

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

**DETECÇÃO E CLASSIFICAÇÃO DE POTENCIAIS
EVOCADOS AUDITIVOS BASEADAS EM FILTROS
CASADOS**

AMANDA FRANCO SPIRANDELI

ORIENTADOR: PROF. DR. ALCIMAR BARBOSA SOARES, PhD

Uberlândia - MG
Janeiro/2020

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

**DETECÇÃO E CLASSIFICAÇÃO DE POTENCIAIS
EVOCADOS AUDITIVOS BASEADAS EM FILTROS
CASADOS**

AMANDA FRANCO SPIRANDELI

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de Mestre em Ciências. Área de concentração: Engenharia Biomédica. Linha de Pesquisa: Processamento de sinais.

Prof. Alcimar Barbosa Soares, PhD
Orientador

Prof. Dr. Adriano de Oliveira Andrade
Coordenador do curso de Pós-Graduação

Uberlândia - MG
Janeiro/2020

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

S759 Spirandeli, Amanda Franco, 1994-
2020 Detecção e classificação de potenciais evocados auditivos
baseadas em filtros casados [recurso eletrônico] / Amanda Franco
Spirandeli. - 2020.

Orientador: Alcimar Barbosa Soares.
Coorientador: Ailton Luiz Dias Siqueira Junior.
Dissertação (Mestrado) - Universidade Federal de Uberlândia,
Pós-graduação em Engenharia Biomédica.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.di.2020.272>
Inclui bibliografia.
Inclui ilustrações.

1. Engenharia biomédica. I. Soares, Alcimar Barbosa, 1968-,
(Orient.). II. Siqueira Junior, Ailton Luiz Dias, 1981-, (Coorient.). III.
Universidade Federal de Uberlândia. Pós-graduação em
Engenharia Biomédica. IV. Título.

CDU: 62:61

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
Coordenação do Programa de Pós-Graduação em Engenharia Biomédica
Av. João Naves de Ávila, 2121, Bloco 3N, Sala 115 - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
Telefone: (34) 3239-4761 - www.ppgeb.feelt.ufu.br - ppegb@feelt.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Biomédica				
Defesa de:	Dissertação de Mestrado Acadêmico, 056, PPGEb				
Data:	quatorze de janeiro de dois mil e vinte	Hora de início:	14 horas	Hora de encerramento:	16:40 h
Matrícula do Discente:	11622EBI001				
Nome do Discente:	Amanda Franco Spirandeli				
Título do Trabalho:	Abordagem para Detecção e Classificação de Potenciais Evocados Auditivos Baseadas em Filtros Casados				
Área de concentração:	Engenharia Biomédica				
Linha de pesquisa:	Engenharia de Reabilitação e Tecnologias Assistivas				
Projeto de Pesquisa de vinculação:	Integração Sensorio-Motora e Cognitiva: Modelos Para Potencialização do Reaprendizado Motor de Pacientes Paréticos Pós-AVE				

Reuniu-se no Anfiteatro do bloco 1E, Campus Santa Mônica, da Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Biomédica, assim composta: Professores Doutores: Sérgio Ricardo de Jesus Oliveira - FEELT/UFU; Edgard Afonso Lamounier Júnior - FEELT/UFU; Ailton Luiz Dias Siqueira Júnior - IFTM; Alcimar Barbosa Soares - FEELT/UFU orientador da candidata.

Iniciando os trabalhos o presidente da mesa, o Prof. Alcimar Barbosa Soares, apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público, e concedeu à Discente a palavra para a exposição do seu trabalho. A duração da apresentação da Discente e o tempo de arguição e resposta se deram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovada.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Alcimar Barbosa Soares, Professor(a) do Magistério Superior**, em 15/01/2020, às 11:58, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Ailton Luiz Dias Siqueira Junior, Usuário Externo**, em 16/01/2020, às 11:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Sergio Ricardo de Jesus Oliveira, Membro de Comissão**, em 16/01/2020, às 15:44, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Edgard Afonso Lamounier Junior, Professor(a) do Magistério Superior**, em 23/01/2020, às 09:42, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1785714** e o código CRC **169D640D**.

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

**DETECÇÃO E CLASSIFICAÇÃO DE POTENCIAIS
EVOCADOS AUDITIVOS BASEADAS EM FILTROS
CASADOS**

AMANDA FRANCO SPIRANDELI

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de Mestre em Ciências. Área de concentração: Engenharia Biomédica. Linha de Pesquisa: Processamento de sinais.

Membros da Banca:

Prof. Dr. Alcimar Barbosa Soares, PhD (Orientador – UFU)
Prof. Dr. Ailton Luiz Dias Siqueira Junior (IFTM)
Prof. Dr. Edgard Afonso Lamounier Junior (UFU)
Prof. Dr. Sérgio Ricardo de Jesus Oliveira (UFU)

Uberlândia - MG
Janeiro/2020

“Portanto dEle, por Ele e para Ele são todas as coisas.

A Ele seja a glória perpetuamente!

Amém.”

Romanos 11. 36 (Bíblia Sagrada)

Agradecimentos

Os processos de dores e muita persistência me ensinaram que ser GRATA é uma das “armas” mais poderosas para uma vida de sucesso que tanto almejamos.

A minha maior gratidão é ao meu Deus. Ele é o meu melhor amigo, o meu sustento, a minha alegria e hoje sou tão grata a Deus por me permitir vivenciar e realizar mais um sonho de me tornar mestre. Sei que isso tem um propósito muito maior que eu possa imaginar, acima de tudo, de manifestar a glória de Deus por onde eu estiver.

Eu agradeço aos meus pais, Kleber e Silvia, que sempre me incentivaram e investiram tanto tempo e recursos para me ajudar a crescer e com os conselhos sempre me levaram a sair da zona de conforto. Eles sempre foram meus maiores exemplos. Eu amo vocês com todo meu coração. Ao meu irmão Lucas, por ser sempre o meu amigo e cuidar de mim com tanto carinho e amor. Ao meu namorado, pela paciência e apoio em todos os momentos.

Eu agradeço imensamente ao meu professor e orientador Alcimar, por toda paciência, auxílio, apoio e conselhos durante esta caminhada. Eu admiro muito a sua força, persistência e profissionalismo. Muito obrigada por tudo! Ao professor Ailton, que sempre esteve presente para auxiliar em todos os momentos possíveis e também me orientar durante esse percurso. Agradeço aos demais professores da pós-graduação e do Biolab, em especial o coordenador da pós Professor Edgard e Professor Sérgio pelo apoio e simpatia sempre.

Agradeço imensamente a todos os meus colegas e amigos do Biolab (Andrei, Vinicius, Éber, Eduardo, Aline, Ana Clara, Najara, Bruno, Pedro, Ricardo, Eric, Amanda, Mariana, Ruben, Alexandre), que sempre foram inspirações para mim, em especial, a Mestre Amanda Medeiros, a qual me ensinou e foi uma verdadeira amiga durante toda esta caminhada. Eu amo vocês!

Ao CNPq, pelo suporte financeiro desta pesquisa.

Resumo

Interface cérebro máquina (ICM) é um sistema de comunicação direta entre cérebro e um dispositivo externo. Para classes especiais de sujeitos que sofrem, por exemplo, de síndrome do encarceramento, as ICMs exógenas baseadas em paradigmas *oddball* têm se destacado na literatura. Tais sistemas exploram os componentes N200, P300 de potenciais relacionados a eventos (PREs) como um meio de comunicação/controle da interface. No entanto, os modelos atuais para extração de características e classificação de sinais corticais para o controle de ICMs dependem de algoritmos complexos de aprendizado de máquina e com alto custo computacional, como redes neurais e máquina de vetores de suporte. Portanto, a taxa de comandos que podem ser decodificados por essas ICMs ainda está abaixo da desejada. Neste contexto, é altamente desejável o desenvolvimento de novos métodos de decodificação que possam melhorar o desempenho em tempo real de ICMs exógenas. Filtros casados têm sido utilizado há muito tempo como ferramenta de classificação, em tempo real, em sistemas de telecomunicação. O filtro casado é um sistema ótimo para detectar um sinal conhecido sob ruído gaussiano. De forma geral, é um sistema de fácil implementação, cuja saída maximiza a relação sinal ruído em dado instante de tempo, sem demandar altos custos computacionais. Neste trabalho, propõe-se um *framework* baseado em um banco de filtros casados, associado a um sistema de aquisição de sinais eletroencefalográficos (EEG), extração de características e detecção de picos, para classificação de informações neurais associadas à PREs. O sistema foi validado a partir de dados de eletroencefalografia obtidos de bancos de dados reais e sinais EEG sintéticos. Os resultados demonstram a viabilidade da técnica. Nos experimentos realizados, buscou-se a discriminação entre duas classes alvo para permitir a detecção de respostas ‘sim’ e ‘não’. A partir de dados simulados, o método obteve em média 90,27% de performance e 7,70 bit/min. A validação com dados EEG reais resultou em acurácia média de até 77,50%, com taxa de transferência de informações de até 3,19 bit/min. A validação do sistema demonstrou resultados satisfatórios, permitindo a decodificação de PREs com a dependência de poucas características do sinal, sem ajustes finos, abrindo caminho para uso de algoritmos de controle de ICMs em sistemas embarcados auxiliando indivíduos acometidos por síndrome do encarceramento.

Palavras-Chave: Filtros casados; Interface cérebro máquina; Potenciais relacionados à eventos; eletroencefalografia.

Abstract

A Brain Machine Interface (BMI) is a direct communication system between the brain and an external device. For a special group of subjects suffering, for example, from locked in syndrome, exogenous BMIs based on oddball paradigms have been presented in the literature. Such systems exploit event-related potentials (ERPs) that are evoked by specific stimuli and make use of its components such as the N200 and P300 as input signals for communication / interface control. However, current models for feature extraction and classification of cortical signals for the control of BMIs depend on complex machine learning algorithms with high computational cost, such as neural networks and support vector machines. Therefore, the rate of commands that can be decoded by such BMIs is still below the desired. In this context, the development of novel decoding methods that can improve the real-time performance of exogenous BMIs is highly desired. Matched filters have long been used as a real-time sorting tool in telecommunication systems and is a valid approach for detecting a known signal under Gaussian noise. In general, it is an easy to implement system that maximizes the output signal-to-noise ratio at any given time without requiring high computational costs. In this work, a novel framework is proposed based on a matched filter bank, associated with an electroencephalographic signal acquisition (EEG) system, feature extraction and peak detection for classification of neural information associated with ERPs. The system was validated using both synthetic EEG signals and real EEG data obtained from BMI databases. The results demonstrate the viability of the proposed framework. In the experiments performed, we sought to discriminate between two target classes to allow the detection of ‘yes’ and ‘no’ answers. From simulated data the method obtained on average 90.27% of performance and 7.70 bit / min. Validation with real EEG data resulted in an average accuracy of up to 77.50%, with information transfer rate of up to 3.19 bit / min. The validation of the system demonstrated satisfactory results, allowing the decoding of PREs with the dependence of few signal characteristics, without fine adjustments, paving the way for the use of BMI control algorithms in embedded systems assisting individuals affected by the incarceration syndrome.

Keywords: Matched filters; Brain machine interface; Event related potential; electroencephalography.

Lista de Figuras

Figura 2.1 – Diagrama de blocos do funcionamento de uma interface cérebro máquina.	23
Figura 2.2 – Posicionamento dos eletrodos de EEG no padrão 10-20 (Adaptado de Ramadan and Vasilakos 2017).	25
Figura 2.3 – Tipos de sinais eletrofisiológicos para controle de ICMs (Adaptado de Machado, 2013)	26
Figura 2.4 – Segmentos do sinal de EEG com os sinais de interesse e a média dos mesmos (Adaptado de Kungl, 2016).	29
Figura 2.5 – Abordagem base para classificação de dois alvos para controle de ICM. A classificação utiliza recursos extraídos como variáveis independentes para definir limites entre os diferentes alvos em um espaço de características (Adaptado de Nicolas-Alonso and Gomez-Gil 2012).	31
Figura 2.6 – Ilustração do hiperplano ideal para uma SVM (Adaptado de Lotte et al., 2007).	32
Figura 3.1 – Ilustração de um sistema típico de radar (Adaptado de Encyclopédia Britannica).	36
Figura 3.2 – Diagrama de blocos e ilustração da detecção de pulso em um sistema de comunicação binário utilizando filtros casados	37
Figura 3.3 – Modelo base de um filtro casado (Adaptado de Lavanon & Mozeson, 2004).	38
Figura 3.4 – Ilustração da resposta ao impulso do filtro casado (Levanon & Mozeson, 2004)	39
Figura 3.5 – (a) Pulso retangular $g(t)$ e (b) a resposta ao impulso $h(t)$ do filtro casado.	40
Figura 3.6 – Sinal de saída do filtro casado.	41

Figura 4.1 – Diagrama de blocos de um detector de PRE baseado em filtros casados. A saída (a) ocorre quando é aplicado um sinal $x(t)$ formado apenas pelo ruído $n(t)$. A saída (b) ocorre quando um sinal $x(t)$ é composto pelo pulso $s(t)$ e o ruído $n(t)$.	44
Figura 4.2 – (a) Em cinza tem a representação de várias épocas para um canal de um dado estímulo do sinal EEG e em vermelho o PRE médio dessas épocas. (b) o PRE médio de todas as épocas, que é o sinal desejado $s(t)$. (c) a resposta ao impulso $h(t)$ do filtro casado invertida no tempo de acordo com a definição; e contendo apenas as formas de onda de interesse N200 e P300, neste caso.	45
Figura 4.3 – Diagrama de blocos de um receptor M-ário (Adaptado de Lathi & Ding, 2009) .	46
Figura 4.4 – Exemplo de sinais associados às etapas de um sistema M-ário para classificação de PREs via filtros casados: (a) sinal de entrada, composto de um PRE; (b) saída do banco de filtros casados.	47
Figura 4.5 – Abordagem geral da proposta: Sinais auditivos são apresentados ao sujeito; as épocas associadas a cada estímulo, para cada canal EEG (aqui neste exemplo são representados canais das áreas centrais, mais associadas às respostas corticais (PREs) após estímulos auditivos) são coletadas e, enviadas ao classificador baseado em filtros casados, que deverá indicar qual dos estímulos o sujeito está focado.	49
Figura 4.6 – Diagrama de blocos da estrutura de classificação de PREs para um canal EEG.	50
Figura 4.7 – Sinais associado às etapas do sistema de classificação: (a) sinal de entrada – composto de um PRE. (b) saída do banco de filtros; a curva roxa representa a janela de análise dos picos e o círculo representa a saída do filtro que superou as demais amplitudes.	51
Figura 4.8 – Exemplo da geração de PREs semissintéticos. A curva azul representa o PRE real do canal FCZ para um indivíduo, e pelo ajuste de curva obtem-se o modelo de PRE para entrada do simulador (curva vermelha).	53

Figura 5.1 – Ilustração da simulação de 40 <i>trials</i> do conjunto G1S4, para cada eletrodo (cor cinza) e a média de todos os <i>trials</i> (vermelho) destacando PREs com as deflexões P100, N200 e P300.	62
Figura 5.2 – Curva de performance da resposta do sistema <i>versus</i> o número de épocas promediadas para a geração de sinais de entrada dos filtros, para o conjunto de dados G1S1	63
Figura 5.3 – Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um canal do conjunto G1S4 para o canal FCz; (b) saída do banco de filtros do classificador interno para o canal FCz – linha roxa: janela de análise dos picos; linha azul: saída do filtro para o alvo A; linha vermelha: saída do filtro para o alvo B; círculo preto: instante de tempo e filtro cuja saída apresenta maior amplitude (filtro selecionado – o PRE de entrada é associado ao alvo A, neste caso).....	64
Figura 5.4 – Curva de performance da resposta do sistema <i>versus</i> o número de épocas promediadas para a geração de sinais de entrada dos filtros, para o conjunto de dados G2S1	65
Figura 5.5 – Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um canal do conjunto G2S4 para o canal FCz; (b) saída do banco de filtros do classificador interno para o canal FCz – linha roxa: janela de análise dos picos; linha azul: saída do filtro para o alvo A; linha vermelha: saída do filtro para o alvo B; círculo preto: instante de tempo e filtro cuja saída apresenta maior amplitude (filtro selecionado – o PRE de entrada é associado ao alvo A, neste caso).....	66
Figura 5.6 – Curva de performance da resposta do sistema <i>versus</i> o número de épocas promediadas para a geração de sinais de entrada dos filtros, para o conjunto de dados G3S1	68

Figura 5.7 – Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um canal do conjunto G3S4 para o canal FCz; (b) saída do banco de filtros do classificador interno para o canal FCz – linha roxa: janela de análise dos picos; linha azul: saída do filtro para o alvo A; linha vermelha: saída do filtro para o alvo B; círculo preto: instante de tempo e filtro cuja saída apresenta maior amplitude (filtro selecionado – o PRE de entrada é associado ao alvo A, neste caso)..... 69

Figura 5.8 – Curva de performance da resposta do sistema versus o número de épocas promediadas para a geração de sinais de entrada dos filtros (Voluntário 1). Templates dos filtros gerados com todas as 20 épocas para cada alvo (A ou B) 70

Figura 5.9 – Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um sinal EEG (canal FCz); (b) saída do banco de filtros casados; a curva roxa representa a janela de análise dos picos e o círculo representa a saída do filtro que superou em amplitude..... 71

Figura 5.10 – Matriz de confusão para a média de acerto de todos os indivíduos para cada alvo, nos dados sequenciais e aleatórios, para canais de EEG. 73

Figura 5.11 – Época média geral para o voluntário 4 para os estímulos alvos escolhidos, com as respostas contralateral anterior (N2ac), ipsilateral e desvio (contralateral menos ipsilateral) quando o indivíduo atende o alvo A (a) e ao alvo B (b) 74

Figura 5.12 – Matriz de confusão para a média de acerto de todos os indivíduos para cada alvo, nos dados sequenciais e aleatórios, para canais de EEG juntamente com a componente N2ac. 75

Figura 5.13 – Exemplo das IMFs principais calculadas de uma época para todos os canais quando o indivíduo V1 atende ao alvo A que é tocado no ouvido esquerdo.. 76

Figura 5.14 – Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um sinal EEG das IMFs principais (canal FCz); (b) saída do banco de filtros casados; a curva

roxa representa a janela de análise dos picos e o círculo representa a saída do filtro que superou em amplitude 77

Figura 5.15 – Matriz de confusão para a média de acerto de todos os indivíduos para cada alvo, para validações com dados sequenciais e aleatórios, utilizando IMFs para geração dos sinais e *templates*..... 78

Figura 5.16 – Média global da acurácia de classificação para todos os sujeitos, com testes sequenciais e aleatórios, para todas as técnicas avaliadas.. 79

Lista de Tabelas

Tabela 2.1 – Acurácia média de classificação (%) e taxa de transferência de informações (bit/min) para diferentes ICM auditivas.	34
Tabela 5.1 – Parâmetros de entrada para o simulador para geração das deflexões dos P_{RE_A} (simula um sujeito prestando atenção no alvo A) para o conjunto de dados G1S1.	61
Tabela 5.2 – Acurácia de classificação e TTI para cada conjunto de dados do G1.	64
Tabela 5.3 – Acurácia de classificação e TTI para cada conjunto de dados do G2.	67
Tabela 5.4 – Acurácia de classificação e TTI para cada conjunto de dados do G3	69
Tabela 5.5 – Acurácia de classificação e TTI para cada voluntário, com validações cruzadas utilizando dados sequenciais e embaralhados para geração dos <i>templates</i> e sinais de entrada dos filtros.....	72
Tabela 5.6 – Acurácia de classificação e TTI para cada voluntário. Validações cruzadas executadas com os dados sequenciais e embaralhados, com a inclusão da componente N2ac aos sinais EEG	75
Tabela 5.7 – Acurácia de classificação e TTI para cada voluntário, com os dados sequenciais e embaralhados, utilizando as IMFs para geração dos <i>templates</i> e sinais de entrada dos filtros.	77
Tabela 5.8 – Acurácia de classificação e a TTI para cada voluntário com validações cruzadas baseadas em dados sequenciais e embaralhados. O <i>template</i> dos filtros foram gerados a partir das IMFs principais e o sinais de entrada a partir dos sinais EEG.....	78
Tabela 5.9 – Acurácia de classificação e TTI para todos os voluntários e todas as estratégias de geração de <i>templates</i> e sinais de entradas para os filtros.....	79

Lista de Abreviaturas e Siglas

ICM	Interface Cérebro Máquina
EEG	Eletroencefalografia
ELA	Esclerose Lateral Amiotrófica
SE	Síndrome do Encarceramento
PRE	Potencial Relacionado à eventos
ECoG	Eletrocorticografia
ICA	Análise de Componente Independente
ACP	Análise de Componentes Principais
EMD	<i>Empirical Mode Decomposition</i>
LDA	Análise discriminante linear
SVM	Maquina de vetor de suporte
SSVEP	Potenciais evocados visuais de estado estacionário
TTI	Taxa de transferência de informação

Sumário

CAPÍTULO 1 - INTRODUÇÃO	19
1.1 Objetivos do trabalho	21
1.2 Objetivos específicos.....	21
1.3 Estrutura da dissertação	22
CAPÍTULO 2 – INTERFACE CÉREBRO MÁQUINA.....	23
2.1 Instrumentação EEG.....	24
2.2 Sinais de controle em ICMs	25
2.3 Pré-processamento.....	28
2.4 Segmentação do sinal EEG	28
2.5 Extração de características	29
2.6 Métodos clássicos para classificação de potenciais evocados	31
2.7 Acurácia e taxa de transferência de informações	33
2.8 Considerações finais	35
CAPÍTULO 3 – FILTROS CASADOS	36
3.1 Definição de filtros casados.....	37
3.2 Características e propriedades dos filtros casados.....	39
3.3 Exemplo de aplicação	40
3.4 Contextualização e considerações iniciais sobre a aplicação de filtros casados na detecção e classificação de PREs	41
CAPÍTULO 4 – PROPOSTA DE UM <i>FRAMEWORK</i> PARA DETECÇÃO E CLASSIFICAÇÃO DE PRES	44
4.1 Detector de PREs usando filtros casados	44
4.2 Classificação de PREs usando filtros casados.....	46
4.3 O <i>framework</i> completo	48
4.4 Estratégia de validação	52
4.4.1 Sinais EEG semissintéticos	52
4.4.2 Sinais EEG reais	54
4.4.2.1 Pré-processamento.....	55
4.4.2.2 Resposta N2ac	55
4.4.2.3 Segmentação do sinal	56
4.4.2.4 Decomposição de Modo Empírico	56

4.5	Experimentos de validação	56
4.5.1	Sinais de EEG semissintéticos.....	56
4.5.1.1	Acurácia <i>versus</i> número de épocas promediadas	57
4.5.1.2	Experimentos com validação cruzada	57
4.5.1.3	Taxa de transferência de informação	57
4.5.2	Sinais de EEG reais	57
4.5.2.1	Acurácia <i>versus</i> número de épocas promediadas	57
4.5.2.2	Experimentos com validação cruzada	58
4.5.2.3	Taxa de transferência de informação	59
	CAPÍTULO 5 - RESULTADOS.....	60
5.1	Sinais EEG semissintéticos	60
5.1.1	Grupo 1: Sinais com relação sinal ruído de 200dB	61
5.1.1.1	Acurácia do sistema <i>versus</i> número de épocas promediadas	61
5.1.1.2	Validação cruzada.....	63
5.1.2	Grupo 2: Sinais com relação sinal ruído de 20dB	65
5.1.2.1	Acurácia do sistema <i>versus</i> número de épocas promediadas	65
5.1.2.2	Validação cruzada.....	66
5.1.3	Grupo 3: Sinais com relação sinal ruído de 10dB	67
5.1.3.1	Acurácia do sistema <i>versus</i> número de épocas promediadas	67
5.1.3.2	Validação cruzada.....	68
5.2	Sinais EEG reais	70
5.2.1	Acurácia do sistema <i>versus</i> número de épocas promediadas	70
5.2.2	Validação cruzada.....	71
5.2.3	Validação incluindo a componente N2ac	73
5.2.4	Validação utilizando Decomposição de modo empírico	75
5.3	Considerações finais sobre os resultados.....	78
	CAPÍTULO 6 – DISCUSSÃO	79
	CAPÍTULO 7 – CONCLUSÕES	82
7.1	Trabalhos Futuros	82
	REFERÊNCIAS	84

Capítulo 1 - Introdução

Interface cérebro máquina (ICM) é um sistema que permite a interação entre sinais cerebrais e dispositivos externos de hardware ou software (Ramadan & Vasilakos, 2017). A ICM é, particularmente, relevante para auxiliar pessoas acometidas por lesões neuromusculares e doenças neurodegenerativas, como esclerose lateral amiotrófica (ELA) e síndrome do encarceramento (SE), que impossibilitam a via natural de comunicação (Chaudhary, Birbaumer, & Ramos-Murguialday, 2016; Nicolas-Alonso & Gomez-Gil, 2012).

A síndrome do encarceramento é uma condição em que o sujeito permanece com as funções cognitivas intactas, mas perde sua capacidade de se mover e de se comunicar verbalmente devido à paralisia dos músculos voluntários do corpo (Chaudhary, Xia, Silvoni, Cohen, & Birbaumer, 2017). Esta síndrome pode ocorrer por causas como: acidente vascular encefálico no tronco cerebral, doenças no sistema circulatório, danos às células nervosas (como os causados por ELA), hemorragia cerebral, dentre outras (Jarad, 2016).

A ELA é uma doença que acomete os neurônios motores e é caracterizada pela deterioração neurológica progressiva e irreversível (Hardiman, Van Den Berg, & Kiernan, 2011). À medida que a doença progride, o indivíduo perde as habilidades de locomoção, fala, deglutição e respiração, passando a depender de equipamentos para manutenção da vida. Segundo estudos, a incidência da doença é de aproximadamente 5,4 casos em 100.000 pessoas, sendo a sobrevida média de três a cinco anos após o diagnóstico da doença (Hobson & McDermott, 2016). No Brasil, quase 5.000 pessoas são diagnosticadas com ELA, anualmente, de acordo com a associação pró cura da ELA (Pereira, 2006).

Como os indivíduos acometidos por doenças como ELA perdem, progressivamente, a capacidade de comunicação, diversas alternativas têm sido buscadas numa tentativa de se estabelecer novos mecanismos de comunicação. Diversas estratégias tem sido implementadas utilizando sinais biológicos voluntários remanescentes, como movimentos oculares (Caligari, Godi, Guglielmetti, Franchignoni, & Nardone, 2013; Spataro, Ciriaco, Manno, & La Bella, 2014) e dispositivos mecânicos para controle de teclados virtuais (Mariano et al., 2014). Entretanto, em estágios avançados de SE, o sinal remanescente mais viável para controle de dispositivos de comunicação alternativa é o sinal cortical (Nicolas-Alonso & Gomez-Gil, 2012). Nestes casos, uma estratégia comum é a utilização de eletroencefalografia (EEG) para detectar a atividade cortical de forma não invasiva e controlar a ICM.

Dentre os fenômenos fisiológicos que podem ser analisados para o controle de uma ICM, estão os potenciais relacionados a eventos (PREs) (Farwell & Donchin, 1988), que são deflexões positivas e negativas variando de acordo com a latência, após a apresentação de um estímulo externo (Polich, 2007; Kappenman & Luck, 2012). PREs podem ser evocados em paradigmas *oddball*, que são baseados na apresentação de estímulos frequentes e repetitivos intercalados de estímulos não frequentes e com características distintas (Beverina et al., 2003). Os estímulos mais comuns para controle de ICMs são estímulos somatossensoriais, visuais e auditivos. Dentre os paradigmas de estimulação visual, os potenciais evocados visuais de estado estacionário (SSVEPs) têm sido explorados e obtido sucesso em pacientes com ELA, principalmente pela taxa de classificação rápida do sinal e da facilidade de configuração do sistema (Han, Xu, Xie, Chen, & Zhang, 2018; Nakanishi et al., 2018). No entanto, nesse tipo de paradigma, o usuário deve focar a atenção em pequenas unidades de uma tela (por exemplo, uma tecla virtual mostrada na tela de um computador), e isso muitas vezes causa cansaço e tontura no sujeito; e ainda, em estágios avançados de ELA, o movimento ocular é comprometido, impedindo o uso de estratégias visuais para comunicação (Murguialday et al., 2011; Nijboer et al., 2008). Os estímulos somatossensoriais por meio do tato, embora sejam eficientes para indivíduos que possuem a visão acometida em decorrência da doença, podem causar desconforto ao usuário inicialmente, e com o passar do tempo o sujeito tende a se acostumar com a estimulação tátil, o que reduz a eficiência da interface (Ahn, Kim, & Jun, 2016; Brouwer & van Erp, 2010; Yao, Meng, Zhang, Sheng, & Zhu, 2013). Diante destes cenários, paradigmas que utilizam a percepção auditiva podem apresentar resultados mais favoráveis àqueles pacientes (Erlbeck, Mochty, Kübler, & Real, 2017; Halder et al., 2010; Kåthner et al., 2013).

Estudos utilizando estímulos auditivos com paradigma *oddball* têm sido usualmente realizados com diferentes tipos de estímulos sonoros, como zumbidos e cliques (M. Huang, Jin, Zhang, Hu, & Wang, 2018), tons (Kanoh, Miyamoto, & Yoshinobu, 2008; Kim et al., 2011), palavras (Furdea et al., 2009; Klobassa et al., 2009) e apresentação de sons em diferentes direções (Lelievre, Washizawa, & Rutkowski, 2013). É possível observar na maioria dos estudos citados que a relação entre a taxa de transferência de informação (TTI) e a acurácia do sistema é inversamente proporcional, ou seja, TTI mais altas geralmente são obtidas por sistemas com acurácia mais baixa (Baykara et al., 2016; Sugi et al., 2018; Kim et al., 2011; Klobassa et al., 2009). Isso geralmente acontece pois, para se aumentar a TTI é necessário um número reduzido de estímulos, o que pode gerar PREs menos evidentes em relação a atividade *background* de EEG (Halder et al., 2010). Além disso, a maioria das técnicas propostas para

extração de características e classificação dos PREs que possuem acurácias mais altas são baseadas em sistemas de aprendizagem de máquina (Guo et al., 2015; Halder, Käthner, & Kübler, 2016), que demandam um treinamento prévio, ajustes finos de parâmetros, modelos complexos e com alto custo computacional (Farquhar & Hill, 2013; Manyakov, Chumerin, Combaz, & Van Hulle, 2011), dificultando sua aplicação em sistemas *online* e embarcados. Uma vez que sistemas embarcados podem proporcionar ao usuário, praticidade, conforto e melhor usabilidade do sistema. Além disso, a amplitude dos PREs são muito baixas, pode variar em $\pm 5 \mu\text{V}$ (Reis et al., 2014), enquanto a atividade cerebral de *background* mensurada no EEG pode atingir até $\pm 50 \mu\text{V}$ (Bressler and Ding, 2006). Assim, para que se possa detectar corretamente PREs é comum utilizar promediações (médias) de trechos (épocas) de 1 a 5 segundos do sinal EEG, em sincronismo com o início do estímulo evocador. No entanto, quanto maior a quantidade de épocas necessárias menor será a TTI da interface.

Neste sentido, os filtros casados surgem como uma possibilidade interessante para buscar minimizar a quantidade necessária de épocas promediadas, uma vez que, por sua natureza, são descritos como elementos ideais para detecção de sinais em um meio ruidoso (Haykin, 2001), como ocorreria entre o PRE (sinal) e o EEG de background (ruído) neste caso.

1.1 - Objetivo do trabalho

Diante do exposto, este trabalho tem por objetivo central propor um *framework* baseado na técnica de filtros casados, para detecção e classificação potenciais relacionados à eventos auditivos em sinais de EEG, que seja aplicável em modelos de ICMs para comunicação alternativa.

1.2 - Objetivos específicos

- Avaliar estratégias e definir uma estrutura (*framework*) baseada em filtros casados para detecção e classificação de PREs em múltiplos canais EEG.
- Validar o *framework* proposto com auxílio de sinais sintéticos.
- Validar o *framework* proposto com auxílio de sinais EEG reais com aplicação em paradigma *oddball* auditivo para respostas binárias (sim/não).

1.3 - Estrutura da dissertação

Este capítulo trouxe a introdução do assunto que será abordado neste trabalho, juntamente com as motivações e objetivos.

Os capítulos seguintes vão discorrer da seguinte forma:

- Capítulo 2: Apresenta o estado da arte de ICMs, apontado os principais métodos para extração de características e classificação de potenciais relacionados à eventos;
- Capítulo 3: Apresenta uma revisão sobre filtros casados abordando os conceitos, características e exemplos de aplicação;
- Capítulo 4: Este capítulo descreve a proposta de um modelo, ou *framework*, para a detecção e classificação de potenciais evocados baseado em filtros casados;
- Capítulo 5: Apresenta os experimentos de validação e os resultados obtidos em cada fase;
- Capítulo 6: Discute os resultados obtidos à luz da literatura atual;
- Capítulo 7: Aborda a conclusão da pesquisa realizada e propõe sugestões para estudos futuros.

Capítulo 2 - Interfaces Cérebro Máquina

Conforme mencionado no capítulo anterior, as interfaces cérebro máquina são sistemas controlados por meio de sinais cerebrais, sem a necessidade de qualquer atividade muscular, e podem ser utilizadas para implementação de mecanismos de comunicação alternativa (McFarland & Wolpaw, 2011). Neste caso, tais dispositivos são desenvolvidos principalmente para auxiliar pacientes com doenças neurodegenerativas que perderam a capacidade de comunicação e interação com o meio externo (Kübler, Kotchoubey, Kaiser, Birbaumer, & Wolpaw, 2001).

A Figura 2.1 ilustra o diagrama de blocos típico de um sistema de interface cérebro máquina. A primeira etapa deste processo é a aquisição dos sinais corticais, que no caso ocorre por meio da eletroencefalografia (EEG). Para que esse registro aconteça são necessários eletrodos de superfície e um equipamento para condicionamento do sinal contemplando amplificadores, filtros, isolamento galvânico e posteriormente a digitalização dos dados registrados (Nicolas-Alonso & Gomez-Gil, 2012).

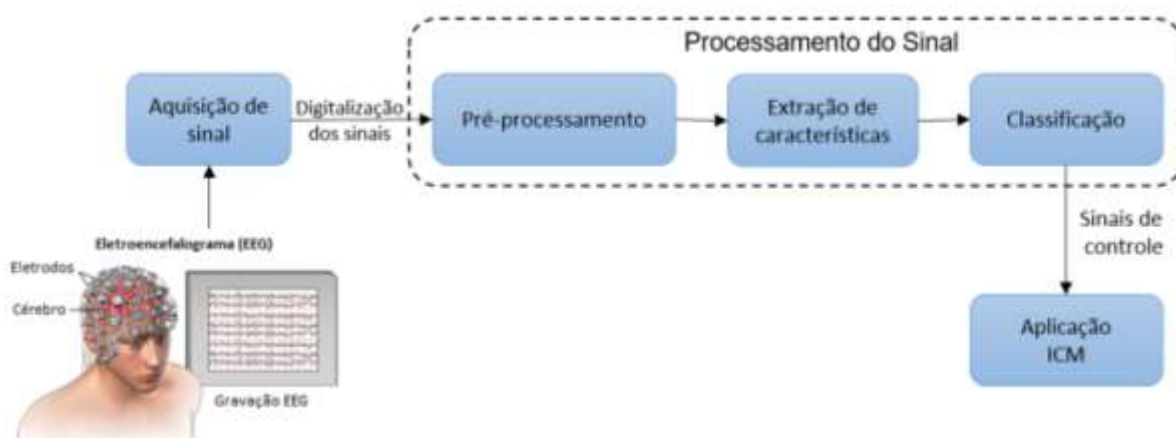


Figura 2.1 – Diagrama de blocos do funcionamento de uma interface cérebro máquina.

A segunda fase, o pré-processamento do sinal, é de grande importância e tem como objetivo a redução de ruídos e remoção de artefatos utilizando filtros digitais e outras técnicas, a fim de garantir a qualidade do sinal e contribuir para resultados mais eficazes. Juntamente com a etapa de pré-processamento, uma estratégia comum no processamento das ICMs é a segmentação do sinal de EEG em janelas (épocas) que contenham informações importantes

quanto às tarefas realizadas pelo usuário, descartando intervalos com informações não relevantes ao sistema (Guo et al., 2015; Halder et al., 2010).

Em sequência, a fase de extração de características, é um conjunto de informações extraídas do sinal janelado usando diferentes métodos e tem como objetivo descrever as intenções do usuário, sendo armazenados na forma de um vetor. Esse vetor de características pode ser constituído apenas pela a forma de onda do sinal ou incluir elementos como, por exemplo, valores em amplitude de picos, valores em latências conhecidas (P100, N200, P300), e potência de determinadas bandas de frequência (Garcés & Orosco, 2008), que trazem em si efeitos fisiológicos dos potenciais elétricos registrados da atividade das células piramidais localizadas no córtex cerebral.

A próxima etapa é a classificação do sinal, que pode ser explicada como a tradução das intenções ou comandos do usuário para controle de uma ICM. Esta fase é um processo que utiliza estratégias para determinar quais características selecionar e como combina-las para otimizar o desempenho do sistema (Garcés & Orosco, 2008). A maioria das estratégias utilizadas atualmente para classificação são baseadas em técnicas de aprendizado de máquina, o que exigem algoritmos mais complexos e com alto custo computacional, ou seja, muito tempo para o processamento.

2.1 - Instrumentação EEG

Atividades eletrofisiológicas cerebrais podem ser mensuradas por exemplo, de forma invasiva, por eletrocorticografia (ECoG), gravação intracortical de potenciais associados à atividade de neurônios; e também de forma não invasiva por meio da eletroencefalografia (EEG) (Nicolas-Alonso & Gomez-Gil, 2012). A instrumentação mais comumente utilizada para mensurar atividades corticais é a eletroencefalografia, principalmente por ser um método não invasivo, relativamente barato e de fácil utilização, além de poder ser portátil e possuir alta resolução temporal (Ramadan & Vasilakos, 2017). Por estes mesmos motivos, o EEG também é o método mais utilizado para desenvolvimento de ICMs (Ahn et al., 2016; Hill et al., 2014; Nagel & Spüler, 2019).

No entanto, apesar de sua excelente resolução temporal (milissegundos), o EEG é limitado em sua resolução espacial (cada eletrodo capta sinais de uma área de aproximadamente 4 cm²), além de ser mais influenciável por interferências de ruídos externos e internos, como a

interferência eletromagnética da rede elétrica (60 Hz) e a movimentação do globo ocular (Garcés & Orosco, 2008).

A Figura 2.2 mostra o posicionamento dos eletrodos no escalpo baseado no sistema internacional 10-20 (Klem et al., 1999). Em uma ICM típica, pode-se utilizar um ou mais eletrodos, a depender da aplicação e das demandas do método (Lal et al., 2004).




Figura 2.2 – Posicionamento de eletrodos EEG segundo o padrão internacional 10-20
(Adaptado de Ramadan & Vasilakos, 2017).

2.2 - Sinais de controle em ICMs

Dentre os fenômenos fisiológicos que podem ser analisados nos sinais corticais para controle de ICMs estão os potenciais evocados de estado estacionário (SSVEPs), os potenciais relacionados à eventos (PREs), potenciais corticais lentos (sincronização e dessincronização) e ritmos sensório-motores (ritmos mu e beta), como destacado na Figura 2.3 (McFarland & Wolpaw, 2011; Nicolas-Alonso & Gomez-Gil, 2012; Ramadan & Vasilakos, 2017).




Figura 2.3 – Tipos de sinais eletrofisiológicos clássicos para controle de ICMs
(Adaptado de Machado, 2013).

De acordo com a natureza dos sinais EEG utilizados como entrada no sistema, as ICMs podem ser categorizadas como endógenas ou exógenas. A ICM endógena é fundamentada na auto-regulação dos ritmos e potenciais cerebrais sem estímulos externos, o que exige um treinamento exaustivo do usuário, e geralmente resulta em taxas de transferência de informações mais baixas. Os sinais utilizados neste tipo de ICM incluem os potenciais corticais lentos e os ritmos sensório motores (Kleber & Birbaumer, 2005; Nicolas-Alonso & Gomez-Gil, 2012). Os potenciais corticais lentos são mudanças de tensão lentas no EEG que podem durar de 0,5 a 10 segundos. As alterações de tensão podem ser positivas quando há a redução da atividade neuronal, ou negativas, quando ocorre uma maior ativação da região córtex (aumento na excitação dos neurônios) (Chaudhary et al., 2016). Em ICMs controladas por potenciais corticais lentos, os usuários podem aprender a manipular um cursor e selecionar alvos apresentados na tela do computador (Birbaumer, Hinterberger, Kübler, & Neumann, 2003). Já os ritmos sensório motores (μ e β), são oscilações da atividade cerebral nas bandas de frequência μ (7 a 13 Hz) e β (13 a 30 Hz). A amplitude do ritmo sensório-motor varia

quando a atividade cerebral está associada a qualquer tarefa motora, mesmo que não haja movimento de alguma parte do corpo. Ou seja, apenas um ensaio mental de um ato motor é capaz de produzir modulações nos ritmos sensório motores (imaginação motora). O usuário pode aprender a gerar essas modulações voluntariamente para selecionar opções na tela do computador também (Wolpaw, Mcfarland, & Vaughan, 2000).

As ICMs exógenas são caracterizadas pela utilização da atividade cerebral desencadeada por estímulos externos, como, por exemplo, os potenciais evocados de estado estacionário ou potenciais relacionados à eventos. ICMs exógenas são mais exploradas na literatura devido a uma taxa de transferência de informações mais alta e tendem a exigir um treinamento mínimo dos usuários (Kleber & Birbaumer, 2005; Nicolas-Alonso & Gomez-Gil, 2012).

Os potenciais evocados de estado estacionário são registros cerebrais gerados quando o indivíduo recebe estímulos periódicos, como imagens piscando, sons modulados, ou vibrações. Estes potenciais corticais aparecem nos registros de EEG replicando a mesma forma (frequência) do estímulo em que o sujeito está focado. Já os potenciais relacionados à eventos são deflexões positivas e negativas em latências conhecidas e bem definidas (principalmente P100, N200 e P300) (Polich, 2007; Kappenman & Luck, 2012). Tais potenciais são normalmente evocados em paradigmas *oddball*, que são baseados na apresentação de estímulos frequentes e repetitivos intercalados de estímulos não frequentes e com características distintas (Beverina et al., 2003). A resposta cerebral, advinda do “prestar atenção” em um estímulo externo específico, é extraída cerca de 300 a 600 ms após a apresentação deste estímulo e está contida na faixa de frequência de 0,15 a 5 Hz (P300). Quanto menor a probabilidade de um certo evento (*oddball*), mais proeminente será o P300 (Citi, Poli, & Cinel, 2010).

Estudos como o de Gamble e Luck (2011) relatam, além deflexões descritas, a presença de uma resposta negativa em torno da latência N200 no local do EEG contralateral ao lado de apresentação de estímulos externos auditivos (orelha direita ou esquerda). Esta componente é denominada “N200 anterior-contralateral” (N2ac) do PRE auditivo. Os pesquisadores concluíram que, durante uma sequência de processos neurais evocados associados a estímulos auditivos, a resposta lateral N2ac se trata de um marcador eletrofisiológico geral de focalização da atenção auditiva em direção a um som alvo detectado (Gamble & Woldorff, 2015).

2.3 - Pré-processamento

Normalmente no processo de aquisição do sinal EEG, o sinal é contaminado por ruídos de diferentes fontes como, por exemplo, piscadas (EOG), artefatos de movimento, atividade muscular (EMG) ou provenientes de outras fontes externas relacionadas (ou não) a dispositivos utilizados na coleta de dados. O objetivo do pré-processamento é retirar ou atenuar os ruídos a fim de obter um sinal de EEG livre de artefatos, mais confiável e visando a melhoria da relação sinal ruído, evidenciando assim, as características que serão analisadas para controle da interface.

A grande maioria dos sistemas utilizam filtros digitais do tipo passa-faixa com frequência de corte entre 2 a 30 Hz para atenuar ruídos da rede elétrica e focar apenas nas frequências de interesse para análise dos dados corticais (Furdea et al., 2009; Onishi, Takano, Kawase, Ora, & Kansaku, 2017). Além disso, estratégias simples complementares podem ser aplicadas, como inspeção visual e limiares em amplitude para eliminar segmentos de dados (épocas) do sinal EEG que apresentem ruídos (Guo et al., 2015).

Outras técnicas comuns para pré-processamento de sinais de EEG são: a remoção de piscadas (EOG) por meio da análise de componentes independentes (ICA) (Hosni, Gadallah, Bahgat, & AbdelWahab, 2007; Zhaojun Xue, Jia Li, Song Li, & Baikun Wan, 2006); a remoção de artefatos oculares por meio de Análise de Componentes Independentes (ICA) combinada ou não com modelos *Wavelet* (wICA) (Castellanos & Makarov, 2006; Mammone, La Foresta, & Morabito, 2012). No entanto essas técnicas são eficazes apenas quando a piscada é bastante evidente na coleta de dados (Castellanos & Makarov, 2006). Além disso, esse processamento ocorre principalmente de forma *off-line*, após uma análise prévia dos dados coletados.

2.4 - Segmentação do sinal EEG

O processo de segmentação do sinal, também denominado de extração de épocas, consiste em analisar o sinal coletado, dividindo-o em janelas que contenham o sinal de interesse, como por exemplo a resposta evocada de um dado estímulo.

Para sinais de EEG é comum realizar essa segmentação para cada canal, considerando o momento em que o estímulo externo é apresentado ao sujeito (*onset*). Define-se o tamanho da janela considerando o tempo de resposta cerebral e a frequência de amostragem (Hill et al., 2014). A Figura 2.4(a) mostra a definição de várias janelas em sinal EEG, definidas a partir de

um dado o estímulo. A Figura 2.4(b) mostra como os sinais de várias janelas são combinados (promediados) para obtenção de um potencial evocado.




Figura 2.4 – Segmentos do sinal de EEG com os sinais de interesse e a média dos mesmos (Adaptado de Kungl, 2016).

2.5 - Extração de características

Após a segmentação e promediação das janelas de sinais obtidas na fase de processamento, os potenciais relacionados à eventos são utilizados como entrada para a etapa de extração de características. A ICM é um sistema que reconhece padrões e classifica cada um como parte de determinada classe, de acordo com suas características. Para isso, a ICM extrai características dos sinais cerebrais. Tais características são, em geral, definidas pelo pesquisador, que as seleciona (por uma avaliação direta ou com auxílio de mecanismos probabilísticos) conforme sua probabilidade de especificar e salientar as diferenças dentre as classes (Nicolas-Alonso & Gomez-Gil, 2012).

Conforme observado na seção 2.1, a atividade cortical pode ser mensurada por múltiplos eletrodos, porém nem todas as informações fornecidas pelos canais medidos são relevantes para a compreensão da intenção do usuário ao tentar controlar uma ICM. Técnicas para redução de dimensionalidade, como análise de componentes principais (ACP) (Yu, Chum, & Sim, 2014), ou a análise de componentes independentes (ICA) (Turnip, Hong, & Jeong, 2011), utilizam

medidas estatísticas para separação de componentes derivadas do sinal, reduzindo assim o vetor de características e, em consequência, o custo computacional.

Além disso, dada a quantidade de características que podem ser extraídas de vários canais e de vários segmentos de dados, deve-se também buscar meios para avaliar quais daquelas características são mais relevantes, evitando vetores de características com alta dimensão. Para tal, pode-se fazer uma análise a fim de detectar vantagens e limitações da utilização de determinada característica a ser extraída. Uma das opções para construir o vetor de características é utilizar as próprias amostras (valores de tensão digitalizados) do sinal, onde a amplitude de cada amostra representaria uma característica. No entanto, esta técnica não é muito recomendada, principalmente para sistemas que trabalham com taxas de amostragem mais altas, pois o tamanho do vetor de características é igual ao número de amostras do segmento de dados, o que pode ocasionar um aumento exagerado no custo computacional.

Outra questão importante é a relação sinal-ruído. Algumas técnicas propõem representar melhor o sinal dos PREs em ensaios únicos, utilizando, por exemplo, a transformada de *wavelet* (Amin et al., 2015; Z. Wang, Wu, Qi, & Jiang, 2010) e a decomposição em modo empírico (EMD) (Guo et al., 2015; Li, Zhou, Yuan, Geng, & Cai, 2013). A primeira (transformada de *wavelet*) fornece uma representação do sinal em tempo e frequência. Já a EMD, se trata da decomposição de uma série temporal em componentes individuais, que são denominados de funções de modo intrínseco (IMF). As IMFs representam oscilações intrínsecas no sinal em si (N. E. Huang et al., 1998; Labate et al., 2013). Algoritmos que utilizam transformadas ou decomposição do sinal, apresentam um custo computacional maior, no entanto, ao utilizar coeficientes das transformadas como características, pode-se contribuir para uma capacidade de discriminação melhor do vetor características, o que resultaria em um aumento de performance do algoritmo.

Outra possibilidade para a construção do vetor de característica é a utilização da latência e tempo de ocorrência do sinal (tempo de resposta cerebral em relação ao estímulo externo e a duração deste ao longo da janela de tempo) (Thompson, Warschausky, & Huggins, 2013). Nesta característica são evidentes pequenas variações de eletrodo para eletrodo devido à lateralidade da resposta (contralateral ou ipsilateral ao estímulo) e também pela conectividade cerebral, que são links anatômicos ou dependências estatísticas entre unidades distintas dentro do sistema nervoso.

2.6 – Métodos clássicos para classificação de potenciais evocados

Métodos de classificação são utilizados para estimar a intenção do sujeito ou em que estímulo ele estaria focado (representando qual estímulo de interesse que poderia, por exemplo, ser associado a uma resposta sim ou não), a partir do vetor de características. O objetivo da classificação é descrever um limite entre as classes e rotulá-las com base em suas características medidas (Garcés & Orosco, 2008). Na Figura 2.5, temos a representação de diversas amostras (compostas de duas características x,y) separadas em duas classes (azul e vermelho), que poderiam, em uma interface cérebro máquina, estar associadas à duas diferentes intenções do usuário.




Figura 2.5 – Abordagem base para classificação de dois alvos para controle de ICM. A classificação utiliza elementos extraídos como variáveis independentes para definir limites entre os diferentes alvos em um espaço de características (Adaptado de Nicolas-Alonso & Gomez, 2012).

A etapa de classificação engloba desde um classificador simples que fixa um limite para as características, a algoritmos mais complexos, como modelos de aprendizado de máquina. Os algoritmos de classificação podem ser aplicados *off-line*, em tempo real (*online*) ou ambos. Uma ICM *online* fornece um meio onde os dados são processados e resultam em reflexos imediatos na interface (Han et al., 2018; Yin et al., 2016). A análise de dados *off-line* é importante para apoiar o desenvolvimento e teste de novos algoritmos (M. Huang et al., 2018; Sugi et al., 2018; Kohavi, 1995).

Diferentes técnicas de agrupamentos e classificação foram desenvolvidas ao longo dos últimos anos e muitas delas são aplicadas para ICMs. As mais comuns descritas na literatura para sistemas de ICMs são: redes neurais artificiais, análise discriminante linear e máquina de vetores de suporte. As redes neurais artificiais fazem uma analogia matemática das funções de

baixo nível dos neurônios biológicos e são utilizadas no reconhecimento de padrões, uma vez que são capazes de aprender e generalizar os dados de treinamento. No algoritmo, as características são distribuídas em cada neurônio de entrada, e suas conexões são ligadas por diferentes pesos (Garcés & Orosco, 2008; Nicolas-Alonso & Gomez-Gil, 2012). Um exemplo, são as redes neurais convolutivas aplicadas em ICMs auditivas para reconhecimento de padrões do som em direções virtuais diferentes (Carabez, Sugi, Nambu, & Wada, 2017).

A análise discriminante linear (LDA), também conhecida como LDA de Fisher, é uma técnica baseada na combinação linear de variáveis discriminantes das características extraídas e permite maximizar a diferença entre os grupos e minimizar as diferenças dentro do grupo (Garcés & Orosco, 2008). Este tipo de classificador tem sido aplicado em ICMs como, multiclass (Garrett, Peterson, Anderson, & Thaut, 2003), P300 *speller* (Krusienski, Sellers, McFarland, Vaughan, & Wolpaw, 2008), no entanto, sua performance não é muito boa, podendo resultar em classificações errôneas na presença de discrepâncias e ruídos fortes (Müller, Anderson, & Birch, 2003).

A máquina de vetor de suportes (SVM) é similar aos classificadores LDA, pois constrói um hiperplano ou um conjunto de hiperplanos para separar os vetores de características em várias classes. No entanto, diferente do LDA, a SVM seleciona hiperplanos que maximizam as margens, ou seja, a distância entre as amostras de treinamento mais próximas e os hiperplanos (Garcés & Orosco, 2008; Nicolas-Alonso & Gomez-Gil, 2012), como ilustrado na Figura 2.6. Este modelo é considerado um classificador simples, com bom desempenho e robusto principalmente em situação em que os vetores de características possuem alta dimensionalidade.




Figura 2.6 – Ilustração do hiperplano ideal para uma SVM (Adaptado de Lotte, Congedo, Lécuyer, Lamarche, & Arnaldi, 2007).

É importante destacar ainda que certos cuidados devem ser tomados em relação à seleção e uso de classificadores. Os pontos centrais a serem observados estão associados a: viés, variação do erro estimado e *overtfitting* (sobre ajuste) (Lemm, Blankertz, Dickhaus, & Müller, 2011). Se um classificador estiver sobre ajustado, ele será superespecializado em classificar os dados de treinamentos ou dados muito semelhantes. Esse fenômeno pode ser evitado amenizando a complexidade do processo de classificação (Lemm et al., 2011). Já a variação do erro estimado pode ser estimada quando se aplica a validação cruzada, onde o algoritmo é testado em um conjunto de dados de validação, que é independente do conjunto de treinamento. Esse procedimento é repetido várias vezes e para várias partições diferentes dos dados (Lemm et al., 2011).

2.7 - Acurácia e taxa de transferência de informações

Boas taxas de transferência de informação (TTI - velocidade de comunicação, dada em bits/min) e acurácia são importantes para que uma ICM se torne um dispositivo prático. A TTI é dada em bits/minuto, e é definida pela equação (Pierce, 2012; Guo et al., 2014):

$$TTI = \frac{(BR \times 60)}{T} \quad (2.1)$$

onde, T é o tempo, em segundos, necessário para seleção da resposta com um determinado número de ensaios (*trials*), e BR é quantidade de bits transmitidos por tentativa dado por (Pierce, 2012; Guo et al., 2014):

$$BR = \log_2 N + P \log_2 P + (1 - P) \log_2 \left(\frac{(1-P)}{(N-1)} \right) \quad (2.2)$$

onde, N é o número de alvos e P a probabilidade de classificação correta.

TTIs mais altas para ICMs com paradigma auditivo podem ser alcançadas através de: (a) aumento da precisão da seleção de alvos por meio da utilização de novas técnicas de detecção e classificação ou novos recursos que facilitem a comunicação entre o usuário e a interface; (b) redução do número de opções para seleção na interface; e (c) redução do tempo para a seleção dos alvos, utilizando paradigmas diferentes ou algoritmos melhores para a detecção da intenção do usuário (Guo et al., 2015; Halder et al., 2010).

Estudos apontam propostas de ICMs auditivas utilizando diferentes paradigmas auditivos, classificadores e estratégias na busca de acurácia e TTI melhores. Hill et al. (2014) obtiveram acurácia média de 77% usando o paradigma auditivo dos potenciais relacionados a eventos N100, N200 e P300, no qual o sujeito devia prestar atenção a uma palavra alvo (sim ou não) em um fluxo de estímulos de palavras não atendidas. Em comparação, fizeram o mesmo teste com 'bip', que por sua vez obteve uma acurácia de aproximadamente 73%; ambos testes utilizaram um classificador por pesos baseado em aprendizado de máquina. Em Halder et al. (2016), usuários finais com deficiência motora aprenderam a controlar um soletrador (*speller*) auditivo usando sons naturais e sinais direcionais com base em potenciais relacionados a eventos. Os dois melhores usuários alcançaram taxas de transferência de informação de 5,78 bits/min e precisão de 92%, aplicando os dados em um classificador baseado na técnica de Análise Discriminante Linear *Stepwise* (SWLDA). Guo et al. (2014) propuseram um paradigma *oddball* auditivo de três estímulos com opções binárias (sim/não), no qual o indivíduo recebia dois alvos com frequências distintas (*oddballs*), e uma série de cinco estímulos sonoros padrão (frequentes), randomizados em sequências de sete estímulos. Os resultados apresentaram um desempenho médio de 87,41% e taxa de transferência de informação de 6,48 bit/min quando as características extraídas da resposta N2ac foram adicionadas às características extraídas dos canais do EEG e os dados foram classificados por uma máquina de vetor de suportes (SVM). Outros estudos mais atuais, baseado em paradigma *oddball* auditivo, relataram uma acurácia média de 80% e TTI de 9,5bit/min com um classificador *Fisher's linear discriminant* (Sugi et al., 2018). Baykara et al. (2016) obtiveram acurácia de 70% e TTI de 5,63 bits/min utilizando a técnica de classificação Análise Discriminante Linear *Stepwise* (SWLDA).

A Tabela 2.1 apresenta um resumo das técnicas descritas anteriormente.

Tabela 2.1 – Acurácia média de classificação (%) e taxa de transferência de informações (bit/min) para diferentes ICM's auditivas.

Referência	Tarefa/Paradigma	Classificador	Acurácia (%)	TTI(bit/min)
Halder et al. (2010)	3 estímulos	SWLDA	78,54	2,46
Guo et al. (2015)	3 estímulos	SVM	87,41	6,48
Baykara et al. (2016)	Speller Auditivo	SWLDA	70,00	5,63
Halder et al. (2016)	Auditivo Espacial	SWLDA	52,80	3,08
Sugi et al. (2018)	Auditivo Espacial	FLD	80,00	9,50

2.8 – Considerações finais

No decorrer deste capítulo foram mencionadas diversas técnicas que podem ser utilizadas para desenvolver unidades de uma interface cérebro máquina. Cada técnica apresenta suas particularidades com vantagens e desvantagens ao serem aplicadas. Observando o diagrama de blocos típico de uma ICM (Figura 2.1) é possível perceber um conjunto de etapas que possuem interdependência entre si, o que pode contribuir para a propagação de erros durante o processo. Além disso, os trabalhos publicados apresentam várias possibilidades e combinações de técnicas de pré-processamento, extração de características e classificação de potenciais relacionados a eventos. A depender das técnicas escolhidas, o tempo de processamento pode aumentar consideravelmente com o aumento do número de amostras, com o consequente aumento do custo computacional. Tais elementos devem ser observados com cuidado quando se busca desenvolver ICMs para aplicações clínicas. Nestas, o tempo de processamento e a facilidade de aplicação dos algoritmos para sistemas embarcados são abordagens desejadas, em conformidade com as condições de cada sujeito.

Uma alternativa para os problemas apontados, seria uma definição de uma metodologia mais simplificada e passível de ser aplicada em sistemas *online*. Como descrito anteriormente, este trabalho apresenta uma proposta neste sentido, por meio de um *framework* baseado na técnica de banco filtros casados, onde cada filtro é preparado para detectar a presença do potencial evocado de um dado alvo e posteriormente classificá-lo de acordo com as intenções do usuário. Esse sistema poderia permitir a decodificação de PREs com dependência de poucas características do sinal, sem ajustes finos, abrindo caminho para o uso de algoritmos de controle de ICMs em sistemas embarcados.

Capítulo 3 - Filtros Casados

Filtros casados são muito utilizados em sistemas de radar e sonar (Levanon, 2004, p. 24) e sistemas de comunicação digital (Haykin, 2001, p. 248). Sistemas de radares são caracterizados por um transceptor (transmissor/receptor) que gera e transmite pulsos sinusoidais na faixa de frequência de micro-ondas. O sinal viaja à velocidade da luz e é refletido quando encontra um objeto em seu caminho (Figura 3.1). O transceptor recebe o eco do sinal que se apresenta atenuado e acrescido de ruídos provenientes do canal de propagação (Vaseghi, 2007). Neste contexto, os filtros casados são usados para detecção do sinal transmitido misturado com ruído e assim, pode-se julgar a distância do objeto e sua velocidade.




Figura 3.1 – Ilustração de um sistema típico de radar (Adaptado de Encyclopédia Britannica).

Em sistemas de comunicação, mensagens binárias são enviadas do transmissor para o receptor através de um canal ruidoso, e o filtro casado é utilizado para detecção de pulsos transmitidos em meio ao sinal ruidoso recebido (Haykin, 2001). A Figura 3.2 ilustra o processo mencionado. Um sinal binário (Figura 3.2(a)) é transmitido por um canal. Ao trafegar pelo canal, o sinal é contaminado por um ruído (Figura 3.2(b)). No receptor, o sinal acrescido de ruído passa por um filtro casado e a sua saída é enviada a um amostrador (Figura 3.2(c)). Um limiar é utilizado para verificar a hipótese da presença ou não de um símbolo (bit) de interesse no sinal recebido. Valores acima do limiar são considerados como sendo o valor binário '1', caso contrário serão considerados como '0'. É ainda comum, em sistemas de comunicação, a

utilização de mais de um filtro em paralelo para detecção de dois ou mais símbolos (Mohamed et al, 2015).

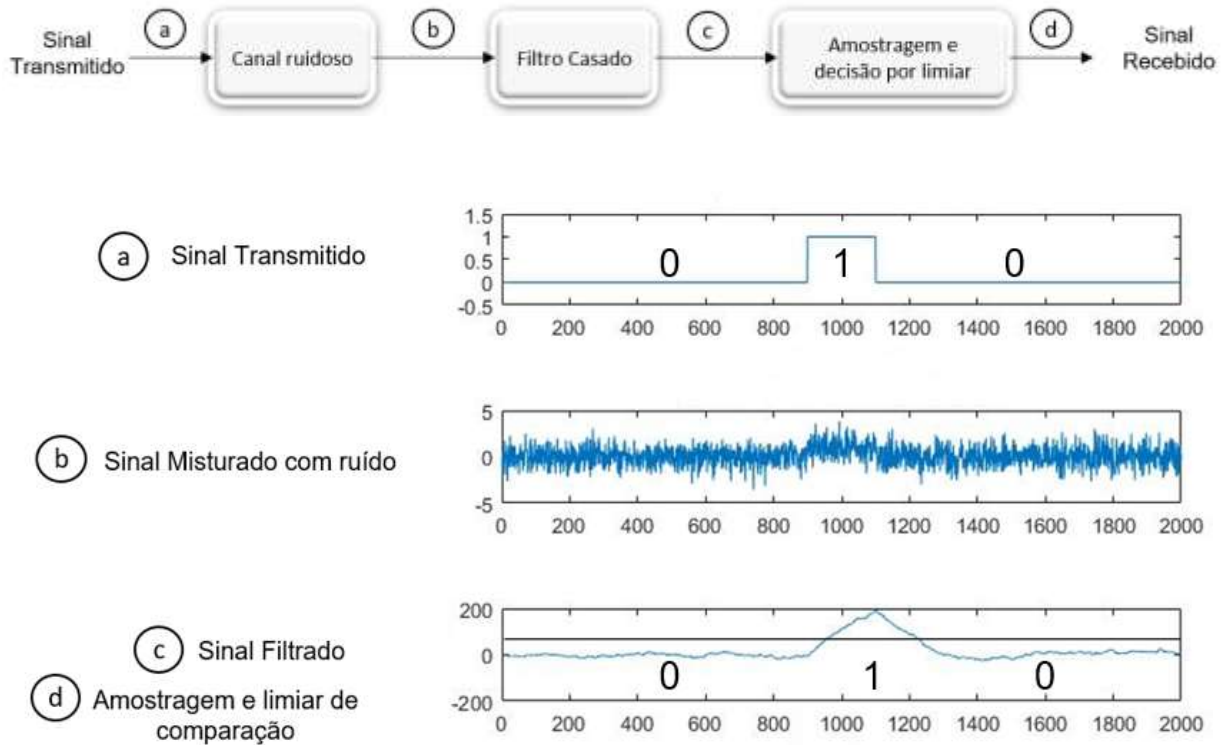


Figura 3.2 - Diagrama de blocos e ilustração da detecção de pulso em um sistema de comunicação binário utilizando filtros casados.

3.1 - Definição de filtros casados

O principal objetivo do filtro casado é a detecção de um sinal conhecido na presença de um ruído gaussiano (Haykin, 2001). Conforme a Figura 3.3, considerando um sinal de entrada do filtro $x(t)$, que consiste no pulso do sinal previamente conhecido $g(t)$ contaminado por um ruído gaussiano branco $w(t)$, $x(t)$ pode ser modelado segundo a Equação 3.1, sendo T um intervalo de observação do sinal:

$$x(t) = g(t) + w(t), \quad 0 \leq t \leq T \quad (3.1)$$

A função do filtro é detectar o pulso $g(t)$ de maneira otimizada dado o sinal recebido $x(t)$. O filtro é definido como um filtro linear e invariante no tempo cuja resposta ao impulso é

dada por $h(t)$ (Equação 3.2). A definição matemática para $h(t)$ pode ser encontrada de forma detalhada em (Haykin, 2001).

$$h = kg(T - t) \quad (3.2)$$

Portanto, um filtro casado possui a resposta ao impulso proporcional ao sinal de entrada ($g(t)$), invertido e deslocado no tempo; k é uma constante real que se comporta como um ganho. A Figura 3.4 mostra como pode ser obtida a resposta ao impulso $h(t)$ de um filtro casado para uma dada forma de onda. Primeiramente invertendo a forma de onda no tempo (Figura 3.4(b)) e depois aplicando um deslocamento e um ganho (k) ao sinal (Figura 3.4(c)).

Por definição, a saída de um filtro casado para um sinal de entrada $x(t)$, composto pela forma de onda conhecida $g(t)$ e por um ruído gaussiano, pode ser descrita como sendo a convolução de $x(t)$ com a resposta ao impulso do filtro $h(t)$ (Equação 3.3) (Levanon & Mozeson, 2004).

$$y(t) = x(t) * h(t) = \int_{-\infty}^{\infty} x(\tau)h(t - \tau) d\tau = \int_{-\infty}^{\infty} x(\tau)kg[T - (t - \tau)] d\tau \quad (3.3)$$

onde ‘*’ representa a convolução.

Considerando o caso onde $k=1$ e $T=0$ podemos simplificar a Equação 3.3 como:

$$y(t) = \int_{-\infty}^{\infty} x(\tau)g(\tau - t) d\tau \quad (3.4)$$



Figura 3.3 – Modelo base de um filtro casado (Adaptado de Lavanon & Mozeson).

A resposta ao impulso pode ser utilizada para filtrar um sinal. Ao realizar a convolução de um sinal de entrada com a resposta ao impulso de um sistema linear a invariante no tempo, temos a saída do sistema. Essa operação é simples de ser implementada em sistemas de processamento digital (Nodovich, 2004).




Figura 3.4 – Ilustração da resposta ao impulso do filtro casado (Levanon & Mozeson, 2004).

3.2 - Características e propriedades dos filtros casados

Primeiramente, precisamos entender o significado da saída de um filtro casado. O filtro casado é um sistema ótimo para detectar um sinal conhecido contaminado por ruído gaussiano (Haykin, 2001). Além disso, é um sistema que maximiza a relação sinal-ruído em um dado instante de tempo (T). Logo, a saída do filtro casado é proporcional à relação sinal ruído da entrada.

Se houver um sinal de entrada cujo pulso conhecido está presente, a relação sinal ruído será alta até atingir uma amplitude máxima, ou seja, a saída do filtro irá aumentar e gerar um pico. No entanto, na ausência do sinal associado $g(t)$, a saída do filtro corresponde a um ruído de baixa amplitude.

Uma característica da saída do filtro que pode ser observada através da Equação (3.4), é a correlação cruzada entre os sinais $x(t)$ com $g(t)$. Em outras palavras, a Equação 3.4, nos permite concluir que a resposta de saída do filtro casado é relacionada com a correlação cruzada do sinal de entrada e o sinal que originou o filtro (Levanon & Mozeson, 2004). Se considerarmos que a correlação cruzada é uma ferramenta que permite detectar a similaridade entre duas formas de onda, podemos concluir que um filtro casado é um sistema cuja saída

mede o grau de similaridade entre duas formas de onda. A saída máxima dos filtros é dada pela Equação 3.5:

$$\eta_{max} = \frac{2E}{N_0} \quad (3.5)$$

Onde E corresponde a energia do sinal que originou o filtro casado e N_0 é a densidade espectral de potencial do ruído branco.

A Equação 3.5 indica o valor máximo da saída de um filtro casado e mostra que a relação sinal-ruído de saída do filtro depende somente da relação da energia do sinal pela densidade espectral de potência do ruído branco na entrada do filtro (Haykin, 2001). Uma propriedade importante de ser observada também é que não existe nenhum tipo de dependência da forma de onda, duração e largura com o espectro do sinal de entrada (Turin, 1960).

3.3 - Exemplo de aplicação

O exemplo a seguir apresenta de forma mais clara e simples uma aplicação dos filtros casados. A Figura 3.5a apresenta um sinal de entrada com um pulso retangular $g(t)$ de amplitude A e duração T . Para esta situação, a resposta ao impulso $h(t)$ do filtro casado apresenta a mesma forma de onda, porém com a possibilidade de uma amplitude variável KA .

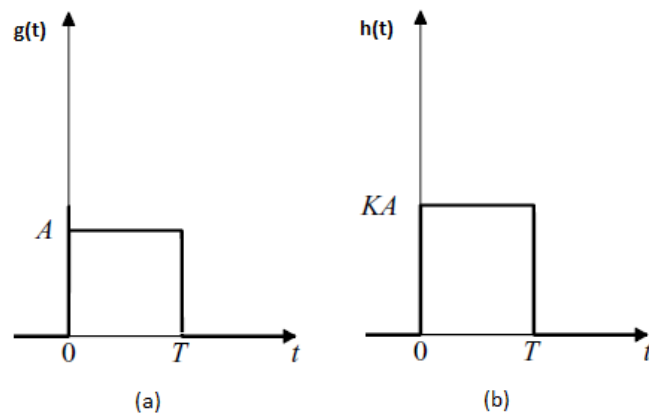


Figura 3.5 – (a) Pulso retangular $g(t)$ e (b) a resposta ao impulso $h(t)$ do filtro casado.

Se considerarmos apenas o sinal $g(t)$ sendo aplicado ao filtro casado, é possível obter a saída $g_0(t)$ deste através da convolução entre $g(t)$ e $h(t)$, que conforme observado na Figura 3.6, resulta em uma forma de onda triangular.




Figura 3.6 – Sinal de saída do filtro casado.

Observe que, nesse caso, a energia do sinal é:

$$E = \int_{-\infty}^{\infty} |g(t)|^2 dt = \int_0^T A^2 dt = A^2 T \quad (3.6)$$

Logo, o valor máximo na saída do filtro $g_0(t)$ referente ao sinal $g(t)$ é dado por:

$$g_0(t) = kA^2T = kE \quad (3.7)$$

Para determinar a relação sinal ruído no instante T , precisamos da média do valor quadrático do ruído, dado por:

$$\overline{n_0^2} = \frac{N_0}{2} \int_{-\infty}^{\infty} |H(f)|^2 df = \frac{N_0}{2} \int_{-\infty}^{\infty} |h(t)|^2 dt = \frac{N_0}{2} \int_0^T |kA|^2 dt = \frac{N_0}{2} k^2 A^2 T \quad (3.8)$$

Assim que a relação sinal ruído no tempo T pode ser obtida da seguinte forma:

$$\eta = \frac{g_0^2(t)}{n_0^2} = \frac{(KA^2T^2)}{(N_0/2)k^2A^2T} = \frac{2A^2T}{N_0} = \frac{2E}{N_0} \quad (3.9)$$

3.4 - Contextualização e considerações sobre a aplicação de filtros casados na detecção e classificação de PRE's

Depois de abordar o conceito, as características e as propriedades dos filtros casados, discorreremos sobre alguns estudos realizados aplicando a técnica para classificação de biopotenciais.

Siqueira & Soares (2015), propuseram uma nova metodologia para decomposição de sinais EMG baseada na técnica de filtros casados. O método foi implementado em quatro etapas: banco de filtros casados, detector de pico, classificador de unidade motora e módulo de resolução de sobreposições de unidades motoras. Cada filtro foi projetado conforme a forma de onda de cada unidade motora a ser detectada. A validação do método foi feita por meio de sinais EMG simulados e sinais reais. Os resultados referentes aos dados simulados apresentaram que a decomposição de unidades motoras sem sobreposição e com uma relação sinal ruído de 10 dB pode ser alcançada com até 99% de acurácia. Já para a sobreposição de 10 unidades motoras por sinal, com SNR de 20 dB, pode ser classificada corretamente em 71% das unidades motoras. Foi possível observar a eficiência do método de forma que, toda aplicação foi realizada um computador desktop padrão e proporcionou um algoritmo rápido e com altas taxas de sucesso. Podemos observar no trabalho proposto por Siqueira & Soares (2015), um método com aplicação de um banco de filtros casados atuando de modo simultâneo e paralelo a fim de classificar diferentes unidades motoras, o que contribuiu para melhoria de desempenho do sistema.

Em outro estudo utilizando filtros casados, Lafuente et al. (2017) apresentaram uma abordagem não supervisionada para extração de ondas cerebrais P300 a partir de sinais EEG. Foi feita a combinação de diferentes métodos: cancelamento de artefatos, pré-classificação usando seleção de janelas e análise contextual de dados, filtros casados, correlação e normalização da P300 com a saída dos filtros e classificador baseado em uma pontuação ponderada. O filtro casado foi projetado com a resposta P300 é obtida pela a média de todos os sinais marcados como resposta EEG de um estímulo alvo. A validação do método foi feita a partir de dados reais de EEG durante paradigma visual. Os resultados deste estudo mostraram até 92% de acurácia. O trabalho de Lafuente et al. (2017) aponta uma aplicação dos filtros casados juntamente com uma modelagem matemática baseada em uma função de log-verossimilhança para extração da onda P300. Neste caso, o filtro casado procura pela forma de onda conhecida ajustando automaticamente seu tempo de ocorrência, a amplitude e a duração. Por mais que o proposta deste método apresente uma performance alta, o processamento do sinal até ser classificado consiste em várias etapas para extrair e ajustar características utilizando medidas estatísticas a fim de melhorar os resultados. Além disso, a técnica utiliza apenas dois eletrodos de EEG, o que possui a vantagem de baixa dimensionalidade dos dados, porém limita a análise de características particulares das respostas evocadas em regiões diversas, impedindo análises de respostas mais globais. A proposta também foi definida apenas para o paradigma visual, o que impede sua utilização por indivíduos em estágios avançados de

ELA, com movimento ocular comprometido (Murguialday et al., 2011). Numa tentativa de minimizar estes problemas, outros estudos foram desenvolvidos utilizando paradigmas modificados com modalidades sensoriais alternativas, como a percepção auditiva (Halder et al., 2010; Käthner et al., 2013; Erlbeck et al., 2017).

Capítulo 4 - Proposta de um *framework* para detecção e classificação de PREs

Neste capítulo abordaremos a proposta de aplicação da técnica dos filtros casados para a detecção e classificação de PREs, em paradigma *oddball* auditivo. Além disso, apresentaremos a metodologia a ser aplicada para validação do *framework* desenvolvido.

4.1 - Detector de PREs usando filtros casados

De acordo com Turin (1960) e Haykin (2001), um dos pontos principais dos filtros casados consiste na detecção da presença de um pulso conhecido em meio a um ruído branco. Para o contexto de sinais provenientes da atividade cerebral, $x(t)$ consiste no sinal EEG resultante da resposta evocada do cérebro (PRE) dado um estímulo externo $s(t)$ somada à atividade de encefálica de background $n(t)$. Quando $x(t)$ é inserido em um filtro casado $h(t)$, a resposta da convolução $y(t)$ pode ocorrer de duas formas (Figura 4.1): (a) no caso do sinal $x(t)$ possuir apenas a componente natural do EEG $n(t)$ (atividade background de EEG), temos uma resposta do filtro com oscilações baixas; (b) no entanto, quando o sinal $x(t)$ contém a resposta evocada $s(t)$ misturada à atividade de background $n(t)$, a saída do filtro apresenta um pico da convolução no instante t_0 .




Figura 4.1 – Diagrama de blocos de um detector de PREs baseado em filtros casados.

A saída (a) ocorre quando é aplicado um sinal $x(t)$ formado apenas pela atividade de background EEG $n(t)$. A saída (b) ocorre quando um sinal $x(t)$ é composto pelo PRE $s(t)$ e a atividade de background $n(t)$.

Geralmente, os PREs não são facilmente detectados em testes (estímulos) individuais, pois estão acontecendo outros processos, simultaneamente, no cérebro que refletem no EEG. Por essa razão normalmente os PREs são representados como a forma de onda média das épocas de vários testes (Figura 4.2a). Sendo assim, o *template* de cada filtro é projetado com o PRE médio para um dado estímulo em um canal EEG (Figura 4.2b), invertido no tempo e deslocado de T (Figura 4.2c).

Assim, se conhecemos a forma de onda média dos PREs relacionados a um estímulo específico $s(t)$, é possível definir um filtro casado cuja a resposta ao impulso $h(t)$ e pode ser expressa pela Equação 3.2 (Capítulo 3).

Na Figura 4.2c, o sinal referente a resposta ao impulso do filtro $h(t)$ pode ser delimitado em uma janela apenas para as formas de onda de interesse, evitando assim detecção de ruídos e conteúdos desnecessários. Neste caso, foi definido $k=1$ (que é uma constante real que se comporta como um ganho) e a constante $T = 300$ ms equivalente à largura do pulso do PRE (dentro da janela de tempo da época - 150 a 450 ms pós estímulo).




Figura 4.2 – (a) Em cinza tem a representação de várias épocas para um canal EEG e em vermelho o PRE médio dessas épocas; (b) o PRE médio de todas as épocas, que é o sinal desejado $s(t)$; (c) a resposta ao impulso $h(t)$ do filtro casado invertida no tempo, de acordo com a definição; contendo apenas as formas de onda de interesse N200 e P300, neste caso.

4.2 Classificação de PREs utilizando filtros casados

Outra aplicação importante para a técnica de filtros casados é a classificação dos pulsos transmitidos entre agrupamentos similares. Um exemplo dessa aplicação são os receptores M-ários utilizados em sistemas de comunicação para classificação de pulsos recebidos. No receptor M-ário, cada M símbolo, ou mensagem é representado por uma forma de onda específica. A forma de onda é transmitida em um dado tempo T , e é corrompida por ruídos no canal de transmissão. Conhecida a forma de onda, o receptor decide que forma de onda foi transmitida com uso dos filtros casados (Lathi & Ding, 2009), como mostrado no diagrama de blocos da Figura 4.3. Como se nota, as saídas dos filtros casados são acrescidas por um valor de *bias* a_i . O *bias* é definido para cada filtro. Este é um elemento importante pois cada filtro responde a um pulso/símbolo específico. A decisão sobre qual símbolo foi recebido é tomada em favor do maior valor b_i (saída do filtro após a adição do *bias*).

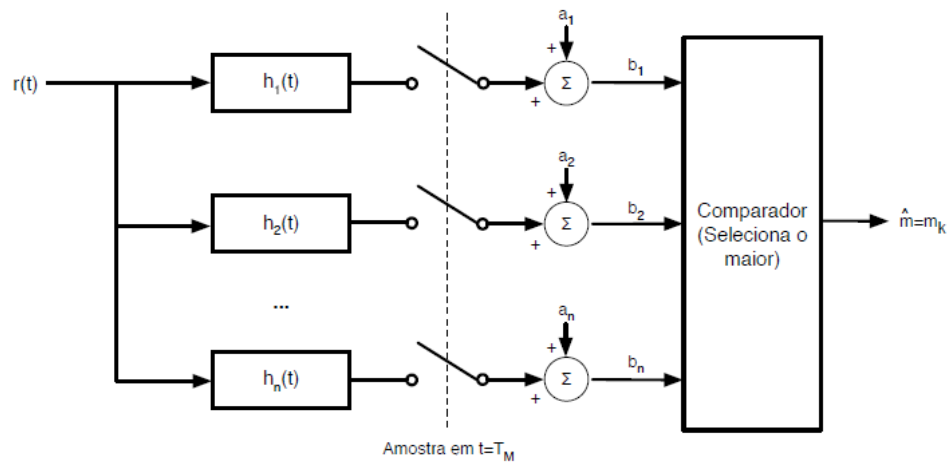


Figura 4.3 – Diagrama de blocos de um receptor M-ário (Adaptado de Lathi & Ding, 2009).

A equação 4.2 define o cálculo do *bias* para um pulso i , sendo N_0 um valor constante que define o espectro do ruído branco, $P(m_i)$ a probabilidade de ocorrência do impulso do filtro no sinal, e E_i a energia associada a cada do filtro (Lathi & Ding, 2009).

$$a_i = \frac{1}{2} [N_0 \times \ln(P(m_i)) - E_i] \quad (4.2)$$

Quando a probabilidade de ocorrência dos símbolos é igual, o termo $N_{0 \times} \ln(P(m_i))$ passa a ser constante para todos os símbolos, logo, a equação (4.2) pode ser simplificada de acordo com a equação (4.3):

$$a_i = -\frac{Ei}{2} \quad (4.3)$$

A Figura 4.4 apresenta um exemplo de saída utilizando sinais EEG. O sinal EEG composto por um PRE para um determinado alvo A (Figura 4.4(a)), e foi aplicado a um banco de filtros casados com dois filtros (cada um corresponde a um alvo diferente), e um valor de *bias* foi adicionado à saída dos filtros, conforme Equação 4.3. A Figura 4.4(b) representa a saída dos dois filtros. Como é possível observar, as saídas dos filtros respondem com picos suaves inicialmente, porém o filtro que corresponde a entrada da Figura 4.4(a) terá uma resposta maior que os demais no instante em que o PRE associado àquele filtro estiver presente no sinal EEG.




Figura 4.4 – Exemplo de sinais associados às etapas de um sistema M-ário para classificação de PREs via filtros casados: (a) sinal de entrada, composto de um PRE; (b) saída do banco de filtros casados.

Através dessa análise e baseando-se na ideia de classificação dos receptores M-ários (Figura 4.3), temos indícios que os filtros casados possuem potencial para detectar e classificar PREs em sinais EEG. As seções a seguir detalham o método completo proposto.

4.3 - O *framework* completo

A Figura 4.5 ilustra a abordagem geral da proposta. Como destacado anteriormente, o sistema tem por objetivo detectar e classificar PREs associados a estímulos auditivos em um sistema de comunicação alternativa baseado no paradigma *oddball*, que permita ao sujeito responder a questões de respostas binárias (sim ou não). Neste sistema, três tipos de estímulos auditivos, intercalados aleatoriamente, são apresentados, por exemplo, via fones de ouvido:

- Um pacote de n estímulos (ruído branco) nas duas orelhas simultaneamente (estéreo);
- Um único estímulo A, de frequência f_A é apresentado unicamente na orelha esquerda (por exemplo) - alvo A;
- Um único estímulo B, de frequência f_B é apresentado unicamente na orelha direita (por exemplo) - alvo B;
- A quantidade de estímulos frequentes (ruído branco) é definida pelo protocolo (por exemplo, cinco – neste caso um ensaio (*trial*) conteria 7 estímulos – 5 frequentes e dois (A e B) não frequentes);
- A duração dos estímulos é definida por cada protocolo (por exemplo, 100ms);
- O intervalo entre estímulos é definido pelo protocolo (por exemplo, aleatoriamente entre 400 a 800 ms).

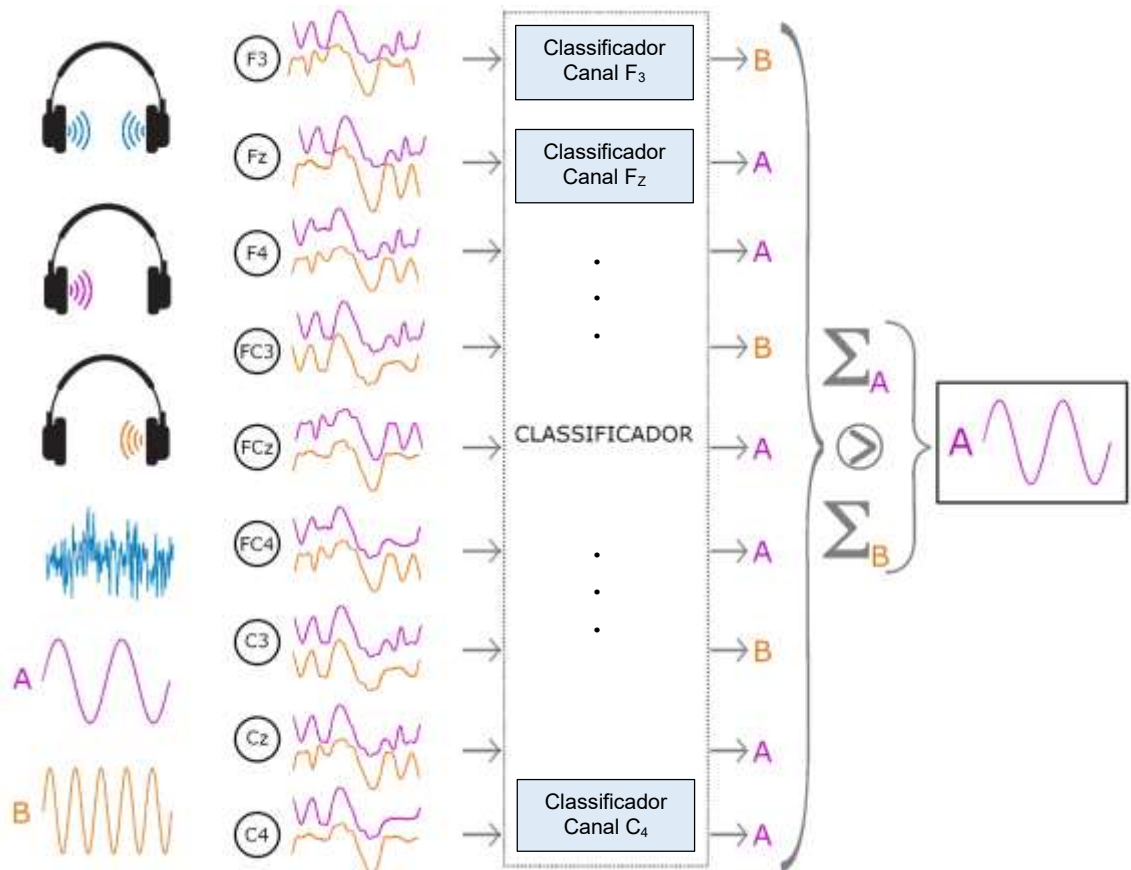


Figura 4.5 – Abordagem geral da proposta: Sinais auditivos são apresentados ao sujeito; as épocas associadas a cada estímulo, para cada canal EEG (aqui neste exemplo são representados canais das áreas centrais, mais associadas às respostas corticais (PREs) após estímulos auditivos) são coletadas e, enviadas ao classificador baseado em filtros casados, que deverá indicar em qual dos estímulos o sujeito está mais focado.

Como o objetivo da ICM seria, por exemplo, permitir que uma dada pergunta seja feita oralmente ao sujeito (por exemplo, “você está com sede?”). Neste sistema, imediatamente após a pergunta, inicia-se uma sequência de m ensaios, cada um enviando, no nosso exemplo, sete estímulos auditivos. Caso o sujeito deseje responder “sim” ele deve focar no estímulo A e ignorar todos os demais. Caso o sujeito deseje responder “não” ele deve focar no estímulo B e ignorar todos os demais.

Como sabemos, a onda P300 da época coletada logo após um estímulo tem sua amplitude aumentada caso o sujeito esteja prestando atenção no mesmo. E ainda, a forma de onda da P300 também será distinta. Então, se antes de iniciarmos o uso da ICM, realizarmos diversos ensaios pedindo ao sujeito para focar sua atenção apenas no estímulo A (ou B), podemos compor uma época (promediada dos vários ensaios) que represente a atividade

cerebral do indivíduo quando o mesmo presta atenção no estímulo A (ou B). Estas épocas seriam então as funções $h(t)$ de nossos filtros casados para um dado canal EEG ($h_A(t)$ - resposta “sim”; $h_B(t)$ - resposta “não”).

No entanto, caso nosso sistema se restringisse a avaliar PREs associados a um único canal EEG, sua acurácia seria muito baixa. Isto se dá devido à extrema variabilidade dos sinais EEG e suas respostas à estímulos individuais. Para minimizar tais erros, em nosso *framework* propomos uma estratégia em que todos os canais de interesse seriam avaliados paralelamente. Ou seja, o processo de geração dos *templates* $h_A(t)$ e $h_B(t)$ é replicado para todos os canais, formando assim, um banco de filtros casados.

Nosso classificador teria então o objetivo de avaliar os PREs de todos os canais, combinar suas respostas (A ou B) e, por fim, indicar em qual estímulo não frequente (*oddball*) o sujeito estaria mais concentrado (Alvo A ou Alvo B).

A Figura 4.6 detalha, para um dado canal EEG, o diagrama de blocos proposto para classificação dos PREs de cada Alvo A ou B.

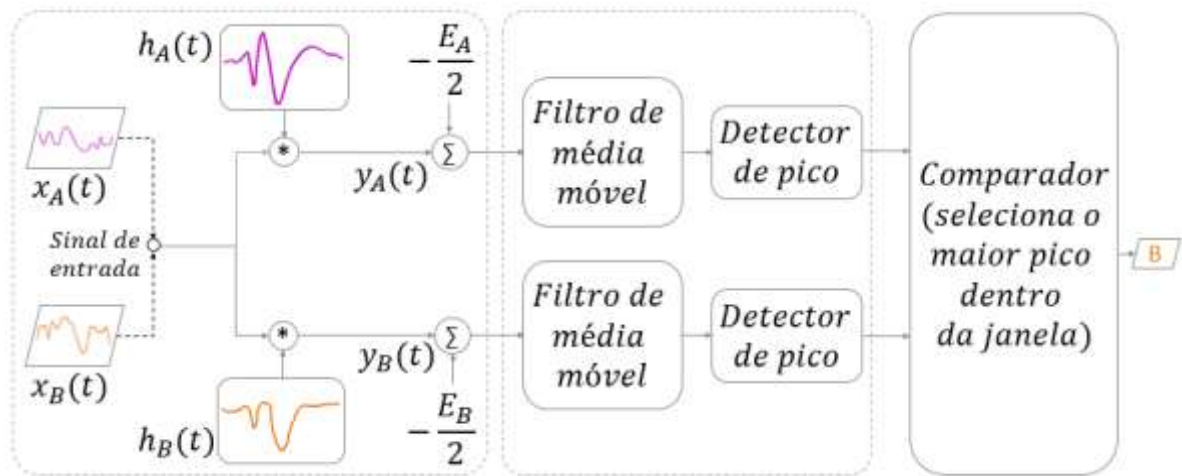


Figura 4.6 – Diagrama de blocos da estrutura de classificação de PREs para um canal EEG.

Conforme descrito, os PREs associados aos alvos A e B são enviados sequencialmente aos filtros casados de cada alvo. As saídas dos filtros são somadas a um valor *bias*, conforme explicado na seção anterior. Em seguida, o sinal passa por um filtro de média móvel de ordem 3 para suavizar oscilações de alta frequência e assim minimizar os erros de falsos positivos. Um detector de máximos locais é incluído na saída de cada filtro – este detector indica o instante de máxima correlação da época (PRE) com o *template* do filtro ($h(t)$). Nesta etapa de detecção de pico, a avaliação é realizada em uma janela de análise entre 150 a 450 ms após a apresentação

do estímulo (região da época contendo a onda P300). Uma vez que um ensaio é completado e os máximos associados aos dois PREs Alvo (A e B) são obtidos, estes são enviados a um comparador. O maior dos máximos indica então o PRE (alvo) que possui maior correlação com os *templates* ($h_A(t)$ ou $h_B(t)$) dos filtros do canal (ou seja, em qual dos dois estímulos o sujeito teria prestado mais atenção). A Figura 4.7 ilustra este processo com sinais EEG reais.




Figura 4.7 - Sinais associado às etapas do sistema de classificação: (a) sinal de entrada – composto de um PRE. (b) saída do banco de filtros; a curva roxa representa a janela de análise dos picos e o círculo representa a saída do filtro que superou as demais amplitudes

Finalmente, conforme se nota na Figura 4.5, as respostas dos classificadores de todos os canais devem ser combinadas para definir a resposta final (em que estímulo o sujeito estaria mais concentrado). Para isso, e após avaliar diversas estratégias, optou-se por um mecanismo de voto ponderado. Nesta, as amplitudes de todos os canais que votam em A (ou B) são somadas. A resposta final do sistema é então aquela de maior resultado.

4.4 – Estratégia de validação

Para validar o método proposto, utilizamos sinais EEG gerados por meio de um simulador desenvolvido para tal e, posteriormente, foram feitos testes utilizando um banco de dados EEG reais em sujeitos saudáveis.

4.4.1 - Sinais EEG semissintéticos

Um simulador de sinais EEG foi construído baseando-se na técnica proposta por Lopes-dos-Santos et al. (2018).

As formas de onda dos potenciais relacionados a eventos foram criadas a partir da soma de três funções gaussianas simulando P100, N200 e P300, que são modeladas conforme a Equação 4.4.

$$p(t) = a \cdot e^{\frac{-(t-c)^2}{2\sigma^2}} \quad (4.4)$$

onde c é a latência do PRE que inclui um deslocamento aleatório para simular o *jitter*; σ é a largura do ERP; e a é a amplitude e deflexão do sinal.

Para cada ensaio, os componentes gaussianos foram gerados com um *jitter* aleatório (± 5 ms, uniformemente distribuídos) e adicionado atividade de background de um registro de EEG real em estado de repouso, a fim de conservar características dos sinais reais (Equação 4.5) (Guo et al., 2014).

$$T(t) = (\sum_{i=1}^n p_i(t)) + b(t) \quad (4.5)$$

onde $T(t)$ é a forma de onda de um ensaio, $p(t)$ é a forma de onda do PRE (Equação 4.4); $b(t)$ é a atividade de EEG em segundo plano.

O simulador construído (Spirandeli et al. 2018), permite ao operador definir os parâmetros de amplitude, latência, largura de onda (desvio padrão) e deflexão da onda (positiva ou negativa) das gaussianas, além disso, o número de ensaios (*trials*) contendo o PRE e o valor da relação sinal ruído. Como os parâmetros citados variam de acordo com a resposta evocada do cérebro para cada sujeito, foram simulados 4 conjuntos de dados com parâmetros distintos extraídos de um banco de dados reais (Guo et al., 2014), a fim de simular diferentes sujeitos. A extração dos parâmetros de cada indivíduo foi feita por um sistema onde a entrada foi o PRE

médio do sinal real (Figura 4.8 - curva azul) de um canal e através de uma função de ajuste de curva foi possível obter os padrões finais (Figura 4.8 – curva vermelha).




Figura 4.8 – Exemplo da geração de PREs semissintéticos. A curva azul representa o PRE real do canal Fcz para um indivíduo. Por ajuste de curvas obtém-se o modelo de PRE para entrada do simulador (curva vermelha).

Para cada estímulo, foram simulados 40 ensaios individuais. Para validação dos métodos, foram criados 3 grupos para verificar o seu desempenho, levando em conta alterações na relação sinal ruído (RSR) entre o potencial de interesse e a atividade background do EEG, considerando uma taxa de amostragem de 1000 Hz:

- **G1:** Sinais com a relação sinal-ruído de 200dB.
- **G2:** Sinais com a relação sinal-ruído de 20dB.
- **G3:** Sinais com a relação sinal-ruído de 10dB

E ainda, para cada grupo, foram gerados quatro conjuntos de sinais simulados (conforme mencionado), a partir da atividade EEG de sinais reais de quatro sujeitos distintos:

- **GiS1:** Parâmetros do simulador extraídos dos PREs reais (banco de dados) do sujeito 1 prestando nos alvos A e B (dois PREs simulados); Atividade EEG de background: sujeito 1 em repouso.
- **GiS2:** Parâmetros do simulador extraídos dos PREs reais (banco de dados) do sujeito 2 prestando nos alvos A e B (dois PREs simulados); Atividade EEG de background: sujeito 1 em repouso.

- GiS3: Parâmetros do simulador extraídos dos PREs reais (banco de dados) do sujeito 3 prestando nos alvos A e B (dois PREs simulados); Atividade EEG de background: sujeito 1 em repouso.
- GiS4: Parâmetros do simulador extraídos dos PREs reais (banco de dados) do sujeito 4 prestando nos alvos A e B (dois PREs simulados); Atividade EEG de background: sujeito 1 em repouso.

4.4.2 - Sinais EEG reais

Os sinais de EEG utilizados neste estudo foram obtidos de um banco de dados fornecido por Guo et al. (2014), que investigaram a influência da resposta N2ac PRE no desempenho de uma ICM com paradigma *oddball* auditivo. Neste trabalho, os autores contaram com a participação de 10 voluntários saudáveis que foram posicionados sentados, confortavelmente, em uma cadeira utilizando uma touca de EEG de 32 eletrodos (Ag/AgCl). Os voluntários usavam fones de ouvido e foram orientados a manter os olhos fechados e evitar movimentos oculares durante o experimento. Os sujeitos da pesquisa receberam perguntas simples de “sim ou não” (“A bola de futebol é redonda?”, “O céu é verde?”) que foram sorteadas antes da gravação do EEG. A resposta dos indivíduos à questão determinou o alvo em que deveriam prestar atenção (se "sim", atender ao alvo A, se "não", atender ao alvo B).

Foi realizada 1 tarefa para cada indivíduo, diferenciando apenas as frequências dos estímulos apresentados. A tarefa consistiu em 20 repetições, sendo que, em cada repetição (ensaio) sete estímulos foram apresentados ao indivíduo: cinco pulsos de ruído branco reproduzidos em estéreo binaural; um pulso 100 Hz de som mono tocado na orelha esquerda (alvo A); e um pulso de 4000 Hz som mono na orelha direita (alvo B). Cada estímulo teve duração de 100 ms, com intensidade ajustada para 75dB (nível de pressão sonora). A tarefa foi realizada duas vezes, respondendo a uma pergunta de cada vez, com as duas perguntas exigindo respostas diferentes.

Os intervalos entre estímulos foram randomizados entre 400 ms e 800 ms. Neste estudo, os dados de EEG foram obtidos dos eletrodos F3, F4, F4, C3, C4, FC3, FC4, FC4 (referência em M1 e M2 e aterramento em AFz), com a frequência de amostragem em 1000 Hz (Guo et al., 2014).

4.4.2.1 - Pré-processamento

Antes de qualquer processamento, os dados brutos de EEG foram filtrados para remoção de tendências lineares. Posteriormente um filtro passa-faixa digital *butterworth* (6 polos para o passa-alta e 10 polos no passa-baixa, com as frequências de corte entre 2 Hz e 10 Hz, respectivamente). Apesar dos experimentos terem sido realizados com os indivíduos com os olhos fechados, pequenos movimentos oculares ainda podem comprometer os sinais EEG. Para avaliar a ocorrência dos mesmos e permitir sua remoção, foram gravados simultaneamente com o EEG os sinais eletroculográficos (EOG) verticais e horizontais. Para remoção de artefatos oculares todas as épocas passaram por uma inspeção visual. As que apresentaram artefatos visualmente excessivos foram eliminadas do conjunto de dados. Posteriormente, foi ainda estabelecido um limiar de $\pm 50 \mu V$ para validar cada época, e caso alguma excedesse esse nível seria eliminada (Moretti et al., 2003).

4.4.2.2 - Resposta N2ac

A resposta N2ac foi investigada por Gamble e Luck (2011), e se trata de uma componente de atenção seletiva apontando uma negatividade na faixa de latência N2 nos eletrodos contralaterais anteriores sempre que se é apresentado um estímulo auditivo. Guo et al. (2014) demonstraram também um desempenho melhor do classificador de uma ICM auditiva, com a utilização da resposta N2ac.

O cálculo da componente N2ac é dado pelas Equações (4.4) e (4.5). A resposta dos eletrodos ipsilaterais anteriores é subtraída das respostas dos eletrodos contralaterais anteriores. Assim:

- Para o alvo A (canal de áudio esquerdo)

$$N2acA = [(F4 + FC4 + C4) - (F3 + FC3 + C3)] \quad (4.4)$$

- Para o alvo B (canal de áudio direito)

$$N2acB = [(F3 + FC3 + C3) - (F4 + FC4 + C4)] \quad (4.5)$$

4.4.2.3 - Segmentação do sinal

Depois do pré-processamentos, o sinal de EEG foi segmentado em janelas de 1 segundo, extraídas 200 ms antes do início dos estímulos até 800 ms após seu início, para cada canal. Após a segmentação, foi realizado o referenciamento das épocas em relação a linha de base do pré-estímulo. Uma vez que existiam vinte repetições por tarefa, as épocas utilizadas para testar e treinar o classificador de PREs foram extraídas dos estímulos raros (Alvo A, Alvo B), ou seja, 40 épocas por pergunta. Também foram utilizadas as épocas extraídas dos sinais N2acA e N2acB que foram alvos de investigação buscando a melhoria da performance do sistema.

4.4.2.4 - Decomposição em modo empírico

A decomposição em modo empírico (EMD), é uma técnica não-linear que busca decompor uma série temporal em componentes individuais, que são denominados de funções de modo intrínseco (IMF). As IMFs representam oscilações intrínsecas no sinal em si, que, por definição, são funções com o mesmo número de extremos e cruzamentos por zero, com seus envelopes sendo simétricos em relação a zero (Labate et al., 2013; Huang et al., 1998).

A EMD foi utilizada neste trabalho para realizar uma filtragem refinada do sinal de EEG buscando melhorar a relação sinal ruído do EEG e aumentar o desempenho do sistema. A técnica foi aplicada em todas as 40 épocas de cada pergunta, resultando em um grupo de IMFs por época. Para se avaliar qual IMF melhor representaria as características do sinal, foi calculado o coeficiente de correlação cruzada entre cada IMF e o sinal de EEG correspondente que gerou a época. Logo, a IMF com maior coeficiente foi escolhida como a melhor componente para representar aquela época. Resultando então 40 IMFs, uma para cada época de estímulo.

4.5 - Experimentos de validação

4.5.1 – Sinais EEG semissintéticos

Para cada grupo de sinais simulados, com cada uma das distintas relações sinal-ruído (G1: 200dB; G2: 20dB; G3: 10dB), foram realizados os seguintes testes:

4.5.1.1 - Acurácia *versus* número de épocas promediadas

Para avaliar a quantidade mínima de épocas necessárias para atingir uma boa performance, foram realizados vários testes com quantidades diferentes de épocas promediadas para geração do sinal de entrada dos filtros – de uma época até a quantidade total de épocas de cada tarefa. Neste caso os *templates* dos filtros foram gerados com a promediação de todas as épocas para os alvos A e B para cada um dos 9 canais simulados. Para cada teste avaliou-se a acurácia do sistema.

4.5.1.2 - Experimentos com validação cruzada

Uma vez definida a quantidade mínima de épocas para geração dos sinais de entrada dos filtros, a performance global do sistema, foi avaliada por meio de validação cruzada. Como veremos na descrição dos resultados, utilizamos ‘uma’, ‘três’ e ‘cinco’ épocas promediadas para a geração dos sinais de entrada dos filtros. Os *templates*, neste caso, foram então gerados pela promediação das demais épocas. Para cada situação repetiu-se a validação cruzada. Por exemplo, com três épocas para geração dos sinais de entrada, para cada giro de validação cruzada três eram escolhidas para geração dos sinais de entrada dos filtros casados e as demais utilizadas para *templates* dos filtros.

4.5.1.3 - Taxa de transferência de informação

Para cada teste realizado com sinais semissintéticos, calculou-se, por fim, a taxa de transferência de informação (TTI), conforme definido pela Equação (2.1).

4.5.2 – Sinais EEG reais

4.5.2.1 - Acurácia *versus* número de épocas promediadas

Para avaliar a quantidade mínima de épocas necessárias para atingir uma boa performance com sinais reais, foram realizados vários testes com quantidades diferentes de épocas promediadas para geração do sinal de entrada dos filtros – de uma época até a quantidade total de épocas de cada tarefa. Neste caso os *templates* dos filtros foram gerados com a

promediação de todas as épocas para os alvos A e B. Para cada teste avaliou-se a acurácia do sistema.

4.5.2.2 - Experimentos com validação cruzada

Uma vez definida a quantidade mínima de épocas para estabelecer boa performance (cinco – como veremos nos Resultados), a acurácia global do sistema foi avaliada por meio de validação cruzada. Na validação cruzada, $\frac{3}{4}$ do conjunto de dados foram selecionados para treinamento (para a construção do *template* do banco de filtros casados) e $\frac{1}{4}$ restante foi utilizado para teste (a promediação destas seria a entrada para o classificador).

A validação cruzada primeiramente foi realizada com os conjuntos de épocas extraídos na sequência em que ocorreram os ensaios. Como eram 20 ensaios para cada repetição, as interações se deram da seguinte forma:

- Primeira interação – as cinco primeiras épocas de cada estímulo foram promediadas para gerar o sinal de entrada daquele estímulo, e as demais para o *template* do filtro.
- Segunda interação foi: o sinal de entrada foi gerado com a promediação da segunda época até a sexta época, e o restante para o *template* do filtro. Este processo foi repetido, iniciando-se pela terceira época, e assim sucessivamente até a décima sexta época.

A validação cruzada também foi realizada selecionando-se aleatoriamente as cinco épocas para gerar os sinais de entrada.

O objeto da estratégia descrita (validação cruzada sequencial ou aleatória) foi avaliar se alguma alteração poderia ocorrer na performance sistema à medida que o sujeito se acostumava com os estímulos apresentados durante a tarefa.

Neste estudo, após a investigação preliminar da quantidade de épocas mínimas para os sinais de entrada do sistema, o procedimento acima de validação cruzada foi repetido para as seguintes situações, visando avaliar qual delas resultaria em melhor performance (ver item 4.4.2):

- (i) EEG - O *template* dos filtros casados e os sinais de entrada foram construídos com épocas do sinal EEG;

- (ii) EMDFI - O *template* dos filtros casados e o sinal de entrada do sistema foram construídos com as IMFs com melhor correlação com os sinais EEG;
- (iii) EMDF - O *template* do filtros casados foi construído com as IMFs e o sinal de entrada com épocas do sinal EEG;
- (iv) N2ac – Para o item acima com melhor performance (o EEG, conforme será apresentado nos resultados), verificou ainda a influência de inclusão do sinal N2ac.

Foram utilizados 9 canais de interesse para cada voluntário. O *template* de cada filtro foi janelado entre 150 ms até 450 ms pós-estímulo, por apresentar melhor desempenho na classificação utilizando esse segmento de dados.

4.5.2.3 - Taxa de transferência de informação

Para cada teste realizado com sinais semissintéticos, calculou-se, por fim, a taxa de transferência de informação (TTI), conforme definido pela Equação (2.1).

Capítulo 5 - Resultados

Este capítulo apresentará ao decorrer das seções os resultados obtidos para cada etapa dos experimentos de validação do *framework* proposto.

5.1 - Sinais semissintéticos

Conforme descrito no capítulo anterior, diversos pacotes de sinais semissintéticos (baseados em sinais EEG reais e PREs simulados) foram gerados para avaliar a performance do sistema em situações controladas. Para cada nível de RSR, quatro conjuntos de dados foram gerados:

- Grupo 1 (RSR = 200dB): G1S1, G1S2, G1S3 e G1S4;
- Grupo 2 (RSR = 20dB): G2S1, G2S2, G2S3 e G2S4;
- Grupo 3 (RSR = 10dB): G3S1, G3S2, G3S3 e G3S4.

Onde,

- S1: Parâmetros do simulador extraídos dos PREs reais (banco de dados) do sujeito 1 prestando nos alvos A e B (dois PREs simulados); Atividade EEG de background: sujeito 1 em repouso.
- S2: Parâmetros do simulador extraídos dos PREs reais (banco de dados) do sujeito 2 prestando nos alvos A e B (dois PREs simulados); Atividade EEG de background: sujeito 1 em repouso.
- S3: Parâmetros do simulador extraídos dos PREs reais (banco de dados) do sujeito 3 prestando nos alvos A e B (dois PREs simulados); Atividade EEG de background: sujeito 1 em repouso.
- S4: Parâmetros do simulador extraídos dos PREs reais (banco de dados) do sujeito 4 prestando nos alvos A e B (dois PREs simulados); Atividade EEG de background: sujeito 1 em repouso.

A Tabela 5.1 apresenta, como exemplo, os parâmetros de amplitude, latência, largura de onda (desvio padrão) e deflexão da onda (positiva ou negativa) das gaussianas utilizados para simulação de PREs para o conjunto G1S1 nos diversos canais EEG.

Tabela 5.1 - Parâmetros de entrada para o simulador para geração das deflexões dos PRE_A (simula um sujeito prestando atenção no alvo A) para o conjunto de dados G1S1.

Onda	Parâmetros	Canais								
		F3	FZ	F4	C3	CZ	C4	FC3	FCZ	FC4
P100	Latência (ms)	106	107	110	100	101	102	104	104	108
	Largura de onda (ms)	23.25	26.00	30.00	16.50	25.00	23.00	10.25	27.25	29.00
	Amplitude (μV)	4.49	4.93	4.63	4.29	4.84	3.82	2.86	4.84	3.78
	Deflexão (P/N)	P	P	P	P	P	P	P	P	P
N200	Latência (ms)	209	207	207	217	205	209	202	208	207
	Largura de onda (ms)	27.00	29.75	28.75	34.75	33.50	34.00	33.25	31.25	29.75
	Amplitude (μV)	9.50	13.76	12.95	9.33	12.22	12.83	9.41	14.50	14.40
	Deflexão (P/N)	N	N	N	N	N	N	N	N	N
P300	Latência (ms)	301	299	304	300	304	301	293	300	299
	Largura de onda (ms)	39.25	37.50	41.00	19.25	21.25	18.00	21.25	22.50	15.50
	Amplitude (μV)	4.06	5.73	5.84	7.71	8.71	6.71	5.83	8.14	4.77
	Deflexão (P/N)	P	P	P	P	P	P	P	P	P

5.1.1 - Grupo 1: Sinais com a relação sinal-ruído de 200dB

5.1.1.1 - Acurácia *versus* número de épocas promediadas

O primeiro experimento realizado buscou avaliar o desempenho do classificador com diferentes quantidades de épocas promediadas para gerar os sinais de entrada para o classificador, e assim avaliar qual seria a quantidade mínima de promedições que permitisse uma boa performance (como vimos, quanto menor a quantidade de épocas promediadas, maior a TTI do sistema). Os *templates* dos filtros para os alvos A ($PRE_A = h_A(t)$) e B ($PRE_B = h_B(t)$) foram gerados com todas épocas dos PREs A e B, respectivamente.

Para cada tipo de estímulo meta (alvos A e B), foram simulados 40 ensaios (*trials*) para cada “pergunta”. Semelhante ao protocolo experimental utilizando o banco de dados de EEG real. Nesta etapa, os sinais foram simulados, conforme descrito anteriormente, utilizando RSR de 200dB. A Figura 5.1, ilustra um exemplo da simulação dos 40 *trials* para um dado estímulo em cinza e a média dos *trials* em vermelho.




Figura 5.1 – Ilustração da simulação de 40 trials do conjunto G2S4, para cada eletrodo (cor cinza) e a média de todos os trials (vermelho) destacando PREs com as deflexões P100, N200 e P300

A Figura 5.2, mostra um gráfico destacando a acurácia do sistema para classificar PREs associadas à dois estímulos alvo versus a quantidade de épocas utilizadas para geração dos sinais de entrada dos filtros (neste exemplo é mostrada apenas a resposta para o conjunto G1S1).




Figura 5.2 – Curva de performance da resposta do sistema *versus* número de épocas promediadas para geração de sinais de entrada dos filtros, para o conjunto de dados G1S1.

Conforme esperado, com uma relação sinal ruído tão alta (200 dB), o desempenho do classificador foi de 100% independentemente da quantidade de épocas utilizadas para gerar os sinais de entrada. A mesma resposta foi obtida para os demais conjuntos de dados (G1S2, G1S3 e G1S4).

5.1.1.2 - Validação cruzada

Para melhor avaliar a performance do sistema ao classificar sinais sintéticos com RSR de 200dB, os quatro conjuntos de dados do G1 foram então classificados em validação cruzada. Para cada conjunto de sinais (G1Si), foram avaliadas três situações:

- Sinal de entrada dos filtros gerados com uma época apenas, e *templates* gerados pela promediação das demais épocas (39); Aconteceram 40 interações.
- Sinal de entrada dos filtros gerados pela promediação de três épocas, e *templates* gerados pela promediação das demais épocas (37); Aconteceram 38 interações.
- Sinal de entrada dos filtros gerados pela promediação de cinco épocas, e *templates* gerados pela promediação das demais épocas (35). Aconteceram 36 interações.

A validação cruzada foi realizada com os conjuntos de épocas e o resultado de performance do sistema é dado pelo resultado médio de todas interações.

A Tabela 5.2 apresenta a acurácia e TTI do classificador para cada condição.

Tabela 5.2 – Acurácia de classificação e a TTI para cada conjunto de dados do G1.

Conjunto de Dados	Acurácia (%)		
	1 época	3 épocas	5 épocas
G1S1	96,25	98,68	100,00
G1S2	98,75	100,00	100,00
G1S3	100,00	100,00	100,00
G1S4	100,00	100,00	100,00
Média \pm dp	98,75 \pm 1,53	100,00 \pm 0,57	100,00 \pm 0
TTI (bit/min)	12,90	14,26	14,26

Observe que o sistema foi capaz de detectar e classificar corretamente pelo menos 98,75 % dos PREs para todas as condições.

A Figura 5.3 apresenta um exemplo de processamento de uma época ponderada de um dos sinais do sintéticos gerados. O sinal contém um PRE promediado do conjunto G1S4 para o Alvo A (Figura 5.3(a)). A Figura 5.3(b) apresenta a saída dos filtros casados. Note que o sistema foi capaz de identificar Alvo (círculo) no mesmo instante de tempo em que a forma de onda do PRE é observada.




Figura 5.3 - Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um canal do conjunto G1S4 para o canal FCz; (b) saídas do banco de filtros do classificador interno para o canal FCz - linha roxa: janela de análise dos picos; linha azul: saída do filtro

para o alvo A; linha vermelha: saída do filtro para o alvo B; círculo preto: instante de tempo e filtro cuja saída apresenta maior amplitude (filtro selecionado – o PRE de entrada é associado ao alvo A, neste caso).

5.1.2 - Grupo 2: Sinais com a relação sinal-ruído de 20dB

Esta etapa é similar a anterior, mas agora os sinais foram simulados com RSR de 20dB (grupo G2).

5.1.2.1 - Acurácia *versus* número de épocas promediadas

A Figura 5.4 apresenta a curva de desempenho do sistema *versus* o número de épocas promediadas para geração dos sinais de entrada para os filtros (neste exemplo é mostrada apenas a resposta para o conjunto G2S1).




Figura 5.4 – Curva de performance da resposta do sistema versus a quantidade de épocas promedidas para gerar os sinais de entrada dos filtros, para o conjunto de dados G2S1.

É possível observar que, na presença de ruídos (RSR de 20dB), com sinais de entrada sendo formados pela promediação de um, dois e três PREs reduz a performance para, aproximadamente, 75%, 87% e 95%, respectivamente. A partir de quatro épocas promediadas, a acurácia é de 100%.

5.1.2.2 - Validação cruzada

A Figura 5.5 apresenta, assim como para o grupo anterior, uma época com RSR de 20B para quando o Alvo A é atendido. Note que, mesmo com a presença de ruído, o sistema ainda é capaz de detectar corretamente o PRE alvo.




Figura 5.5 - Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um canal do conjunto G2S4 para o canal FCz; (b) saídas do banco de filtros do classificador interno para o canal FCz - linha roxa: janela de análise dos picos; linha azul: saída do filtro para o alvo A; linha vermelha: saída do filtro para o alvo B; círculo preto: instante de tempo e filtro cuja saída apresenta maior amplitude (filtro selecionado – o PRE de entrada é associado ao alvo A, neste caso).

A Tabela 5.3 mostra os resultados obtidos para o G2 (em condições similares ao descrito no item 5.1.1.2, mas com RSR de 20dB). É possível observar que, como esperado, sinais com RSR de 20B provocaram a redução da acurácia e da TTI do sistema. Ainda assim, as taxas de classificação correta permanecem acima de 88% e, para o caso da média de 5 épocas, esse valor chega até 100% em um dos conjuntos de dados.

Tabela 5.3 – Acurácia de classificação e a TTI para cada conjunto de dados do G2.

Conjunto de Dados	Acurácia (%)		
	1 época	3 épocas	5 épocas
G2S1	82,50	94,73	95,83
G2S2	87,50	90,78	98,61
G2S3	87,50	92,10	91,66
G2S4	95,00	100,00	100,00
Média \pm dp	88,12 \pm 4,46	94,40 \pm 3,53	96,52 \pm 3,18
TTI (bit/min)	6,77	9,83	11,17

5.1.3 - Grupo 3: Sinais com a relação sinal-ruído de 10dB

Este terceiro grupo visa representar condições reais de relação sinal ruído entre o potencial de interesse e a atividade background do EEG - potência do ruído de fundo 10 vezes maior do que a potência do PRE (Reis et al., 2014; Bressler and Ding, 2006).

5.1.3.1 - Acurácia *versus* número de épocas promediadas

A Figura 5.6 apresenta a curva de desempenho do sistema *versus* o número de épocas promediadas para geração dos sinais de entrada para os filtros (neste exemplo é mostrada apenas a resposta para o conjunto G3S1).

Nota-se que na presença de ruídos ainda maiores que no caso anterior, a classificação de sinais de entrada contendo apenas ensaios únicos (*single trial*) tem acurácia reduzida para, aproximadamente, 72%. Acurácias de 100% começam a ocorrer quando os sinais de entrada são gerados a partir de, pelo menos, 15 épocas.




Figura 5.6 – Curva de performance da resposta do sistema *versus* a quantidade de épocas promedidas para gerar os sinais de entradas dos filtros, para o conjunto de dados G3S1.

5.1.3.2 - Validação cruzada

A Figura 5.7 apresenta uma época com RSR de 10B para quando o Alvo A é atendido. Note que, mesmo com a presença de ruído, o sistema ainda é capaz de detectar corretamente o PRE alvo.




Figura 5.7 - Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um canal do conjunto G3S4 para o canal FCz; (b) saídas do banco de filtros do classificador interno para o canal FCz - linha roxa: janela de análise dos picos; linha azul: saída do filtro para o alvo A; linha vermelha: saída do filtro para o alvo B; círculo preto: instante de tempo e filtro cuja saída apresenta maior amplitude (filtro selecionado – o PRE de entrada é associado ao alvo A, neste caso).

Os resultados gerais para G3 são apresentados na Tabela 5.4. Observa-se, como esperado, uma redução na performance em relação aos grupos anteriores, que possuem maior RSR.

Tabela 5.4 – Acurácia de classificação e a TTI para cada conjunto de dados do G3.

Conjunto de Dados	Acurácia (%)		
	1 época	3 épocas	5 épocas
G3S1	78,75	85,52	95,83
G3S2	85,00	86,84	87,50
G3S3	73,75	80,26	83,33
G3S4	87,50	93,42	94,44
Média ± dp	81,25 ± 5,37	86,51 ± 4,68	90,27 ± 5,10
TTI (bit/min)	4,33	6,13	7,70

5.2 - Sinais EEG reais

Conforme descrito no capítulo 4, os dados de EEG para esta etapa de validação foram obtidos do trabalho de (Guo et al., 2014), que avaliou a resposta de um sistema de classificação baseado em máquinas de vetor de suporte para identificação de respostas binárias (sim/não) durante a operação de ICM com paradigma *oddball* auditivo. Os sinais foram captados dos eletrodos F3, F4, F4, C3, C4, FC3, FC4, FC4 (referência em M1 e M2 e aterramento em AFz), com a frequência de amostragem em 1000 Hz. Sinais de cinco sujeitos foram avaliados nesta pesquisa. Cada tarefa foi composta de 20 ensaios (*trials*).

5.2.1 - Acurácia *versus* número de épocas promediadas

A Figura 5.8, ilustra a resposta do sistema *versus* o número de épocas promediadas para geração dos sinais de entrada dos filtros. Nesta etapa, os *templates* foram gerados pela promediação de todas as 20 épocas (neste exemplo, é mostrada a performance apenas para um dos voluntários).




Figura 5.8 – Curva de performance do sistema *versus* o número de épocas promediadas para geração dos sinais de entrada dos filtros (Voluntário 1). *Templates* dos filtros gerados com todas as 20 épocas para cada alvo (A ou B).

Como se observa, a partir de 5 épocas promediadas verifica-se acurácias sempre acima de 89%, que conforme destacado nos capítulos introdutórios deste trabalho, pode ser considerada bastante satisfatória para esta classe de ICMs. Com 10 épocas, ou mais, promediadas o sistema classifica corretamente 100% dos PREs alvo.

5.2.2 - Validação cruzada

Uma vez que os testes anteriores apontaram que a quantidade mínima de épocas para boa performance deva ser igual a cinco, as validações cruzadas foram realizadas a partir deste patamar. Ou seja, para cada tarefa de 20 *trials*, a validação cruzada foi feita utilizando $\frac{3}{4}$ dos dados para geração dos *templates* dos filtros (15 *trials* para cada alvo A ou B) e $\frac{1}{4}$ para geração dos sinais de entrada (5 *trials*).

A Figura 5.9 ilustra um exemplo para quando o voluntário 4 atende aos alvos A (Figura 5.9(a-esquerda) e B (Figura 5.9(a-direita) de um canal. A saída dos filtros e a seleção do classificador é mostrada nas Figuras 5.9(b-esquerda) e 5.9(b-direita), respectivamente. Observe que, para ambos os casos, o sistema consegue identificar corretamente os alvos.

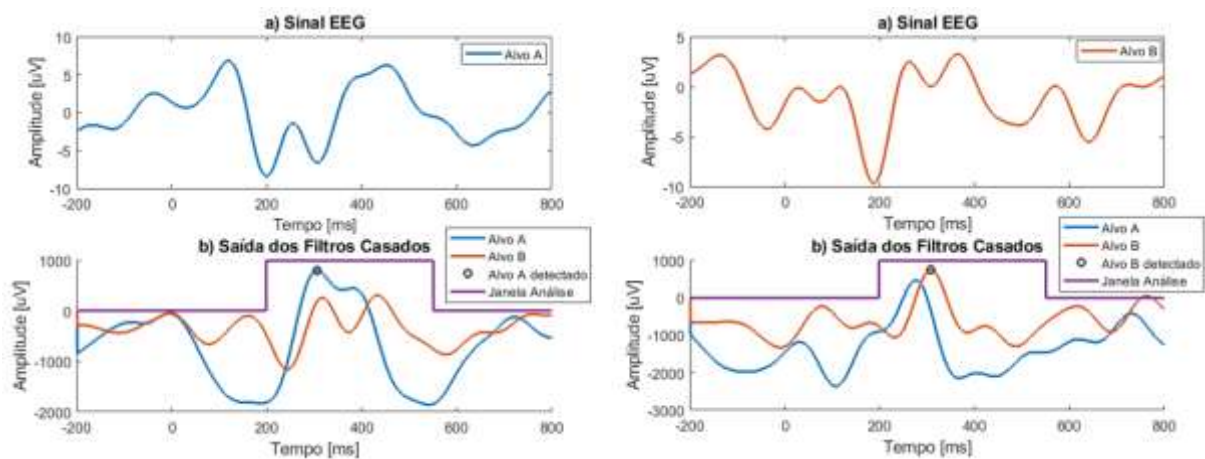


Figura 5.9 - Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um sinal EEG (canal FCz) – composto de um PRE; (b) saída do banco de filtros; a curva roxa representa a janela de análise dos picos e o círculo representa a saída do filtro que superou em amplitude.

Cada canal votou uma resposta, foi utilizada uma estratégia de voto ponderado, em que, as amplitudes de todos os canais que votam em A (ou B) são somadas. A resposta final do sistema é então aquela de maior resultado.

Para avaliar os possíveis impactos de algum efeito de aprendizado durante a execução das tarefas (o sujeito começa a detectar algum padrão nos estímulos), a validação cruzada foi ainda realizada de duas formas: i) os conjuntos de épocas para as promediações foram extraídos sequencialmente; ii) os conjuntos de épocas para as promediações foram extraídos aleatoriamente do conjunto de dados das tarefas. A Tabela 5.5 mostra a acurácia e a TTI do sistema para as duas situações.

Tabela 5.5 – Acurácia de classificação (%) e TTI para cada voluntário, com validações cruzadas utilizando dados sequenciais e embaralhados para geração dos *templates* e sinais de entrada dos filtros.

Voluntário	Sequencial	Aleatório
V1	90,00	87,50
V2	68,75	75,00
V3	50,00	53,12
V4	58,75	84,37
V5	81,25	78,12
Média \pm dp	71,75 \pm 13,52	75,62 \pm 12,08
TTI (bit/min)	2,01	2,83

A Figura 5.10 apresenta a matriz de confusão com acurácia média de acerto para todos os indivíduos para cada um dos alvos. É possível notar que a acurácia para quando o sujeito está atendendo ao Alvo B é relativamente menor do que para o Alvo A.




Figura 5.10 – Matriz de confusão para a média de acerto de todos indivíduos para cada alvo, nos dados sequenciais e aleatórios, para canais de EEG.

5.2.3 – Validação incluindo a componente N2ac

Conforme descrito por Gamble & Luck (2011), quando os sujeitos atendem a um estímulo auditivo alvo, espera-se que as amplitudes do PRE N200 no lado contralateral anterior do cérebro sejam mais altas do que aquelas no lado ipsilateral anterior. Assim, nesta pesquisa, decidimos investigar se tal efeito também teria impacto positivo na performance do sistema.

A Figura 5.11 mostra a grande média de formas de onda ipsilateral e contralaterais (N2ac) nos eletrodos anteriores quando o sujeito V4 presta atenção aos estímulos alvo escolhidos.




Figura 5.11 – Época média geral para o voluntário 4 para os estímulos alvos escolhidos, com as respostas contralateral anterior (N2ac), ipsilateral e desvio (contralateral menos ipsilateral) quando o indivíduo atende o alvo A (a) e ao alvo B (b).

A Tabela 5.6 apresenta a acurácia da classificação para detecção das escolhas desejadas para cada sujeito utilizando a componente N2ac como ‘canal’ extra para o classificador.

Tabela 5.6 – Acurácia de classificação (%) e TTI para cada voluntário. Validações cruzadas executadas com os dados sequenciais e embaralhados, com a inclusão da componente N2ac aos sinais EEG.

Voluntários	Sequencial	Aleatório
V1	90,62	84,37
V2	71,87	84,37
V3	43,75	59,37
V4	68,75	71,87
V5	81,25	87,50
Média ± dp	71,25 ± 15,73	77,50 ± 10,53
TTI (bit/min)	1,92	3,19

Como se nota, em média, a adição do sinal N2ac resultou em uma pequena melhora na acurácia para promediações a partir de dados embaralhados em comparação com os resultados obtidos quando o classificador recebeu entradas apenas dos canais de EEG (Tabela 5.4). Por outro lado, a inclusão da componente N2ac não resultou em melhora ou piora da acurácia do classificar as promediações foram realizadas com épocas sequenciais.

A Figura 5.12 mostra a matriz de confusão para validações cruzadas com dados sequenciais e embaralhados. É possível identificar, que a média de acertos para o Alvo A é superior a 75%, enquanto para o Alvo B, é pouco maior que 60%. Esses valores mais baixos de classificação se devem, majoritariamente, à baixa performance alcançada pelo sujeito V3, conforme apresentado na Tabela 5.5.




Figura 5.12 - Matriz de confusão para média de acerto de todos indivíduos para cada alvo, para validações com dados sequenciais e aleatórios, utilizando-se a componente N2ac.

5.2.4 – Validação utilizando Decomposição em Modo Empírico

EMD tem sido utilizada como um método para eliminar artefatos de sinais que podem comprometer a performance de um classificador (Guo et al., 2014). Para avaliar se tal técnica poderia contribuir para nossa proposta, neste trabalho, a EMD foi utilizado para a decomposição das épocas e cada época foi decomposta em um conjunto de IMFs dentre os quais, uma seria escolhida com melhor representante do PRE que se deseja classificar. Para escolher a melhor IMF, foi feita a correlação entre cada IMF com a forma de onda que à originou. Sendo assim, a IMF com maior correlação foi escolhida para a representação da época. A Figura 5.13 mostra um exemplo das principais IMFs selecionadas para cada canal em uma das épocas, quando o estímulo alvo A é reproduzido no ouvido esquerdo de um voluntário.




Figura 5.13 – Exemplo das IMFs principais calculadas de uma época para todos os canais quando o indivíduo V1 atende ao alvo A que é tocado no ouvido esquerdo.

Canais como FZ, FC3, FCZ, C4, parecem transmitir informações sobre as tendências gerais associadas às deflexões nos períodos de N200 e P300. No entanto, foi observado que nem todas as IMFs correspondem adequadamente às oscilações de interesse nos períodos de

N200 e P300, o que pode explicar uma performance mais baixa (Tabela 5.7) do sistema quando o *template* dos filtros casados e dos sinais de entrada são gerados a partir da promediação das IMFs.

A Figura 5.14 apresenta um exemplo com o sinal de entrada do sistema sendo a promediação das IMFs mais correlacionadas com o sinal de EEG. No sinal de alvo A (Figura 5.14(a–esquerda)) é possível observar uma IMF que evidencia oscilações nas latências de N200 e P300. No entanto, a IMF para alvo B não apresenta oscilações que realçam adequadamente as latências esperadas (Figura 5.14(a–direita)), apesar de, ainda assim, a resposta do classificador ter sido correta.

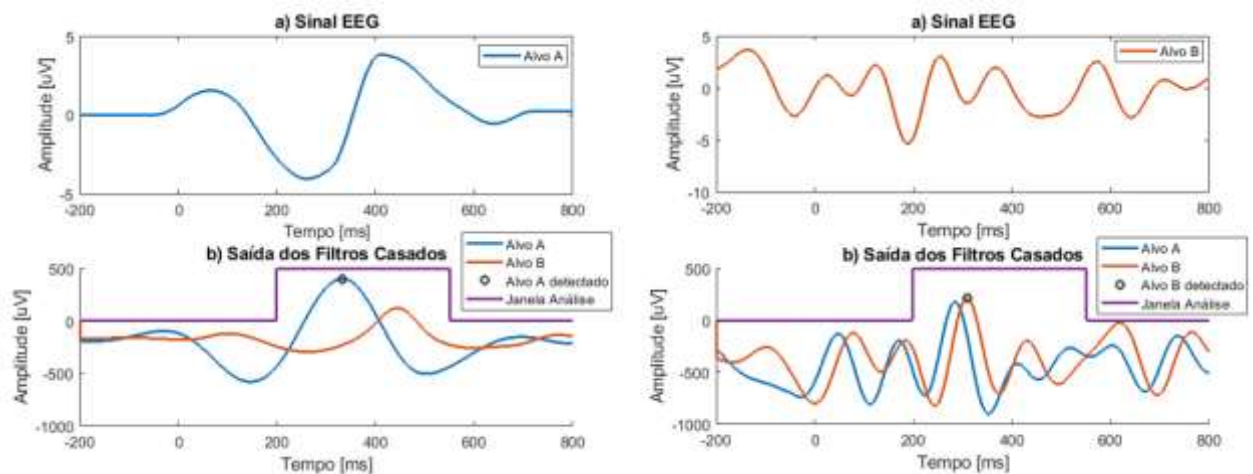


Figura 5.14 - Sinais associados às etapas do sistema de classificação: (a) sinal de entrada de um sinal EEG das IMFs principais (canal FCz); (b) saída do banco de filtros casados; a curva roxa representa a janela de análise dos picos e o círculo representa a saída do filtro que superou em amplitude.

Tabela 5.7 – Acurácia de classificação (%) e TTI para cada voluntário, com os dados sequenciais e embaralhados, utilizando as IMFs para geração dos *templates* e sinais de entrada dos filtros.

Voluntários	Sequencial	Aleatório
V1	63,33	71,87
V2	53,12	46,87
V3	59,37	56,25
V4	53,12	56,25
V5	71,87	56,25
Média ± dp	60,16 ± 7,02	57,50 ± 8,05
TTI (bit/min)	0,42	0,23

A Figura 5.15 apresenta a matriz de confusão para esta etapa, onde a média de acerto para cada alvo tanto para os dados sequenciais como para os dados aleatórios atingem em torno de 50% a 60% apenas.




Figura 5.15 - Matriz de confusão para média de acerto de todos indivíduos para cada alvo, para validações com dados sequenciais e aleatórios, utilizando IMFs para geração dos sinais e templates.

Por fim, testou-se ainda avaliar o uso de IMFs apenas para geração dos *templates* dos filtros, enquanto os sinais de entrada seriam as promediações dos sinais EEG. A Tabela 5.8 apresenta os resultados referentes a este teste.

Tabela 5.8 – Acurácia de classificação e a TTI para cada voluntário com validações cruzadas baseadas em dados sequenciais e embaralhados. O *template* dos filtros foram gerados a partir das IMFs principais e o sinais de entrada a partir dos sinais EEG.

Voluntários	Sequencial	Aleatório
V1	80,00	65,62
V2	34,37	59,37
V3	56,25	50,00
V4	56,25	68,75
V5	62,50	56,25
Média \pm dp	57,87 \pm 14,61	60,00 \pm 6,67
TTI (bit/min)	0,25	0,41

Em média, o uso das informações das IMFs para geração apenas dos *templates* dos filtros não melhorou a performance do sistema, quando comparado com a classificação usando apenas sinais EEG ou sinais EEG associados à componente N2ac.

5.3 Considerações finais sobre os resultados

Os resultados obtidos até aqui podem ser resumidos na Tabela 5.9. Nesta tabela, são apresentadas a acurácia e a TTI da classificação para detectar as escolhas desejáveis para cada indivíduo executando as tarefas, a partir de todas as estratégias testadas.

Tabela 5.9 - Acurácia de classificação e a TTI para todos os voluntários e todas as estratégias de geração de *templates* e sinais de entrada para os filtros.

Voluntário	Sequencial				Aleatório			
	EEG	EMDFI	EMDF	EEG+N2ac	EEG	EMDFI	EMDF	EEG+N2ac
V1	90,00	63,33	80,00	90,62	87,50	71,87	65,62	84,37
V2	68,75	53,12	34,37	71,87	75,00	46,87	59,37	84,37
V3	50,00	59,37	56,25	43,75	53,12	56,25	50,00	59,37
V4	58,75	53,12	56,25	68,75	84,37	56,25	68,75	71,87
V5	81,25	71,87	62,50	81,25	78,12	56,25	56,25	87,50
Média ± dp	71,75 ±	60,16 ±	57,87 ±	71,25 ±	75,62 ±	57,50 ±	60,00 ±	77,50 ±
	13,52	7,02	14,61	15,73	12,08	8,05	6,67	10,53
ITR (bit/min)	2,01	0,42	0,25	1,92	2,83	0,23	0,41	3,19

Para comparar a robustez do método, avaliou-se ainda a combinação das respostas para todos os indivíduos com validações cruzadas sequenciais e aleatórias (Figura 5.16). Percebe-se que, o uso de apenas sinais EEG e de sinais EEG acrescidos da componente N2ac resulta nas melhores performances. Por fim, a utilização de dados aleatórios para geração dos *templates* e sinais de entrada dos filtros promove resposta globais melhores.




Figura 5.16 – Média global da acurácia de classificação para todos os sujeitos, com testes sequenciais e aleatórios, para todas as técnicas avaliadas.

Capítulo 6 - Discussão

Nossos resultados demonstram que o *framework* proposto pode fornecer uma alternativa para detecção e classificação de potenciais relacionados à eventos com uma boa precisão. Em média, o método alcançou taxas de sucesso superiores a 81% para ensaios únicos simulados com relação sinal-ruído de 10dB, que é o caso mais crítico. Para média de 5 épocas no sinal de entrada o sistema obteve 90,27 % de performance e TTI de 7,70 bit/min, também para os dados simulados. Ao processar um sinal de EEG real, o método alcançou 77,5 % para classificação de sinais de EEG associados com a componente N2ac.

Estudos anteriores afirmam que a componente N2ac, que é uma negatividade contralateral anterior na latência N200, está associada à atenção seletiva de estímulos auditivos (Gamble & Luck, 2011). Guo et al. (2015), mostraram que a inclusão da N2ac junto aos canais de EEG para uma ICM, controlada por PREs em paradigma *oddball* auditivo, melhorou a precisão da classificação e provaram estatisticamente que as amplitudes do N200 no lado contralateral são superiores aos valores do ipsilateral. O fato de ter amplitudes maiores, para a técnica de filtros casados foi interessante, pois quando a entrada do filtro casado é o sinal correto mais o ruído (que neste caso seria a atividade background de EEG), a resposta do pico de saída dos filtros é linearmente relacionado com a energia do sinal (Levanon & Mozeson, 2004); logo, nesta pesquisa, a componente N2ac contribuiu para a melhora da resposta final do sistema.

Neste trabalho, foram realizados dois testes com *Empirical Mode Decomposition*. No primeiro teste foi utilizado a IMF com maior correlação com o sinal associado, tanto para o sinal de entrada do sistema como para a construção do *template* dos filtros. Para este teste obtivemos uma acurácia média de 60,16%. Para o outro teste realizado, o sinal de entrada do sistema foi o sinal de EEG filtrado e o *template* dos filtros foram projetados com base nas IMFs, obtendo acurácia média de 57,87%. Estudos mostram que a técnica de *empirical mode decomposition* (EMD) aplicada na decomposição de potenciais evocados pode auxiliar no alcance de uma performance melhor no processo de classificação (Diez, Mut, Laciari, Torres, & Avila, 2009; Noshadi, Abootalebi, Sadeghi, & Shahvazian, 2014; T. Wang, Lin, Zhang, Peng, & Zhan, 2013). Isto se daria, pois a técnica ajudaria na eliminação de ruídos e a quantidade de informações a serem processadas. No entanto, nesta pesquisa, observou-se que as IMFs mais representativas dos PREs muitas vezes carregavam oscilações distintas entre o sinal de entrada e o *template*, o que pode justificar a diminuição na performance do sistema, uma vez que medir o grau de similaridade do sinal com o *template* do filtro é uma das

características da técnica dos filtros casados (Haykin, 1999). Uma proposta futura para melhoria da performance seria utilizar uma combinação de duas ou mais IMFs que comporiam melhor as características mais relevantes das oscilações dos potenciais evocados e buscar por metodologias na escolha das melhores IMFs para representar o sinal.

Diferentes técnicas de detecção e classificação supervisionadas foram desenvolvidas ao longo dos últimos anos e muitas delas são aplicadas a ICMs. As mais comuns descritas na literatura são: redes neurais artificiais (Garcés & Orosco, 2008), análise discriminante linear (Garcés & Orosco, 2008) e máquina de vetores de suporte (Nicolas-Alonso & Gomez-Gil, 2012). Boa parte desses métodos apresentam um bom desempenho, porém existem algumas particularidades que devem ser abordadas. Por exemplo, a maior fonte de dificuldades para esses algoritmos são o *viés* (variação do erro estimado) e a possibilidade de *overtfitting* (sobre ajuste) (Lemm et al., 2011). Além disso, aquelas técnicas possuem um alto custo computacional. Se um classificador estiver sobre ajustado, ele será superespecializado em classificar os dados de treinamentos ou dados muito semelhantes. Esse fenômeno pode ser evitado amenizando a complexidade do processo de classificação (Lemm et al., 2011). Já a variação do erro estimado pode ser evitada quando se aplica a validação cruzada. Esse procedimento é repetido várias vezes e em várias partições diferentes dos dados (Lemm et al., 2011). Similar a estas estratégias, nosso método também requer conhecimento prévio das características do sinal. No entanto, o *framework* proposto foi projetado buscando respostas rápidas para futuras aplicações em tempo real, evitando algoritmos de extração de características e classificação que exigem computação intensiva, ajustes finos, e que corra riscos de sobre ajuste. Assim, um classificador que use filtros casados digitais poderia auxiliar no de ICMs online.

A arquitetura do *framework* proposto permite o uso de várias técnicas de otimização no processamento de sinais de EEG, como o processamento paralelo dos filtros. Este modelo foi inspirado no trabalho de Siqueira & Soares (2015), que aplicaram um banco de filtros casados para a decomposição de unidade motoras em eletromiografia. Lafuente et al. (2017) também aplicaram a técnica de filtros casados, porém com uma abordagem não supervisionada para classificar a onda P300 em um paradigma visual, através de uma pontuação ponderada. Comparações diretas, do nosso trabalho com uma abordagem não supervisionada, nem sempre são possíveis, pois estão sujeitos a questionamentos. No entanto, um diferencial geral que é possível notar perante aos dois estudos mencionados (Lafuente et al., 2017; Siqueira & Soares, 2015), é um *framework* que utiliza a combinação das respostas dos diversos canais de interesse

do EEG para classificação correta da intenção do usuário (Polich, 2007), enquanto os modelos utilizados pelos autores citados foram projetados para processamento de canais individuais.

Como observado no capítulo de resultados, o método mostrou algumas dificuldades com PREs de baixa energia (próximo ao nível do ruído de base), principalmente em ensaios únicos (*single trial*). Estes mesmos resultados foram observados em estudos anteriores (Lafuente et al., 2017; Siqueira & Soares, 2015). Dentre as soluções viáveis seria contar com técnicas mais especializadas na remoção de artefatos para melhoria d RSR (Kiamini, Alirezaee, Perseh, & Ahmadi, 2009; Mammone et al., 2012), e o aumento da base de dados (Lafuente et al., 2017).

Os PREs foram uma das primeiras estratégias para determinar a intenção do usuário em ICMs auditivas. No entanto, evidências sugerem que o P300 pode mudar com o tempo, causando deterioração no desempenho (Ravden & Polich, 1999), o que pode justificar a pior performance do sistema quando as promediações foram realizadas com dados (épocas) em sequência, em comparação com os dados aleatórios. Como uma proposta futura, seria explorar a construção dos *templates* dos filtros casados de forma dinâmica, ou seja, o *template* seria atualizado ao decorrer das tarefas executadas. Essa estratégia poderia proporcionar melhoria na performance do sistema já que o P300 pode mudar com o tempo nas ICMs (Ravden & Polich, 1999).

O banco de dados de EEG utilizado neste trabalho, apresentou uma tarefa em que dois estímulos auditivos alvos (A e B) mono foram testadas com frequências distintas (Alvo A = 100 e Alvo B = 4000 Hz). Conforme as matrizes de confusão apresentadas nos resultados, para a maioria dos experimentos realizados, a taxa de acerto do alvo B é menor do que a do alvo A. Deduzimos que pelas amplitudes menores do PREs associados ao alvo B interferiram na classificação do sistema, já que a saída máxima dos filtros casados é proporcional à energia da forma de onda do sinal de entrada.

Como apresentado, este trabalho contribui nas etapas de processamento de sinais EEG para o controle de ICMs com uma precisão boa. No entanto, ainda não foi possível a detecção de ensaios únicos com uma boa acurácia de classificação. Uma possível solução seria a inclusão de métodos de pré-processamento mais aprimorados e uma base de dados com sinais com melhor relação sinal-ruído.

Capítulo 7 - Conclusões

Na prática clínica, no caso de pacientes acometidos por esclerose lateral amiotrófica ou síndrome do encarceramento, é essencial que haja sistemas de comunicação alternativa como a interface cérebro máquina, que sejam capazes de serem implementados de forma simples e objetiva.

Sendo assim, foi desenvolvido e implementado nesta pesquisa um *framework* para detecção e classificação de potenciais relacionados a eventos auditivos no controle de ICMs baseado em filtros casados, atingindo o objetivo deste trabalho. O sistema projetado constitui em avanços nas pesquisas relacionadas ao processamento de sinais para controle de interfaces cérebro máquina, permitindo a decodificação de PREs com dependência de poucas características do sinal, sem ajustes finos, abrindo caminho para o uso de algoritmos de controle de ICMs em sistemas embarcados, já que se trata de uma aplicação com algoritmos mais simples e com baixo custo computacional.

Outra contribuição importante desta pesquisa, foi a combinação dos canais de EEG para a resposta global do sistema. Visto que, cada eletrodo abrange a análise de características particulares das respostas evocadas de cada região cerebral.

A validação do *framework* feita através de conjuntos de dados simulados e um banco de dados reais demonstrou resultados bem satisfatórios, apontados pela acurácia e TTI do sistema, mesmo em meio a um alto nível de ruído. Esse trabalho tem um grande potencial para auxiliar no desenvolvimento de futuras pesquisas e assim aplicar em usuários finais a fim de proporcionar uma qualidade de vida melhor.

7.1 Trabalhos Futuros

Como todo trabalho científico, este tem como principal objetivo contribuir para o estado da arte, apontando novas fronteiras para o conhecimento da área. Desta forma, os resultados não se limitam aos aqui apresentados. Apesar da proposta apontar bases para outras pesquisas, este trabalho contempla limitações, que devem ser investigadas em trabalhos futuros a título de aprimorar.

- Realizar as próprias coletas de dados de EEG visando um maior número de voluntários e uma gravação mais segura de artefatos a fim de investigar a melhoria na composição dos sinais de entrada e para construção dos *templates* dos filtros.
- Verificar técnicas para remoção de artefatos com a finalidade de aprimorar a qualidade das formas de ondas dos sinais de EEG.
- Explorar outras alternativas para obtenção do voto entre todos os canais de EEG para a resposta final do sistema.
- Explorar a construção dos *templates* dos filtros casados de forma dinâmica, ou seja, o *template* seria atualizado ao decorrer das tarefas executadas. Essa estratégia poderia proporcionar melhoria na performance do sistema já que o P300 pode mudar com o tempo.
- Expandir o *framework* desenvolvido para aplicação *online* proporcionando evidências para a implementação do sistema em usuários finais.
- Desenvolvimento do sistema embarcado.

REFERÊNCIAS

- AHN, S.; KIM, K.; JUN, S. C. Steady-state somatosensory evoked potential for brain-computer interface-present and future. **Frontiers in Human Neuroscience**, v. 9, n. JAN2016, p. 1–6, 2016. <https://doi.org/10.3389/fnhum.2015.00716>
- AMIN, H. U.; MALIK, A. S.; AHMAD, R. F.; et al. Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques. **Australasian Physical and Engineering Sciences in Medicine**, v. 38, n. 1, p. 139–149, 2015. Springer Netherlands. <https://doi.org/10.1007/s13246-015-0333-x>
- BAYKARA, E.; RUF, C. A.; FIORAVANTI, C.; et al. Effects of training and motivation on auditory P300 brain-computer interface performance. **Clinical Neurophysiology**, v. 127, n. 1, p. 379–387, 2016. International Federation of Clinical Neurophysiology. Disponível em: <https://doi.org/10.1016/j.clinph.2015.04.054>
- BEVERINA, F.; PALMAS, G.; SILVONI, S.; PICCIONE, F.; GIOVE, S. User adaptive BCIs: SSVEP and P300 based interfaces. **PsychNology Journal**, v. 1, n. 4, p. 331–354, 2003.
- BIRBAUMER, N.; HINTERBERGER, T.; KÜBLER, A.; NEUMANN, N. The thought-translation device (TTD): Neurobehavioral mechanisms and clinical outcome. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 11, n. 2, p. 120–123, 2003. <https://doi.org/10.1109/TNSRE.2003.814439>
- BROUWER, A. M.; VAN ERP, J. B. F. A tactile P300 brain-computer interface. **Frontiers in Neuroscience**, v. 4, n. MAY, p. 1–11, 2010. <https://doi.org/10.3389/fnins.2010.00019>
- CALIGARI, M.; GODI, M.; GUGLIELMETTI, S.; FRANCHIGNONI, F.; NARDONE, A. Eye tracking communication devices in amyotrophic lateral sclerosis: Impact on disability and quality of life. **Amyotrophic Lateral Sclerosis and Frontotemporal Degeneration**, v. 14, n. 7–8, p. 546–552, 2013. <https://doi.org/10.3109/21678421.2013.803576>
- CARABEZ, E.; SUGI, M.; NAMBU, I.; WADA, Y. Convolutional Neural Networks with 3D Input for P300 Identification in Auditory Brain-Computer Interfaces. **Computational Intelligence and Neuroscience**, v. 2017, 2017. <https://doi.org/10.1155/2017/8163949>
- CASTELLANOS, N. P.; MAKAROV, V. A. Recovering EEG brain signals: Artifact suppression with wavelet enhanced independent component analysis. **Journal of Neuroscience Methods**, v. 158, n. 2, p. 300–312, 2006. <https://doi.org/10.1016/j.jneumeth.2006.05.033>
- CHAUDHARY, U.; BIRBAUMER, N.; RAMOS-MURGUIALDAY, A. Brain-computer interfaces for communication and rehabilitation. **Nature Reviews Neurology**, v. 12, n. 9, p.

513–525, 2016. <https://doi.org/10.1038/nrneurol.2016.113>

CHAUDHARY, U.; XIA, B.; SILVONI, S.; COHEN, L. G.; BIRBAUMER, N. Brain–Computer Interface–Based Communication in the Completely Locked-In State. **PLoS Biology**, v. 15, n. 1, p. 1–25, 2017. <https://doi.org/10.1371/journal.pbio.1002593>

CITI, L.; POLI, R.; CINEL, C. Documenting, modelling and exploiting P300 amplitude changes due to variable target delays in Donchin’s speller. **Journal of Neural Engineering**, v. 7, n. 5, 2010. <https://doi.org/10.1088/1741-2560/7/5/056006>

DIEZ, P. F.; MUT, V.; LACIAR, E.; TORRES, A.; AVILA, E. Application of the empirical mode decomposition to the extraction of features from EEG signals for mental task classification. **Proceedings of the 31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society: Engineering the Future of Biomedicine, EMBC 2009**, p. 2579–2582, 2009. IEEE. <https://doi.org/10.1109/IEMBS.2009.5335278>

ERLBECK, H.; MOCHTY, U.; KÜBLER, A.; REAL, R. G. L. Circadian course of the P300 ERP in patients with amyotrophic lateral sclerosis - implications for brain-computer interfaces (BCI). **BMC Neurology**, v. 17, n. 1, p. 1–7, 2017. BMC Neurology. Disponível em: <https://doi.org/10.1186/s12883-016-0782-1>

FARQUHAR, J.; HILL, N. J. Interactions between pre-processing and classification methods for event-related-potential classification: Best-practice guidelines for brain-computer interfacing. **Neuroinformatics**, v. 11, n. 2, p. 175–192, 2013. <https://doi.org/10.1007/s12021-012-9171-0>

FARWELL, L. A.; DONCHIN, E. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. **Electroencephalography and Clinical Neurophysiology**, v. 70, n. 6, p. 510–523, 1988. [https://doi.org/10.1016/0013-4694\(88\)90149-6](https://doi.org/10.1016/0013-4694(88)90149-6)

FURDEA, A.; HALDER, S.; KRUSIENSKI, D. J.; et al. An auditory oddball (P300) spelling system for brain-computer interfaces. **Psychophysiology**, v. 46, n. 3, p. 617–625, 2009. <https://doi.org/10.1111/j.1469-8986.2008.00783.x>

GAMBLE, M. L.; LUCK, S. J. N2ac: An ERP component associated with the focusing of attention within an auditory scene. **Psychophysiology**, v. 48, n. 8, p. 1057–1068, 2011. <https://doi.org/10.1111/j.1469-8986.2010.01172.x>

GAMBLE, M. L.; WOLDORFF, M. G. The temporal cascade of neural processes underlying target detection and attentional processing during auditory search. **Cerebral Cortex**, v. 25, n. 9, p. 2456–2465, 2015. <https://doi.org/10.1093/cercor/bhu047>

GARCÉS, M. A.; OROSCO, L. L. **EEG signal processing in brain–computer interface**. Second Edi ed. Elsevier B.V., 2008. <https://doi.org/10.1016/B978-0-12-812892-3.00005-4>

GARRETT, Deon et al. Comparison of linear, nonlinear, and feature selection methods for EEG signal classification. **IEEE Transactions on neural systems and rehabilitation engineering**, v. 11, n. 2, p. 141-144, 2003. <https://doi.org/10.1109/TNSRE.2003.814441>

GUO, M.; XU, G.; WANG, L.; et al. The anterior contralateral response improves performance in a single trial auditory oddball BMI. **Biomedical Signal Processing and Control**, v. 22, p. 74–84, 2015. Elsevier Ltd. Disponível em: <https://doi.org/10.1016/j.bspc.2015.06.014>

HALDER, S.; KÄTHNER, I.; KÜBLER, A. Training leads to increased auditory brain-computer interface performance of end-users with motor impairments. **Clinical Neurophysiology**, v. 127, n. 2, p. 1288–1296, 2016. International Federation of Clinical Neurophysiology. Disponível em: <https://doi.org/10.1016/j.clinph.2015.08.007>

HALDER, S.; REA, M.; ANDREONI, R.; et al. An auditory oddball brain-computer interface for binary choices. **Clinical Neurophysiology**, v. 121, n. 4, p. 516–523, 2010. International Federation of Clinical Neurophysiology. Disponível em: <https://doi.org/10.1016/j.clinph.2009.11.087>

HAN, C.; XU, G.; XIE, J.; CHEN, C.; ZHANG, S. Highly Interactive Brain-Computer Interface Based on Flicker-Free Steady-State Motion Visual Evoked Potential. **Scientific Reports**, v. 8, n. 1, p. 1–13, 2018. Springer US. Disponível em: <https://doi.org/10.1038/s41598-018-24008-8>

HARDIMAN, O.; VAN DEN BERG, L. H.; KIERNAN, M. C. Clinical diagnosis and management of amyotrophic lateral sclerosis. **Nature Reviews Neurology**, v. 7, n. 11, p. 639–649, 2011. Nature Publishing Group. <https://doi.org/10.1038/nrneurol.2011.153>

HILL, N. J.; RICCI, E.; HAIDER, S.; et al. A practical, intuitive brain-computer interface for communicating “yes” or “no” by listening. **Journal of Neural Engineering**, v. 11, n. 3, 2014. <https://doi.org/10.1088/1741-2560/11/3/035003>

HOBSON, E. V.; MCDERMOTT, C. J. Supportive and symptomatic management of amyotrophic lateral sclerosis. **Nature Reviews Neurology**, v. 12, n. 9, p. 526–538, 2016. <https://doi.org/10.1038/nrneurol.2016.111>

HOSNI, S. M.; GADALLAH, M. E.; BAHGAT, S. F.; ABDELWAHAB, M. S. Classification of EEG signals using different feature extraction techniques for mental-task BCI. **ICCES'07 - 2007 International Conference on Computer Engineering and Systems**, p. 220–226, 2007. <https://doi.org/10.1109/ICCES.2007.4447052>

HUANG, M.; JIN, J.; ZHANG, Y.; HU, D.; WANG, X. Usage of drip drops as stimuli in an auditory P300 BCI paradigm. **Cognitive Neurodynamics**, v. 12, n. 1, p. 85–94, 2018. Springer Netherlands. <https://doi.org/10.1007/s11571-017-9456-y>

HUANG, N. E.; SHEN, Z.; LONG, S. R.; et al. The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis. **Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 454, n. 1971, p. 903–995, 1998. <https://doi.org/10.1098/rspa.1998.0193>

JARAD, N. Clinical review. **Chronic Respiratory Disease**, v. 13, n. 2, p. 173–188, 2016. <https://doi.org/10.1177/1479972316631139>

KANO, S.; MIYAMOTO, K.; YOSHINOBU, T. A Brain-Computer Interface (BCI) System. , p. 642–645, 2008.

KÄTHNER, I.; RUF, C. A.; PASQUALOTTO, E.; et al. A portable auditory P300 brain-computer interface with directional cues. **Clinical Neurophysiology**, v. 124, n. 2, p. 327–338, 2013. <https://doi.org/10.1016/j.clinph.2012.08.006>

KIAMINI, M.; ALIREZAEI, S.; PERSEH, B.; AHMADI, M. Elimination of Ocular Artifacts from EEG signals using the wavelet transform and empirical mode decomposition. , v. 6, n. 4, p. 1094–1097, 2009. <https://doi.org/10.1109/ECTICON.2009.5137235>

KIM, D. W.; HWANG, H. J.; LIM, J. H.; et al. Classification of selective attention to auditory stimuli: Toward vision-free brain-computer interfacing. **Journal of Neuroscience Methods**, v. 197, n. 1, p. 180–185, 2011. Elsevier B.V. Disponível em: <https://doi.org/10.1016/j.jneumeth.2011.02.007>

KLEBER, B.; BIRBAUMER, N. Direct brain communication: Neuroelectric and metabolic approaches at Tübingen. **Cognitive Processing**, v. 6, n. 1, p. 65–74, 2005. <https://doi.org/10.1007/s10339-004-0045-8>

KLOBASSA, D. S.; VAUGHAN, T. M.; BRUNNER, P.; et al. Toward a high-throughput auditory P300-based brain-computer interface. **Clinical Neurophysiology**, v. 120, n. 7, p. 1252–1261, 2009. International Federation of Clinical Neurophysiology. Disponível em: <https://doi.org/10.1016/j.clinph.2009.04.019>

KOHAVERI, R. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. **International Joint Conference of Artificial Intelligence**, , n. March 2001, 1995.

KRUSIENSKI, D. J.; SELLERS, E. W.; MCFARLAND, D. J.; VAUGHAN, T. M.; WOLPAW, J. R. Toward enhanced P300 speller performance. **Journal of Neuroscience Methods**, v. 167, n. 1, p. 15–21, 2008. <https://doi.org/10.1016/j.jneumeth.2007.07.017>

KÜBLER, A.; KOTCHOUBEY, B.; KAISER, J.; BIRBAUMER, N.; WOLPAW, J. R. Brain-computer communication: Unlocking the locked in. **Psychological Bulletin**, v. 127, n. 3, p. 358–375, 2001. <https://doi.org/10.1037/0033-2909.127.3.358>

KUNGL, M. The Impact of Early Experiences on Behavioral and Neural Correlates of Psycho-Social Functioning: A Study on Attachment, Social Interaction and Facial Familiarity Processing in Foster Children and a Control Group. January, 2016.

LABATE, D.; FORESTA, F. LA; OCCHIUTO, G.; et al. Empirical mode decomposition vs. wavelet decomposition for the extraction of respiratory signal from single-channel ECG: A comparison. **IEEE Sensors Journal**, v. 13, n. 7, p. 2666–2674, 2013. IEEE. <https://doi.org/10.1109/JSEN.2013.2257742>

LAFUENTE, V.; GORRIZ, J. M.; RAMIREZ, J.; GONZALEZ, E. P300 brainwave extraction from EEG signals: An unsupervised approach. **Expert Systems with Applications**, v. 74, p. 1–10, 2017. Elsevier Ltd. <https://doi.org/10.1016/j.eswa.2016.12.038>

LAL, T. N.; SCHRÖDER, M.; HINTERBERGER, T.; et al. Support vector channel selection in BCI. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 6, p. 1003–1010, 2004. <https://doi.org/10.1109/TBME.2004.827827>

LATHI, B. P.; DING, Z. Sistemas de Comunicações Analógicas e Digitais Modernos. 4. ed. Rio de Janeiro: LTC, 2012.

LELIEVRE, Y.; WASHIZAWA, Y.; RUTKOWSKI, T. M. Single trial BCI classification accuracy improvement for the novel virtual sound movement-based spatial auditory paradigm. **2013 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference, APSIPA 2013**, 2013. <https://doi.org/10.1109/APSIPA.2013.6694317>

LEMM, S.; BLANKERTZ, B.; DICKHAUS, T.; MÜLLER, K. R. Introduction to machine learning for brain imaging. **NeuroImage**, v. 56, n. 2, p. 387–399, 2011. Elsevier Inc. Disponível em: <https://doi.org/10.1016/j.neuroimage.2010.11.004>

LI, S.; ZHOU, W.; YUAN, Q.; GENG, S.; CAI, D. Feature extraction and recognition of ictal EEG using EMD and SVM. **Computers in Biology and Medicine**, v. 43, n. 7, p. 807–816, 2013. Elsevier. Disponível em: <https://doi.org/10.1016/j.compbiomed.2013.04.002>

LOPES-DOS-SANTOS, Vítor et al. Extracting information from the shape and spatial distribution of evoked potentials. **Journal of neuroscience methods**, v. 296, p. 12–22, 2018. <https://doi.org/10.1016/j.jneumeth.2017.12.014>

LOTTE, F.; CONGEDO, M.; LÉCUYER, A.; LAMARCHE, F.; ARNALDI, B. A review of classification algorithms for EEG-based brain-computer interfaces. **Journal of Neural Engineering**, v. 4, n. 2, 2007. <https://doi.org/10.1088/1741-2560/4/2/R01>

MACHADO. Progress and Prospects in EEG-Based Brain-Computer Interface: Clinical Applications in Neurorehabilitation. **Journal of Rehabilitation Robotics**, p. 28–41, 2013. <https://doi.org/10.12970/2308-8354.2013.01.01.4>

MAMMONE, N.; LA FORESTA, F.; MORABITO, F. C. Automatic artifact rejection from multichannel scalp EEG by wavelet ICA. **IEEE Sensors Journal**, v. 12, n. 3, p. 533–542, 2012. <https://doi.org/10.1109/JSEN.2011.2115236>

MANYAKOV, N. V.; CHUMERIN, N.; COMBAZ, A.; VAN HULLE, M. M. Comparison of linear classification methods for P300 brain-computer interface on disabled subjects. **BIOSIGNALS 2011 - Proceedings of the International Conference on Bio-Inspired Systems and Signal Processing**, v. 2011, p. 328–334, 2011. <https://doi.org/10.1155/2011/519868>

MARIANO, D. T. G.; FREITAS, A. M.; LUIZ, L. M. D.; et al. An accelerometer-based human computer interface driving an alternative communication system. **ISSNIP Biosignals and Biorobotics Conference, BRC**, p. 1–5, 2014. <https://doi.org/10.1109/BRC.2014.6880985>

MCFARLAND, D. J.; WOLPAW, J. R. Brain-computer interfaces for communication and control. **Communications of the ACM**, v. 54, n. 5, p. 60–66, 2011. <https://doi.org/10.1145/1941487.1941506>

MULLER, K.-R.; ANDERSON, Charles W.; BIRCH, Gary E. Linear and nonlinear methods for brain-computer interfaces. **IEEE transactions on neural systems and rehabilitation engineering**, v. 11, n. 2, p. 165–169, 2003. <https://doi.org/10.1109/TNSRE.2003.814484>

MURGUIALDAY, A. R.; HILL, J.; BENSCH, M.; et al. Transition from the locked in to the completely locked-in state: A physiological analysis. **Clinical Neurophysiology**, v. 122, n. 5, p. 925–933, 2011. International Federation of Clinical Neurophysiology. Disponível em: <https://doi.org/10.1016/j.clinph.2010.08.019>

NAGEL, S.; SPÜLER, M. World's fastest brain-computer interface: Combining EEG2Code with deep learning. **Plos One**, v. 14, n. 9, p. e0221909, 2019. <https://doi.org/10.1371/journal.pone.0221909>

NAKANISHI, M.; WANG, YIJUN; CHEN, X.; et al. Enhancing detection of SSVEPs for a high-speed brain speller using task-related component analysis. **IEEE Transactions on Biomedical Engineering**, v. 65, n. 1, p. 104–112, 2018. IEEE. <https://doi.org/10.1109/TBME.2017.2694818>

NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. **Sensors**, v. 12, n. 2, p. 1211–1279, 2012. <https://doi.org/10.3390/s120201211>

NIJBOER, F.; FURDEA, A.; GUNST, I.; et al. An auditory brain-computer interface (BCI). **Journal of Neuroscience Methods**, v. 167, n. 1, p. 43–50, 2008. <https://doi.org/10.1016/j.jneumeth.2007.02.009>

NOSHADI, S.; ABOOTALEBI, V.; SADEGHI, M. T.; SHAHVAZIAN, M. S. Selection of an

efficient feature space for EEG-based mental task discrimination. **Biocybernetics and Biomedical Engineering**, v. 34, n. 3, p. 159–168, 2014. Korea Institute of Oriental Medicine. Disponível em: <https://doi.org/10.1016/j.bbe.2014.03.004>

OLSON, T.; OLSON, T. **Digital Communications**. Ninth Edit ed. Butterworth-Heinemann, 2017. https://doi.org/10.1007/978-1-4939-7393-4_6

ONISHI, A.; TAKANO, K.; KAWASE, T.; ORA, H.; KANSAKU, K. Affective stimuli for an auditory P300 brain-computer interface. **Frontiers in Neuroscience**, v. 11, n. SEP, p. 1–9, 2017. <https://doi.org/10.3389/fnins.2017.00522>

PEREIRA, Roberto Dias Batista. Epidemiologia: ELA no mundo. **Revista Neurociências**, v. 14, p. 9-13, 2006.

POLICH, J. Updating P300: An integrative theory of P3a and P3b. **Clinical Neurophysiology**, v. 118, n. 10, p. 2128–2148, 2007. <https://doi.org/10.1016/j.clinph.2007.04.019>

RAMADAN, R. A.; VASILAKOS, A. V. Brain computer interface: control signals review. **Neurocomputing**, v. 223, n. October 2016, p. 26–44, 2017. Elsevier. Disponível em: <https://doi.org/10.1016/j.neucom.2016.10.024>

RAVDEN, D.; POLICH, J. On P300 measurement stability: Habituation, intra-trial block variation, and ultradian rhythms. **Biological Psychology**, v. 51, n. 1, p. 59–76, 1999. [https://doi.org/10.1016/S0301-0511\(99\)00015-0](https://doi.org/10.1016/S0301-0511(99)00015-0)

SIQUEIRA, A. L. D.; SOARES, A. B. A novel method for EMG decomposition based on matched filters. **Revista Brasileira de Engenharia Biomedica**, v. 31, n. 1, p. 44–55, 2015. <https://doi.org/10.1590/2446-4740.0643>

SPATARO, R.; CIRIACONO, M.; MANNO, C.; LA BELLA, V. The eye-tracking computer device for communication in amyotrophic lateral sclerosis. **Acta Neurologica Scandinavica**, v. 130, n. 1, p. 40–45, 2014. <https://doi.org/10.1111/ane.12214>

SPIRANDELI, A; MARREGA, L.; SIQUEIRA, A.; SOARES, A. An auditory event-related potential encoder. **Congresso de Engenharia Biomédica**, 2018. https://doi.org/10.1007/978-981-13-2517-5_79

SUGI, M.; HAGIMOTO, Y.; NAMBU, I.; et al. Improving the Performance of an Auditory Brain-Computer Interface Using Virtual Sound Sources by Shortening Stimulus Onset Asynchrony. **Frontiers in Neuroscience**, v. 12, n. February, p. 1–11, 2018. <https://doi.org/10.3389/fnins.2018.00108>

THOMPSON, D. E.; WARSCHAUSKY, S.; HUGGINS, J. E. Classifier-based latency estimation: A novel way to estimate and predict BCI accuracy. **Journal of Neural**

Engineering, v. 10, n. 1, 2013. <https://doi.org/10.1088/1741-2560/10/1/016006>

TURIN, G. An introduction to matched filters. *Information Theory, IRE Transactions on*, v. 6, n. 3, p. 311–329, jun. 1960. <https://doi.org/10.1109/TIT.1960.1057571>

TURNIP, A.; HONG, K. S.; JEONG, M. Y. Real-time feature extraction of P300 component using adaptive nonlinear principal component analysis. **BioMedical Engineering Online**, v. 10, p. 1–20, 2011. <https://doi.org/10.1186/1475-925X-10-83>

WANG, T.; LIN, L.; ZHANG, A.; PENG, X.; ZHAN, C. A. EMD-based EEG signal enhancement for auditory evoked potential recovery under high stimulus-rate paradigm. **Biomedical Signal Processing and Control**, v. 8, n. 6, p. 858–868, 2013. Elsevier Ltd. Disponível em: <https://doi.org/10.1016/j.bspc.2013.08.004>

WANG, Z.; WU, L.; QI, Y.; JIANG, Z. Methods of EEG Signal Features Extraction Using Linear Analysis. **Applied Surface Science**, v. 256, n. 11, p. 3443–3447, 2010. <https://doi.org/10.1016/j.apsusc.2009.12.050>

WOLPAW, J. R.; MCFARLAND, D. J.; VAUGHAN, T. M. 2 Noninvasive Brain-Computer Interface Research at the Wadsworth Center. **Toward Brain-Computer Interfacing**, v. 8, n. 2, p. 222–226, 2019. <https://doi.org/10.1109/86.847823>

YAO, L.; MENG, J.; ZHANG, D.; SHENG, X.; ZHU, X. Selective Sensation Based Brain-Computer Interface via Mechanical Vibrotactile Stimulation. **PLoS ONE**, v. 8, n. 6, 2013. <https://doi.org/10.1371/journal.pone.0064784>

YIN, E.; ZEYL, T.; SAAB, R.; et al. An Auditory-Tactile Visual Saccade-Independent P300 Brain-Computer Interface. **International Journal of Neural Systems**, v. 26, n. 1, p. 1–16, 2016. <https://doi.org/10.1142/S0129065716500015>

YU, X.; CHUM, P.; SIM, K. B. Analysis the effect of PCA for feature reduction in non-stationary EEG based motor imagery of BCI system. **Optik**, v. 125, n. 3, p. 1498–1502, 2014. Elsevier GmbH. Disponível em: <https://doi.org/10.1016/j.ijleo.2013.09.013>

ZHAOJUN XUE; JIA LI; SONG LI; BAIKUN WAN. Using ICA to Remove Eye Blink and Power Line Artifacts in EEG. , p. 107–110, 2006.