelo método MEC.

2.3. MCC

A técnica de filtragem espacial MCC é semelhante a MEC. O problema de otimização a ser resolvido visa minimizar a energia do ruído e maximizar a energia SSVEP [4-5], simultaneamente, conforme descrito na expressão (8):

$$\max_{\hat{w}} \frac{\left\| \hat{Y} \cdot \hat{w} \right\|^2}{\left\| \tilde{Y} \cdot \hat{w} \right\|^2} = \max_{\hat{w}} \frac{\hat{w}^T \cdot \hat{Y}^T \cdot \hat{Y} \cdot \hat{w}}{\hat{w}^T \cdot \hat{Y}^T \cdot \hat{Y} \cdot \hat{w}}$$
(8)

A solução é encontrada dividindo os autovalores e autovetores da matriz simétrica $Y^T Y$ pelos da matriz $\tilde{Y}^T \tilde{Y}$ [5]. O vetor de pesos W é calculado, de modo equivalente ao feito para o MEC, por (7). O número de canais S foi fixado em doze, garantindo que a energia SSVEP fosse ao menos 20% maior que a energia do sinal restante. A Figura 4 apresenta o módulo da FFT de 3 s do sinal quando o indivíduo estava exposto a um estímulo de 12 Hz, após a filtragem pelo método MCC.



Figura 4. Espectro do sinal EEG com MCC.

2.4. Extração de Características

Características são informações extraídas do sinal que permitem discriminar uma classe de outra, ou seja, se deseja diferenciar se o indivíduo está concentrado no estímulo de 12 Hz ou 15 Hz. O método de Welch [7] estima a densidade espectral de potência por meio da FFT [9]. Neste trabalho, a estima foi calculada em cada janela de 3 s usando um range de 1 Hz centrado em torno das duas frequências evocadas.

2.5. Seleção de Características

A seleção de atributos permite reduzir a complexidade do classificador, garantindo a sua

capacidade de generalização [10]. A técnica forward wrappers [11] seleciona características que fornecem mais informações para uma determinada estrutura de classificação. Esta técnica se inicia testando individualmente todas as características, aquela que fornecer a maior taxa de acerto para o classificador é selecionada. Na sequência, a característica selecionada é testada em combinação com cada uma das restantes, se houver ganho de desempenho do classificador, aumenta-se o conjunto de características selecionadas. O processo de inclusão progressiva de características contínua até não se verificar mais melhoria com a inclusão de nenhuma outra característica ao conjunto. A técnica de *wrappers* não garante a convergência para o ótimo global.

2.6. Classificador Linear

O classificador é responsável por estimar, a partir do conjunto de características, o comando dado pelo usuário. Na etapa de treinamento ele mapeia cada característica a uma etiqueta que identifica a qual comando ela está associada [9]. Na fase de validação, um conjunto de características diferente é utilizado para avaliar a taxa de acerto do sistema. Os classificadores lineares são frequentemente utilizados em sistemas BCIs devido à sua simplicidade matemática e baixo custo computacional [6]. Neste trabalho, utilizouse um classificador linear baseado no método dos mínimos quadrados, ou seja, deseja-se encontrar a combinação linear w que melhor separe as classes 12 e 15 Hz. A expressão do classificador linear pode ser definida como:

$$\boldsymbol{Y} = \boldsymbol{w}^T \boldsymbol{X} \tag{9}$$

onde w é o vetor de parâmetros do classificador que estabelece uma superfície de divisão entre as classes. O vetor Y é a saída do classificador que indica a qual classe as características especificadas nas linhas da matriz X pertencem. treinamento. utilizaram-se Para 0 as características advindas de 120 segmentos, com igual proporção de dados para ambas as frequências. Estes dados permitiram definir o plano w de separação das classes. O cálculo, na abordagem de mínimos quadrados, é determinado por:

$$\hat{\boldsymbol{w}} = (\boldsymbol{X}^T \boldsymbol{X})^{-1} \boldsymbol{X}^T \boldsymbol{R} \tag{10}$$

sendo R o vetor de rótulos definido como +1 se os atributos correspondem à classe de frequência evocada 12 Hz e -1 se correspondem aos dados do estímulo em 15 Hz. A solução de (10) é obtida pelo método da pseudo-inversa de MoorePenrose [9]. O desempenho do sistema foi medido analisando a taxa de acerto do classificador para as 40 janelas não usadas na etapa de treinamento.

3. Resultados e Discussão

A Tabela 1 apresenta o desempenho da BCI-SSVEP. Em todos os casos usou-se 120 segmentos cada para treinar o classificador linear e 40 segmentos para validá-lo considerando igual proporção de dados para ambas as classes.

O melhor desempenho foi obtido utilizando a técnica de filtragem CAR juntamente com a seleção de atributos por wrappers (95%). A aplicação da técnica de seleção de canais resultou sempre num ganho de desempenho do sistema. Os sistemas que usaram dados filtrados apresentaram desempenho melhor ou igual ao caso sem filtragem. O pior desempenho foi observado, justamente, quando nenhuma técnica de pré-processamento nem de seleção de características foi aplicado (57,5%). Este resultado representa uma perda de desempenho superior a 37% com relação ao melhor caso. É válido ressaltar, que apesar da análise ter sido feita em off-line, considerou-se janelamentos de 3 s, permitindo uma simulação de desempenho em aplicações em tempo real.

TABELA 1 – Desempenho da BCI usando diferentes técnicas de filtragem de sinais EEG.

	Desempenho da BCI (%)		
Técnicas de Pré-	Sem Seleção	Wranners	
Processamento	de Atributos	wruppers	
SEM FILTRAGEM	57,5	80,0	
CAR	90,0	95,0	
MCC	77,5	92,5	
MEC	70,0	80,0	
CAR+MCC	77,5	85,0	
CAR+MEC	82,5	85,0	

4. Conclusões

Os resultados corroboram a importância da filtragem dos sinais cerebrais e seleção de características para um melhor desempenho dos sistemas BCI. A seleção de atributos se mostrou extremamente importante, apresentando ganho em todos os cenários. Neste experimento, a técnica de filtragem mais eficiente foi a CAR. Entretanto, considerou-se somente a frequência fundamental na modelagem do potencial evocado para as técnicas MCC e MEC, embora seja possível incluir as sub-harmônicas no modelo. Como trabalho futuro, será investigada esta modelagem mais completa.

Agradecimentos

Os autores agradecem ao FINEP, CNPq, CAPES e UFOP, pelo apoio financeiro.

Referências

- [1] Censo Demográfico, IBGE. "Características gerais da população, religião e pessoas com deficiência." Rio de Janeiro (2010).
- [2] Middendorf, M., et al. "Brain-computer interfaces based on the steady-state visualevoked response." IEEE Transactions on Rehabilitation Engineering 8.2 (2000): 211-214.
- [3] Regan, D. "Human brain electrophysiology: evoked potentials and evoked magnetic fields in science and medicine." (1989).
- [4] Garcia-Molina, G., Zhu, D. "Optimal spatial filtering for the steady state visual evoked potential: BCI application." Neural Engineering (NER), 5th International IEEE/EMBS Conference on. IEEE, 2011.
- [5] Friman, O., et al. "Multiple channel detection of steady-state visual evoked potentials for brain-computer interfaces." Biomedical Engineering, IEEE Transactions on 54.4 (2007): 742-750.
- [6] Carvalho, S. N., et al. "Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs". Biomedical Signal Processing and Control, v. 21, p. 34-42, 2015.
- [7] 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 Trans. Audio Electroacoustics. V. AU-15, pp.70-73, 1967.
- [8] Nunez, P. e Srinivasan, R. "Electric fields of the brain: the neurophysics of EEG". Oxford university press, 2006.
- [9] Theodoridis S. e Koutroumbas K., "Pattern Recognition," Fourth Edition, Academic Press, California, 2010.
- [10] Guyon I. e Elisseeff A., "An introduction to variable and feature selection". The Journal of Machine Learning Research. V. 3, pp. 1157-1182, 2003.
- [11] Kohavi R. e John G. H., "Wrappers for feature subset selection". Artificial intelligence, v. 97, n. 1, pp. 273-324, 1997.