



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ELETRÔNICA E SISTEMAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DIOGO ROBERTO RAPOSO DE FREITAS

**PLATAFORMA PARA ANÁLISE DO SINAL DE EEG APLICADO AO
ERD/ERS NO RECONHECIMENTO EM TEMPO REAL DA
IMAGINAÇÃO DO MOVIMENTO**

Recife

2017

DIOGO ROBERTO RAPOSO DE FREITAS

**PLATAFORMA PARA ANÁLISE DO SINAL DE EEG APLICADO AO
ERD/ERS NO RECONHECIMENTO EM TEMPO REAL DA
IMAGINAÇÃO DO MOVIMENTO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Engenharia Elétrica.

Área de concentração: Eletrônica.

Orientador: Prof^o. Dr^o. Marco Aurélio Benedetti Rodrigues.

Recife

2017

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

F866p Freitas, Diogo Roberto Raposo de.
Plataforma para análise do sinal de EEG aplicado ao ERD/ERS no reconhecimento em tempo real da imaginação do movimento / Diogo Roberto Raposo de Freitas. – 2017.
139 folhas, il., gráfs., tabs.

Orientador: Prof. Dr. Marco Aurélio Benedetti Rodrigues.

Tese (Doutorado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2017.
Inclui Referências e Apêndice.

1. Engenharia Elétrica. 2. Eletroencefalografia. 3. Instrumentação Biomédica. 4. Processamento de Sinais Bioelétricos. 5. BCI. 6. DWT. 7. FPGA. 8. ERD/ERS. 9. Sistemas Embarcados. I. Rodrigues, Marco Aurélio Benedetti. (Orientador). II. Título.

UFPE

621.3 CDD (22. ed.)

BCTG/2019-147

DIOGO ROBERTO RAPOSO DE FREITAS

**PLATAFORMA PARA ANÁLISE DO SINAL DE EEG APLICADO AO
ERD/ERS NO RECONHECIMENTO EM TEMPO REAL DA
IMAGINAÇÃO DO MOVIMENTO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Engenharia Elétrica.

Aprovada em: 07/12/2017.

BANCA EXAMINADORA

Prof^o. Dr^o. Marco Aurélio Benedetti Rodrigues (Orientador)
Universidade Federal de Pernambuco

Prof^a. Dr^a. Fernanda Maria Ribeiro de Alencar (Examinadora Interna)
Universidade Federal de Pernambuco

Prof^o. Dr^o. Marcos Tavares de Melo (Examinador Interno)
Universidade Federal de Pernambuco

Prof^o. Dr^o. Hélio Magalhães de Oliveira (Examinador Externo)
Universidade Federal de Pernambuco

Prof^a. Dr^a. Patrícia Silva Lessa (Examinadora Externa)
Universidade Federal de Pernambuco

Dedico este trabalho a Deus, a minha linda esposa Emanuely, a meus lindos filhos Guilherme, Gabriella e João Gabriel, e a meus lindos e amáveis pais Dilson e Rosa.

AGRADECIMENTOS

Agradeço a Deus por sua infinita misericórdia, por ter nos concedido saúde e forças para realizar este trabalho.

Agradeço a minha linda família pelo apoio e compreensão no momentos de dedicação a este projeto, e pelas palavras de ânimo nos momentos difíceis.

Agradeço a meu orientador e amigo Prof. Marco Aurélio Benedetti pela paciência, apoio e direcionamento nesta longa jornada que foi esta tese.

Um agradecimento especial ao meu amigo André Oliveira pela confiança de longa data de que este trabalho seria concluído.

Aos colegas do Grupo de Pesquisa em Engenharia Biomédica (GPEB – UFPE) pela torcida, companhia e por estarem sempre dispostos a ajudar. Como são muitos gostaria de não deixar nenhum de fora destes agradecimentos.

Agradeço ao apoio e compreensão do Eng. Bruno R. Cunha, e aos Prof. Marcílio Félix e Gustavo Oliveira.

Agradeço ao Prof. Ricardo Ataíde pelas palavras de ânimo nos momentos certos. E a Profa. Marilú Gomes pelas informações pertinentes ao trabalho.

Agradeço aos professores da banca examinadora pela gentileza em ceder seu precioso tempo para avaliar esta tese de doutorado.

Ao Coord. e Secretária do PPGEE-UFPE, o Prof. Marcelo Cabral e a Sra Andréa Tenório.

Esperamos que este trabalho seja benéfico para muitos seres.

*Manopubbaṅgamā dhammā
manoseṭṭhā manomayā*

“A mente é precursora de todos os fenômenos mentais;
a mente é seu criador; eles são criados pela mente.”

Dhammapada verso 1

RESUMO

Dispositivos portáteis para aquisição e processamento digital de sinais de eletroencefalografia (EEG) são peças fundamentais para construção de Interfaces Cérebro Máquina (BCI – *Brain Computer Interface*). Estas interfaces possibilitam o acionamento de dispositivos eletromecânicos controlados via pensamento e possuem diversas aplicações: reabilitação motor-neural de pacientes com limitações de movimento; equipamentos para intervenções em processos industriais/militares perigosos; entretenimento. Este trabalho propõe uma plataforma para aquisição de EEG e processamento digital em FPGA (*Field Programmable Gate Array*), com a finalidade de reconhecer a imaginação do movimento (IM) das mãos em tempo real e possibilitar um *feedback* visual. Construiu-se um amplificador de dois canais específico para captação analógica do sinal de EEG. O tratamento digital dos dados foi realizado através da implantação de um algoritmo adaptado da transformada *wavelet* discreta Daubechies-4, capaz de decompor o EEG em suas faixas de frequência constituintes β , α , θ e δ . Em seguida, o sistema executa o escalograma em hardware e classifica os sinais de forma síncrona medindo a ERD/ERS (*Event Related Desynchronization/Synchronization*) para identificar de forma online a IM da mão direita ou esquerda pelo método de *threshold*. A técnica foi aplicada em sinais gravados de um banco de dados de três indivíduos e em sinais adquiridos diretamente de um voluntário. Os resultados foram comparados com algoritmos *offline* e mostram a viabilidade do processo. O sistema reconhece a IM e indica qual das mãos foi imaginada. A principal contribuição desta tese é uma ferramenta para trabalhar com ERD/ERS através de uma plataforma embarcada para reconhecimento de IM em tempo real com *feedback* visual, não invasiva, construída com hardware reconfigurável, que funciona à bateria e possui canal de comunicação sem fio.

Palavras-chave: EEG. Instrumentação biomédica. Processamento de sinais bioelétricos. BCI. DWT. FPGA. ERD/ERS. Sistemas embarcados.

ABSTRACT

Portable devices for EEG digital processing are key components of a BCI (Brain Computer Interfaces). These interfaces allows activation of mechanical devices controlled by thought and have many applications: motor-neural rehabilitation; equipments for intervention in industrial and military processes; entertainment. In this work, it is proposed an EEG acquisition and FPGA digital processing platform to recognize real-time hand movement imagination (MI) and performs visual feedback. For EEG analog acquisition a dedicated two channels amplifier was built. Digital processing was carried out by a modified Daubechies-4 discrete wavelet transform (DWT) algorithm, capable of decomposing EEG into its constituent frequency bands β , α , θ and δ . The scalogram was run in hardware to signal classification by ERD/ERS (Event Related Desynchronization/ Synchronization), to identify right or left hand MI online by threshold method. The technique was applied on recorded signals from a database of three individuals and on real signals from a volunteer. The results were compared with offline algorithms and show the process feasibility, as system recognise MI and indicates which hand was imagined. This thesis presents an embedded system for real-time MI recognition and visual feedback, noninvasive, built with reconfigurable hardware, which works on battery and has a wireless communication channel.

Keywords: EEG. Biomedical instrumentation. Biomedical signal processing. BCI. DWT. FPGA. ERD/ERS. Embedded systems.

LISTA DE SIGLAS

EEG	Eletroencefalografia
ERD	<i>Event Related Desynchronization</i>
ERS	<i>Event Related Synchronization</i>
IM	Imaginação do movimento
BCI	<i>Brain Computer Interface</i>
ERP	<i>Event Related Potentials</i>
PC	<i>Personal Computer</i>
FPGA	<i>Field Programmable Gate Array</i>
SNC	Sistema Nervoso Central
DAC	<i>Digital to Analog Converter</i>
DSP	<i>Digital Signal Processor</i>
HDL	<i>Hardware Description Language</i>
ADC	<i>Analog to Digital Converter</i>
CI	Circuito Integrado
SPI	<i>Serial Peripheral Interface</i>
VGA	<i>Video Graphical Adapter</i>
bps	<i>bits per second</i>
UART	<i>Universal Asynchronous Receiver Transmitter</i>
ISM	<i>Industrial, Scientific and Medical Radio Bands</i>
RTL	<i>Register Transfer Logic</i>
ULA	Unidade Lógico-Aritmética
SSVEP	<i>Steady State Visually Evoked Potential</i>
EOG	Eletro-oculografia
MRCP	<i>Movement Related Cortical Potentials</i>
EMG	Eletromiografia
MEG	Magneto-eletroencefalografia
CWT	<i>Continuous Wavelet Transform</i>
DWT	<i>Discrete Wavelet Transform</i>
WPS	<i>Wavelet Power Spectrum</i>
TAWPS	<i>Time Average Wavelet Power Spectrum</i>

SUMÁRIO

1	INTRODUÇÃO	12
1.1	MOTIVAÇÃO.....	13
1.2	OBJETIVO GERAL	14
1.3	OBJETIVOS ESPECÍFICOS	14
1.4	ESTRUTURA DO TEXTO	14
2	ELETOENCEFALOGRAFIA APLICADA EM BCI	15
2.1	FISIOLOGIA BÁSICA DO SISTEMA NERVOSO HUMANO	15
2.2	EEG	19
2.3	AQUISIÇÃO DE SINAIS DE EEG	20
2.4	INTERFACE CÉREBRO-MÁQUINA (BCI)	25
2.5	ANÁLISE DE SINAIS DE EEG USANDO TÉCNICAS DIGITAIS PARA CONSTRUÇÃO DE BCI	29
2.6	FPGA	37
2.7	ESTADO DA ARTE DAS BCI BASEADAS EM EEG	39
2.8	CONSIDERAÇÕES FINAIS	42
3	PLATAFORMA PARA RECONHECIMENTO DE IM DAS MÃOS EM TEMPO REAL	45
3.1	ESPECIFICAÇÕES DO SISTEMA	45
3.2	DIAGRAMA EM BLOCOS DA PLATAFORMA PROPOSTA	47
3.3	SUBSISTEMA DIGITAL CONSTRUÍDO NO FPGA	51
3.4	ALGORITMO PARA CÁLCULO DOS COEFICIENTES DA <i>WAVELET</i> DAUBECHIES-4	57
3.5	CÁLCULO DA ENERGIA DA ONDA α	64
3.6	ALGORITMO DE CLASSIFICAÇÃO	66
3.7	CONSIDERAÇÕES FINAIS	69
4	RESULTADOS	70
4.1	SINAIS DE EEG DE BASE DE DADOS E SINAIS REAIS PARA TESTE DO ALGORITMO DA <i>WAVELET</i>	70
4.2	CÁLCULOS DE ERRO E CORRELAÇÃO DOS COEFICIENTES DA <i>WAVELET</i>	75
4.3	CORRELAÇÃO ENTRE A ENERGIA CALCULADA PELO FPGA E O	77

	MATLAB	
4.4	RECONHECIMENTO DE IM DAS MÃOS A PARTIR DE SINAIS DE BASE DE DADOS	80
4.5	RECONHECIMENTO DE IM DAS MÃOS A PARTIR DE SINAIS DE EEG DE UM VOLUNTÁRIO	84
4.6	VELOCIDADE DE PROCESSAMENTO E QUANTIDADE DE RECURSOS CONSUMIDOS DO FPGA	88
4.7	CONSIDERAÇÕES FINAIS	88
5	CONCLUSÃO	90
5.1	TRABALHOS FUTUROS	91
	REFERÊNCIAS	93
	APÊNDICE A - TABELAS COMPARATIVAS ENTRE OS CÁLCULOS DO ALGORITMO DO FPGA E DO MATLAB	119

1 INTRODUÇÃO

Uma interface cérebro computador (BCI – *Brain Computer Interface*, nomenclatura comumente utilizada na literatura) é um sistema que possui como entrada sinais bioelétricos provenientes da atividade cerebral e a saída controla dispositivos eletromecânicos ou virtuais. A pesquisa e o desenvolvimento de BCIs vem atraindo, nos últimos anos, investimentos de grupos de pesquisa e empresas mundo afora [1] [2] [3]. Atualmente existem diversas aplicações para as BCIs: reabilitação de pacientes com membros amputados ou lesões no sistema nervoso central que possuem limitações de movimento [1], comunicação, robótica, processos industriais e militares perigosos para o ser humano e entretenimento [4] [5] [6] [7].

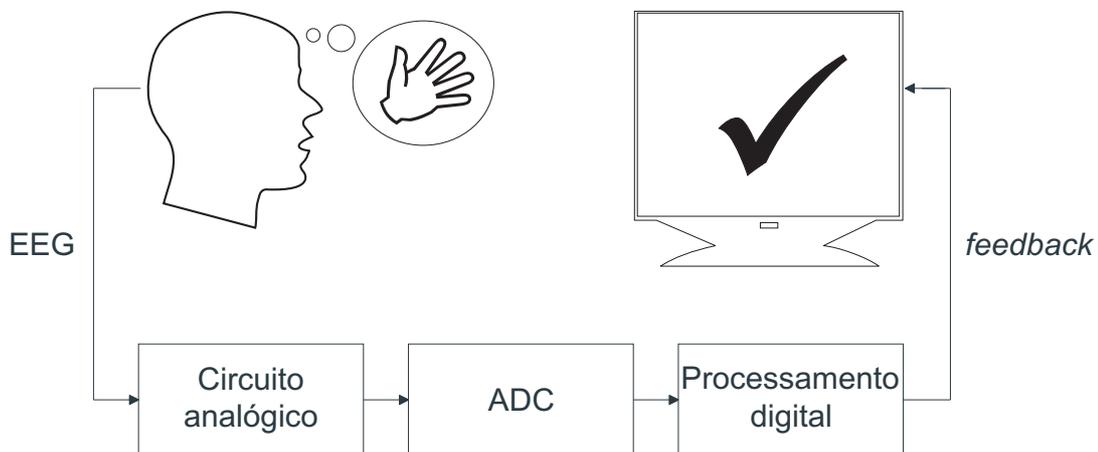
As BCIs são classificadas de acordo com a forma de aquisição dos sinais cerebrais, pelo tipo de interação que o operador deve ter com o sistema (chamada paradigma), e pela aplicação [8]. A forma de aquisição pode ser invasiva ou não invasiva, e dentre as não invasivas está a eletroencefalografia (EEG). Nesta modalidade, pode-se controlar uma BCI pela imaginação de movimento (IM), por potenciais evocados (ERP – *Event Related Potentials*) que são obtidos a partir de estímulos sensoriais visuais ou sonoros, ou por atividades cognitivas como cálculo mental, rotação mental de objetos, escrita ou contagem mentais [8] [9]. As aplicações das BCIs controladas por EEG incluem o controle de equipamentos e dispositivos como braço robótico, helicópteros portáteis ou virtuais, cama hospitalar ou cadeira de rodas, soletradores (*spellers*) e controle de ponteiro de *mouse* em computadores [8] [10] [11].

Para construção de BCI que utilize EEG para controlar um dispositivo via IM deve-

se adotar um sistema *online*, para reconhecimento de padrões em tempo real [12]. E para reconhecer padrões no sinal de EEG, deve-se antes treinar o sistema, para que sejam armazenadas as características desejadas do sinal de EEG para comparação posterior [13]. Na maior parte da literatura, as BCIs *online* empregam um computador pessoal (PC – *Personal Computer*) para executar os cálculos e apresentação gráfica dos sinais.

Este trabalho aborda a técnica de reconhecimento de IM das mãos em tempo real via FPGA, para construção de BCI *online*. Com esta finalidade foi construído um dispositivo portátil que adquire o EEG, digitaliza o sinal, executa o reconhecimento de padrões e transmite os resultados para um monitor de vídeo para *feedback* visual, sem a necessidade de um PC. A Fig. 1.1 ilustra o fluxo de processamento do sinal de EEG, desde a IM das mãos até a resposta do sistema para o operador.

Figura 1.1 – Esquema geral da plataforma de *hardware* desenvolvida.



Fonte: autor.

1.1 MOTIVAÇÃO

A maior parte dos estudos relacionados com BCIs controladas via IM utilizam um PC executando *softwares* de alto nível para reconhecimento de padrões, devido à complexidade dos algoritmos [14] [15]. Os computadores utilizados são de uso geral e possuem alto poder de processamento, porém são fisicamente maiores e consomem mais energia em comparação com sistemas dedicados. Além disso, são necessários fios e cabos para levar os sinais ao sistema de processamento, gerando interferências no registro do EEG. O resultado deste método é uma arquitetura de *hardware* dependente de equipamentos comerciais para aquisição do sinal e plataformas de *software* baseadas em PC, que impossibilitam a livre movimentação do indivíduo que utiliza a BCI, ou o faz de forma limitada.

A proposta deste projeto é desenvolver um sistema portátil, de funcionamento independente de um PC, capaz de realizar a aquisição de EEG, filtragem, conversão do sinal

análogo para digital e processamento em *hardware* para identificação de padrões no registro de EEG em tempo real, para reconhecer IM das mãos, e que permite a transmissão sem fio dos padrões para um dispositivo de registro remoto de grande porte.

1.2 OBJETIVO GERAL

Desenvolvimento de plataforma embarcada que implementa técnicas para aquisição e tratamento de sinais em *hardware* para reconhecimento de IM das mãos via análise em tempo real do sinal de EEG, permitindo *feedback* visual.

1.3 OBJETIVOS ESPECÍFICOS

Os objetivos específicos deste trabalho são:

1. Construir um dispositivo portátil para aquisição de EEG, incluindo as etapas analógicas de amplificação, filtragem do sinal e digitalização (conversão analógico para digital).
2. Desenvolver e implementar um algoritmo de identificação de padrões através da decomposição em *wavelets*, cálculo do escalograma (WPS – *Wavelet Power Spectrum*) e classificação via ERD/ERS em FPGA, permitindo *feedback* visual por uma interface de vídeo.
3. Possibilitar transmitir sem fio o sinal do EEG processado para um PC remoto para armazenamento dos dados.

1.4 ESTRUTURA DO TEXTO

Este trabalho está dividido em cinco capítulos. A Introdução apresenta um panorama do assunto em conjunto com o objetivo geral e os específicos. No Capítulo 2, é realizada uma revisão bibliográfica das técnicas de processamento de sinal de EEG aplicadas em BCI. O Capítulo 3 apresenta as técnicas e ferramentas utilizadas para construção do sistema que realiza a aquisição e decomposição do sinal de EEG em *wavelets*, cálculos e classificação de IM das mãos, e a infraestrutura utilizada. Os resultados obtidos com sinais de banco de dados *online* e com aquisição de sinais reais de EEG em um voluntário são abordados no Capítulo 4, incluindo a discussão destes resultados. As considerações finais e trabalhos futuros finalizam o texto no Capítulo 5.

2 ELETROENCEFALOGRAFIA APLICADA EM BCI

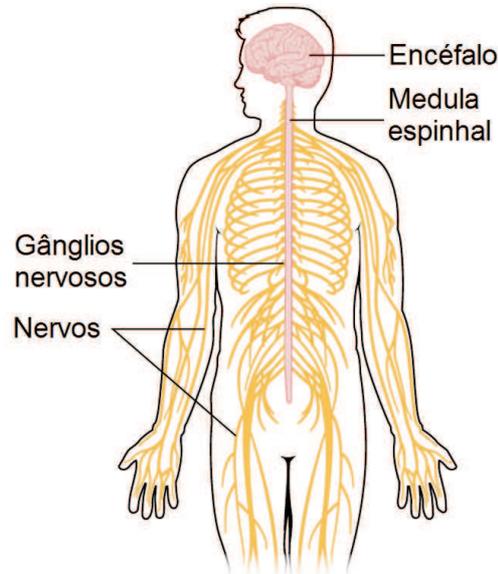
Este Capítulo embasa tecnicamente o desenvolvimento do projeto, e nele os principais conceitos e definições são apresentados. São abordados os impulsos nervosos e o surgimento do sinal de EEG. Em seguida, são discutidas as características e tipos de BCI. Mais adiante, são abordadas as técnicas de análise de sinais de EEG para reconhecimento de padrões e sua implementação em FPGA. Por fim, é realizada uma revisão sistemática da literatura para dar uma visão geral do estado da arte das BCI baseadas em EEG.

2.1 FISILOGIA BÁSICA DO SISTEMA NERVOSO HUMANO

O sistema nervoso humano é composto pelo sistema nervoso central (SNC) e o periférico (SNP) [16] [17]. O SNC engloba o encéfalo e a medula espinhal (Fig. 2.1). O encéfalo encontra-se dentro da caixa encefálica (ou crânio) e é dividido em cérebro, cerebelo, diencefalo — contendo o tálamo e o hipotálamo, e tronco cerebral [18]. O córtex cerebral é a camada mais externa do cérebro, possuindo de 1 a 5 mm de espessura e aproximadamente 100 bilhões de neurônios [19] [20] [21]. Existe literatura abrangente afirmando que essa região é a mais recente na evolução da espécie humana [20] [22] [23] [24].

O córtex cerebral é anatomicamente dividido em lobos representados na Fig. 2.2. Estes lobos possuem regiões que são especializadas em determinadas funções. Existem áreas específicas para a visão no lobo occipital; linguagem, pensamento e audição nos lobos temporal e parietal; sentidos e movimentos voluntários no córtex sensorial e córtex motor

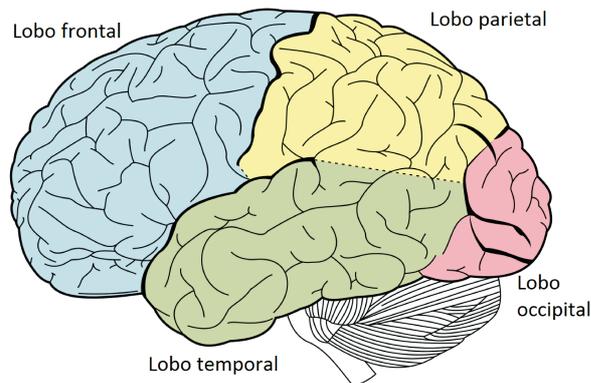
Figura 2.1 – O sistema nervoso humano é formado pelo sistema nervoso central (encéfalo e medula espinhal) e o periférico (nervos e gânglios).



Fonte: adaptado de cnx.org/resources/37beec4ad5ed1d7d66aa510af01f5abf5d0070c8/1201_Overview_of_Nervous_System.jpg. Acessado em 15 fev. 2016.

respectivamente, adjacentes ao sulco central do cérebro, que fica entre o lobo parietal e frontal [25].

Figura 2.2 – Anatomia do córtex cerebral evidenciando os lobos cerebrais.



Fonte: adaptado de upload.wikimedia.org/wikipedia/commons/thumb/0/0e/Lobes_of_the_brain_NL.svg/1280px-Lobes_of_the_brain_NL.svg.png. Acessado em 6 mar. 2016.

O córtex motor se encontra no lobo frontal, e adjacente a ele existem duas áreas relacionadas ao movimento voluntário do corpo chamadas córtex pré-motor e área motora suplementar. Regiões específicas associadas com o movimento das mãos, dedos, punho, pés, músculos da face e vocalização estão localizadas no córtex motor [19] [26], enquanto que o córtex pré-motor e a área motora suplementar estão envolvidos em atividades “complexas”, que exigem múltiplos movimentos de forma sequencial memorizadas

com antecedência [27] [28].

A atividade cerebral gera milhões de impulsos nervosos simultâneos provenientes dos neurônios. Esses impulsos se irradiam do córtex cerebral até o couro cabeludo na superfície do crânio, e podem ser medidos por meio do sinal de EEG. Os neurônios são as células fundamentais do sistema nervoso [17] e possuem a característica de propagar os impulsos nervosos. Podem ser divididos anatomicamente em três partes básicas: o corpo celular (ou soma), dendritos e axônio. Nos dendritos estão localizadas as sinapses, que realizam a comunicação entre os neurônios [29].

A atividade elétrica neuronal surge a partir da diferença de concentração de íons, principalmente sódio (Na^+) e potássio (K^+), que se acumulam na membrana celular em proporções diferentes no líquido intra-celular (LIC) e no líquido extra-celular (LEC) (vide Tabela 2.1 e Fig. 2.3). Na membrana existem canais seletivos que permitem a passagem de determinados íons. Os mais importantes para a propagação de impulsos nervosos são os canais passivos de sódio e de potássio. Eles permitem a passagem de íons quando ocorrem variações específicas de potencial elétrico na membrana celular. Uma vez abertos os canais de sódio permitem a entrada de íons Na^+ para o interior da célula, enquanto que os canais de potássio conduzem os íons K^+ para fora, em virtude das diferenças de concentrações iônicas mostradas na Tabela 2.1. Um terceiro canal chamado bomba sódio-potássio (Na^+-K^+) reequilibra as concentrações iônicas consumindo energia da célula na forma de ATP (*Adenosine Tri-Phosphate*). Essa energia é necessária, pois a bomba trabalha contra o gradiente de concentração iônica, retirando íons Na^+ e inserindo íons K^+ no interior da célula [19] [30] [31].

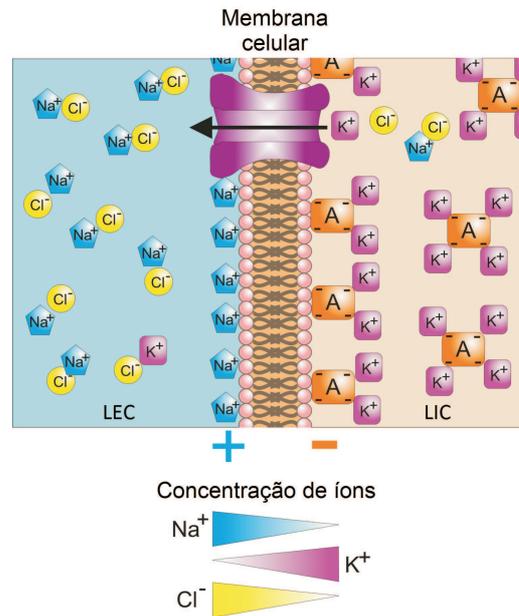
Tabela 2.1 – Concentração dos principais íons no LEC e LIC.

Íon	LEC (mEq/L)	LIC (mEq/L)
Na^+	142	10
K^+	4	140
Cl^-	103	4
Ca^{++}	2,4	0,0001

Fonte: [19] [30] [31].

Quando em repouso, as concentrações iônicas mantêm um potencial em torno de -90 mV no interior da célula, em comparação com o LEC [32]. A excitação ocorre nas sinapses [33] quando o potencial elétrico ultrapassa o valor limiar, que gira em torno de -70 a -50 mV , provocando a despolarização da membrana celular. Neste momento, os canais de sódio se abrem permitindo a entrada destes íons no LIC. O resultado é o aumento do potencial de membrana para $+35\text{ mV}$, conforme gráfico da Fig. 2.4. Esse aumento do potencial ativa os canais de potássio, reduzindo o potencial de membrana aos níveis de repouso (o período refratário é o intervalo de tempo em que os canais de

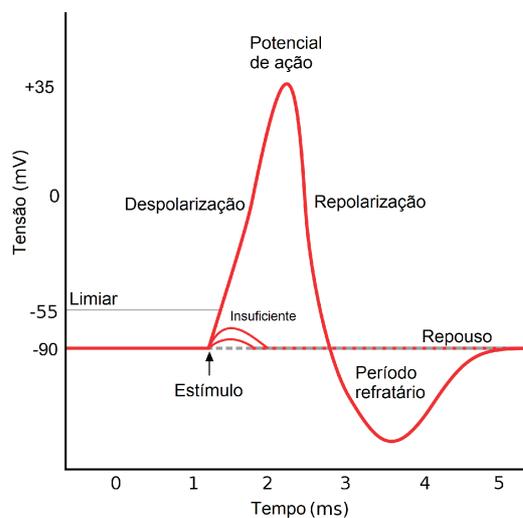
Figura 2.3 – Esquema mostrando a diferença de concentração dos principais íons no LIC e LEC.



Fonte: adaptado de upload.wikimedia.org/wikipedia/commons/f/fb/Basis_of_Membrane_Potential2.png. Acessado em 12 mar. 2016.

potássio ainda estão abertos). As concentrações normais de Na^+ e K^+ são restabelecidas por meio das bombas sódio-potássio [19]. Uma vez iniciada a despolarização, ela se propaga para as regiões adjacentes e se estende por toda a membrana, em especial ao longo do axônio. Portanto, chama-se impulso nervoso a propagação da despolarização e consequente repolarização da membrana celular.

Figura 2.4 – Potencial de ação em um membrana celular neuronal.



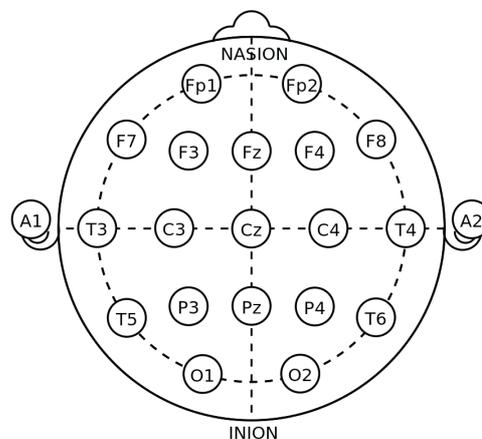
Fonte: adaptado de upload.wikimedia.org/wikipedia/commons/thumb/4/4a/Action_potential.svg/2000px-Action_potential.svg.png. Acessado em 16 mar. 2016.

Os impulsos nervosos transmitem as informações sensoriais recebidas pelo corpo até o córtex sensorial. Da mesma forma, os movimentos voluntários são enviados do córtex motor até os músculos. Os processos de pensamento, cognição e as demais atividades cerebrais autônomas são transmitidas entre os neurônios via impulsos nervosos [18].

2.2 EEG

Atribui-se a Beger [34] [35] [36] em 1929 o primeiro registro de EEG em humanos. Trata-se de uma técnica não invasiva de registro da atividade elétrica cerebral [37] [38]. Eletrodos são fixados sobre o couro cabeludo e posicionados de forma sistemática para captar pequenos sinais elétricos, que têm amplitude em torno de $1\mu\text{V}$ podendo chegar a $100\mu\text{V}$, e frequências entre 0,1 Hz e 50 Hz. O método pioneiro de posicionamento dos eletrodos, e mais comum, é o Sistema 10-20 [39], ilustrado na Fig. 2.5. Este sistema capta os sinais elétricos de cada parte do cérebro utilizando 19 eletrodos: frontal Fp1, Fp2, F3, F4, F7, F8 e Fz; central C3, Cz e C4; parietal P3, Pz e P4; temporal T3, T4, T5 e T6; e occipital O1 e O2. Os eletrodos pares ficam no lado direito e os ímpares no lado esquerdo da cabeça.

Figura 2.5 – Sistema 10-20 para localização dos eletrodos de EEG



Fonte: adaptado de upload.wikimedia.org/wikipedia/commons/7/70/21_electrodes_of_International_10-20_system_for_EEG.svg. Acessado em 29 fev. 2016.

Quando se analisa o espectro de frequências do sinal de EEG, nota-se que é composto por faixas de frequências específicas chamadas ondas ou ritmos, que variam em amplitude. São classificadas conforme Tabela 2.2.

As ondas do sinal de EEG refletem alguns estados do indivíduo. Por exemplo, as ondas beta são características quando em estado de alerta (vigília). As ondas alfa são observadas mais facilmente na região posterior da cabeça (occipital) quando o indivíduo está acordado e relaxado, com olhos fechados. Ondas teta refletem estados cognitivos e de concentração em adultos e crianças [40] [41]. Durante o sono ocorrem as ondas delta [46].

Tabela 2.2 – Classificação das ondas do sinal de EEG.

Onda	Frequência (Hz)	Amplitude (μV)
Beta (β)	13 a 30	≈ 10
Alfa (α)	8 a 13	< 50
Teta (θ)	4 a 8	< 100
Delta (δ)	0,5 a 4	75 a 100

Fonte: [19] [35] [45].

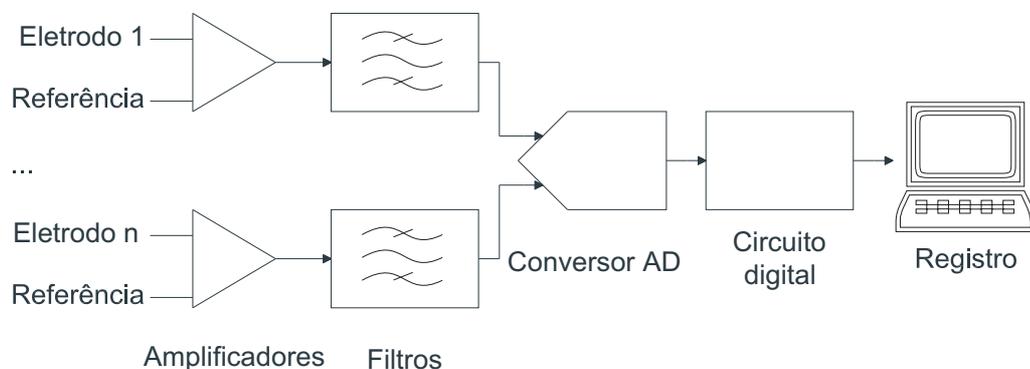
Além de pesquisas para construção de BCI como método não invasivo, o EEG possui aplicações em epilepsia [35], distúrbios do sono [47], pacientes psiquiátricos, profundidade da anestesia durante procedimentos cirúrgicos, detecção de fadiga [51], entretenimento [50], memória e estados cognitivos [48] e detecção de emoções [49].

2.3 AQUISIÇÃO DE SINAIS DE EEG

Uma sistema moderno de aquisição de EEG pode ser dividido em três blocos [52]: captação e condicionamento analógico de sinal, processamento digital e canais de comunicação.

Para adquirir o sinal de EEG é necessário um aparato eletrônico que inclui eletrodos e cabos, amplificadores de instrumentação, filtros analógicos ativos e passivos e conversores analógico para digital (ADC – *Analog to Digital Converter*). Após a digitalização do sinal este pode ser processado por um microprocessador, FPGA ou DSP (*Digital Signal Processor*). Utiliza-se um ou mais canais de comunicação para encaminhar os resultados do processamento para armazenamento e interação com outros dispositivos. A Fig. 2.6 exemplifica um sistema típico.

Figura 2.6 – Esquema (fluxograma) de um aparato eletrônico típico para aquisição de EEG.



Fonte: adaptado de [52].

Os detalhes construtivos de cada bloco de um circuito de aquisição típico são examinados nas próximas subseções. Para efeito de comparação, uma relação de equipamentos comerciais, com suas características e aplicações, é apresentada no final desta Seção.

Amplificadores

O bloco de captação e condicionamento analógico é composto pelos eletrodos e cabos, amplificadores de instrumentação e de sinal, filtros ativos e passivos, ADC.

Os amplificadores captam a diferença de potencial elétrico entre cada eletrodo e seu respectivo eletrodo de referência. Em uma configuração típica unipolar do Sistema 10-20 o eletrodo A1 é a referência para os eletrodos ímpares e A2 para os pares na Figura 2.5. Existe a configuração bipolar onde cada canal possui sua referência, que pode ser qualquer outro eletrodo do Sistema 10-20 diferente de A1 e A2 [227]. Neste trabalho optou-se pela configuração unipolar.

Um ganho de tensão que varia de 1.000 a 10.000 é aplicado ao sinal de EEG, em razão de sua amplitude ser de algumas dezenas de microvolts. A primeira etapa de amplificação é feita utilizando-se amplificadores de instrumentação, que possuem maior impedância de entrada, taxa de rejeição de modo comum maior e melhor estabilidade térmica em comparação com amplificadores operacionais de uso geral.

Chama-se “canal” cada entrada de amplificador ligado a um eletrodo e sua referência. Pode-se ter de 1 até 256 canais simultâneos, dependendo da aplicação. Para tanto, são empregados sistemas de posicionamento de eletrodos diferentes do Sistema 10-20 [45].

Filtros e ADC

Filtros são utilizados para limitar a frequência do sinal entre 0,5 e 50 Hz, e podem ser passivos ou ativos, sendo o último mais empregado. Para construir os filtros ativos são utilizados amplificadores operacionais de uso geral.

Após o sinal ser filtrado ele passa por um ADC onde é convertido para representação binária, para em seguida ser processado e analisado por circuitos digitais específicos. Os resultados do processamento do sinal são enviados por meio de interfaces de comunicação para um dispositivo de registro e armazenamento de dados.

Eletrodos

Eletrodos são usados para captar as diferenças de potencial elétrico em diferentes partes do couro cabeludo. Eles são aplicados em conjunto com uma solução eletrolítica em forma de gel ou pasta, que serve para diminuir a impedância da interface pele-eleto- do através de um sistema de troca iônica [53]. Isto permite níveis adequados de tensão nas entradas dos amplificadores, além de diminuir ruídos e artefatos no sinal.

Figura 2.7 – Exemplo de eletrodo de EEG comumente usado e seu conector elétrico.



Fonte: neuromedicalsupplies.com/wp-content/uploads/2017/02/7000-0257-00_Compumedics-Gold-Cup-Electrodes-2-pk-White-30-inch.jpg

Os eletrodos mais comuns para aquisição de EEG possuem formato de pequenas conchas e são produzidos com metais tipo prata, prata banhada a ouro, cobre banhado a prata ou ouro, e apenas ouro. A Fig. 2.7 apresenta o formato básico. Para esse tipo de eletrodo deve-se usar uma pasta ou gel salino, uma mistura de cloreto de sódio, cloreto de potássio, carbonato de cálcio, álcoois e ésteres [54], para melhorar a impedância elétrica entre o metal e a pele. Além do gel, a pele do paciente deve ser preparada para remover oleosidade e impurezas, melhorando o contato com o gel e o eletrodo. Na outra extremidade do eletrodo existe a conexão elétrica para o amplificador, e seu formato varia entre diferentes fabricantes.

Deve-se utilizar algum método para fixação dos eletrodos no local correto sobre o couro cabeludo. O próprio gel salino que melhora a impedância da pele fornece uma forma de fixação, pois depois de seco ele fixa o eletrodo no lugar, desde que o paciente permaneça imóvel. Para aplicações que exigem movimentação usa-se uma touca especial para fixar os eletrodos no lugar. Essa touca possui orifícios localizados de forma idêntica ao Sistema 10-20, e servem para colocação dos eletrodos e do gel. A Fig. 2.8 exemplifica estes dois métodos de fixação dos eletrodos.

Os eletrodos abordados até o momento são do tipo passivos. Existe outro tipo de eletrodo chamado ativo [212]. Neste tipo de eletrodo existe um amplificador integrado para diminuir a interferência eletromagnética nos cabos até o amplificador de instrumentação. Porém, a alimentação deve ser levada até o local de aplicação do eletrodo, aumentando seu peso. Eletrodos ativos são sensivelmente mais caros que os passivos, mas os últimos sofrem maior interferência externa, principalmente da rede elétrica e outros equipamentos

Figura 2.8 – Exemplos de métodos de fixação dos eletrodos na cabeça. (a) fixação com gel; (b) fixação com touca.



Fonte: (a) upload.wikimedia.org/wikipedia/commons/d/da/Jen_gets_an_EEG.jpg (b) c1.staticflickr.com/9/8192/8135749317_7a5f46ebb0_b.jpg

próximos. Ao se projetar sistemas de aquisição de EEG deve-se levar em conta estas características, para decidir a melhor relação custo-benefício. Neste trabalho, optou-se por eletrodos passivos metálicos tipo concha ilustrados na Fig. 2.7, juntamente com pasta indicada para EEG.

Os cabos elétricos que levam o sinal dos eletrodos até as entradas dos amplificadores devem ter entre 1 e 2 m de comprimento e ser preferencialmente blindados. Entretanto, existem equipamentos comerciais que utilizam cabos sem blindagem, mas seu comprimento é menor que equipamentos que usam cabos blindados. Os conectores elétricos para a entrada dos amplificadores variam entre os fabricantes.

Uma palavra sobre a confecção das placas de aquisição de EEG empregadas neste trabalho. No desenvolvimento das placas de circuito impresso as boas práticas de construção de circuitos eletrônicos devem ser seguidas. Estas práticas envolvem a aplicação de capacitores de desacoplamento na alimentação dos circuitos integrados, cabos de eletrodos e placas de circuito impresso com blindagem, trilhas de alimentação e sinal mais curtas possíveis, separação da alimentação dos circuitos analógicos e digitais, dentre outras [61]. Sinais de EEG são particularmente susceptíveis à interferências eletromagnéticas externas, principalmente causadas pelas instalações elétricas prediais e por dispositivos eletrônicos próximos (computadores, celulares), e essas ações evitam ou diminuem seus efeitos. Mais detalhes do sistema de aquisição de EEG elaborado para este trabalho encontram-se na Seção 3.2.

Processamento digital

O processamento digital tem a finalidade de decompor os sinais de EEG, os transformando de dados brutos para informação útil, de acordo com a finalidade desejada. No caso das aplicações em BCI a principal etapa de processamento é o reconhecimento de padrões [55] que envolve a extração de características relevantes do sinal (*feature extraction*), como faixas de frequências, amplitudes e energia; classificação dos sinais (*classifier*) e decisão sobre alterar ou não uma saída do sistema [56].

O tipo de processador digital é escolhido a depender da complexidade do sistema e dos algoritmos envolvidos [57]. O desafio atual para as BCI portáteis é aliar poder de processamento com baixo consumo de energia. Computadores de uso geral são amplamente usados, porém soluções com FPGA e DSP são minoria entre as pesquisas mais recentes, mas vêm gradualmente ganhando espaço [56] [57] [58]. Este trabalho desenvolveu uma técnica inovadora para processamento digital em paralelo utilizando FPGA, onde o sinal de EEG é decomposto em suas ondas constituintes (β , α , θ e δ), sendo essa decomposição usada para reconhecimento de IM das mãos no mesmo equipamento. Estas técnicas são abordadas no Capítulo 3.

Canais de comunicação

Os canais de comunicação permitem a troca de informações entre diferentes sistemas, sejam para armazenamento e posterior análise, seja para tomada de decisão imediata. No contexto atual, as demandas de IoT (*Internet of Things*) e Indústria 4.0 exigem cada vez mais dos sistemas que eles se comuniquem com outros dispositivos (D2D – *device to device* e M2M – *machine to machine*) através de protocolos e interfaces estabelecidas [52]. As interfaces de comunicação mais usuais são as seriais RS-232, RS-485, USB, SPI, I2C e sem fio (*wireless*) são *Bluetooth*, *wi-fi*, ZigBee, LoRaWAN, GSM, 3G, para citar algumas [59] [60]. Neste trabalho, optou-se pelo *Bluetooth* por conta do baixo consumo de energia, segurança, disponibilidade e baixo custo.

Equipamentos comerciais disponíveis no mercado

Existem equipamentos comerciais que realizam a aquisição de EEG e transmissão sem fio. Os mais conhecidos são Muse (Interaxon, Toronto), MindWave (NeuroSky, EUA), Epoc (Emotive, EUA) [62]. O Muse se propõe a ajudar o usuário a meditar, medindo 4 canais de EEG do córtex frontal, comunicando-se sem fio com um *smartphone* e ajustando o som que o usuário ouve em fones de ouvido. O Epoc se destina a “*contextualized research and advanced brain computer interface (BCI) applications*”, segundo a página do fabricante [63]. Segundo as especificações o dispositivo pode medir até 14 canais de EEG, mas nenhum sobre a região motora (C3 e C4). O MindWave possui aplicações em área

como entretenimento, bem-estar, pesquisas e desenvolvimento, segundo o fabricante [64]. Adquire apenas um canal de EEG (FP1 do Sistema 10-20).

Existe uma opção *open source* para aquisição de EEG, o *headset* OpenBCI [65] com 16 canais, compatível com a plataforma Arduino [66] e com *software* livre. Segundo a página do fabricante ele se destina à pesquisa em diversas áreas, com preços acessíveis.

Com exceção da plataforma livre OpenBCI as demais são proprietárias, e não se tem informações sobre os circuitos e *softwares* envolvidos no prometido processamento de sinais de EEG. Além disso, esses produtos não captam os sinais sobre o córtex motor (canais C3 e C4) necessários para análise de IM para controle de BCI. O custo de aquisição é um fator limitante. Por esses motivos, optou-se neste trabalho pelo projeto e confecção de um circuito de aquisição próprio, que atenda às necessidades do sistema proposto nesta tese e que tenha custo final acessível.

2.4 INTERFACE CÉREBRO-MÁQUINA (BCI)

A partir do processamento do sinal de EEG é possível construir interfaces cérebro-máquina (BCI – *Brain Computer Interface*, termo comumente usado na literatura), que são técnicas de controle de dispositivos e equipamentos externos ao corpo humano diretamente pela atividade cerebral [67] [68]. Pesquisas pioneiras vem sendo realizadas desde as décadas de 60 e 70 [69] [70] [71] [72]. Melhorias nas técnicas de processamento digital de sinais, nas décadas de 80 e 90, alavancaram as pesquisas na área, resultado da disseminação dos computadores pessoais (PC) [73]. Atualmente, existem no mundo mais de cinquenta grupos de pesquisa e empresas investindo nesta tecnologia [74] [75]. Por exemplo, o grupo da Universidade Federal de Pernambuco (UFPE) [76], o Laboratório de Engenharia Biomédica da Universidade de São Paulo [77], e as empresas G.Tec Medical Engineering GmbH [78] e Compumedics Neuroscan [79]. Em 2013, o governo dos Estados Unidos lançou o programa “*The Brain Initiative*”, que deverá investir mais de 4 bilhões de dólares até 2025 em diversas áreas de pesquisa para explorar os processos neurais e suas aplicações [80].

Entre os canais de EEG os de maior interesse para a construção de BCI são provenientes do córtex motor, pré-motor e da área motora suplementar, que correspondem aos canais F3, F4, Fz, C3, C4 e Cz no Sistema 10-20 [81]. Quando existem estímulos visuais (SSVEP – *Steady State Visually Evoked Potential*) são analisados os canais O1 e O2 que identificam a atividade elétrica do córtex visual no lobo occipital [8].

Além do EEG, existem outras técnicas para captar a atividade cerebral, que podem ser invasivas ou não invasivas. Chapin e Nicoletis [82] [83] têm usado técnicas invasivas em primatas desde os anos 90 em estudos neurocientíficos, usando matrizes de microeletrodos implantados no córtex motor para medir diretamente a atividade neuronal e controlar um braço robótico (mais recentemente O’Doherty et al. em 2011 [84]). Esta técnica iniciou-se

em humanos em 2006 [85], quando Hochberg et al. [86] implantou diretamente no córtex motor de um tetraplégico, por nove meses, uma matriz de 10 x 10 microeletrodos de silício de 1 mm de comprimento e aproximadamente $20 \mu\text{m}$ de diâmetro cada, separados $400 \mu\text{m}$ m um do outro. O paciente foi capaz de mover um cursor e outros objetos projetados numa tela.

A segunda técnica invasiva é conhecida como Eletrocorticografia (ECoG) ou EEG Intracranial (IEEG). O SNC é revestido por três meninges chamadas dura-máter (mais externa, ligada ao crânio); aracnoide, altamente vascularizada; e pia-máter, que reveste diretamente o córtex cerebral. Uma matriz de eletrodos planares pode ser implantada cirurgicamente entre as meninges pia-máter e aracnoide (subdural) ou entre a dura-máter e o crânio (epidural), na região de interesse do córtex cerebral. A principal aplicação dessa técnica é no tratamento da epilepsia aguda [88] [87]. Se comparado ao EEG tradicional (não invasivo) o sinal de ECoG possui amplitude e faixa de frequência maior e resolução espacial mais precisa, de aproximadamente 1 mm [89] [90], enquanto o EEG possui resolução espacial entre 10 e 50 mm [91].

Por serem técnicas invasivas, as BCI baseadas em microeletrodos e ECoG possuem limitações em suas aplicações, e dificilmente são aprovadas pelos comitês de ética do Brasil. Os riscos cirúrgicos e pós-operatórios restringem os usuários a pacientes com sérias condições clínicas como tetraplegia, acidente vascular cerebral (AVC), tumores, epilepsia, dentre outras [85]. Os microeletrodos podem danificar o tecido nervoso, sofrer rejeição pelo organismo e o movimento relativo entre o cérebro e o crânio pode mover os eletrodos de seu local original [88]. Também podem haver infecções e hemorragias no acesso aos cabos dos eletrodos nas duas modalidades invasivas (microeletrodos e ECoG), pois as meninges e o crânio precisam ser perfurados e permanecer assim enquanto os eletrodos estiverem implantados. As vantagens são, no caso dos microeletrodos, sinais altamente localizados com amplitudes e faixas de frequência maiores que as demais técnicas. O ECoG possui resolução espacial, amplitudes e faixas de frequências menores comparadas com microeletrodos, porém é uma técnica menos agressiva, pois os eletrodos ficam sobre as meninges e não penetram o córtex cerebral.

Uma abordagem alternativa para construção de BCI são as técnicas não invasivas. Os sinais bioelétricos obtidos possuem menor amplitude, faixas de frequência menores, menor resolução espacial e temporal e maior nível de ruído e interferências (ECG, artefato muscular, indução da rede elétrica) em comparação com técnicas invasivas. Por outro lado, as BCI não invasivas podem ser usadas por indivíduos saudáveis que não estariam dispostos a passar por um procedimento cirúrgico, possibilitando o estudo de uma quantidade maior de indivíduos em diferentes situações, com métodos de análise e opções de *feedback* diversificadas. As principais técnicas não invasivas de medição da atividade cerebral são EEG (abordada na Seção 2.2), MEG (magnetoencefalografia), fNIRS (*Functional Near Infrared Spectroscopy*) e fMRI (*Functional Magnetic Resonance Imaging*), abordadas nos parágrafos

seguintes.

A Magnetoencefalografia (MEG) é a técnica não invasiva de medição dos campos magnéticos gerados pelas correntes iônicas presentes nas células nervosas durante a transmissão dos impulsos nervosos [92]. Os magnetômetros aplicados em MEG são do tipo SQUID (*Superconducting QUantum Interference Devices*) que empregam bobinas de material supercondutor resfriadas em hélio líquido [93]. Os valores dos campos magnéticos gerados pelo córtex cerebral são em média 1.000.000 vezes menores que os demais campos do ambiente (campo magnético da terra, instalações elétricas, ondas eletromagnéticas). Por esta razão, as medições de MEG devem ser realizadas em uma sala blindada contra campos magnéticos externos, preparada com paredes revestidas de metais de alta permeabilidade magnética.

A tecnologia fNIRS mede as variações de concentração de oxiemoglobina e desoxi-hemoglobina por meio da absorção da luz infravermelha pelo sangue. Trata-se de uma técnica não invasiva que utiliza emissores led e foto-receptores colocados sobre o couro cabeludo para injetar luz nos comprimentos de onda específicos e captar a luz refletida que não foi absorvida pelos tecidos. Dentro do comprimento de onda entre 700 a 900 nm as moléculas de oxiemoglobina e desoxi-hemoglobina absorvem luz de forma diferente [94]. Quando se inicia a atividade neuronal na região do córtex em análise, o consumo de oxigênio aumenta, e a resposta do organismo é aumentar a irrigação sanguínea nessa região [95]. Desta forma, conhecendo-se a energia luminosa injetada no tecido e medindo-se a quantidade refletida é possível calcular a energia absorvida para cada comprimento de onda. Portanto, é possível estimar as concentrações de oxiemoglobina e desoxi-hemoglobina em um dado instante numa dada região do córtex cerebral, identificando regiões com maior atividade.

Utilizando a técnica fMRI é possível criar uma imagem do córtex evidenciando as regiões com maior irrigação sanguínea durante atividades motoras ou de IM. Essa abordagem ajuda a determinar áreas cerebrais relacionadas com estas atividades, conforme trabalhos recentes de Park et al. e Hermes et al. [81] [96]. Lee et al. demonstrou uma BCI operada via fMRI [97]. Um fator limitante da técnica é a impossibilidade de livre movimentação do indivíduo, pois o mesmo deve estar sob análise no equipamento que possui um porte considerável que é comparável ao equipamento que registra a MEG, conforme exemplificado na Fig. 2.9.

Pesquisas tem sido realizadas integrando técnicas diferentes de medições da atividade cerebral que podem ser aplicadas para construção de BCI. Como exemplo, citam-se estudos desenvolvidos por Yin et al. [98] e Fazli et al. [99] que avaliam o desempenho do EEG juntamente com o fNIRS para detecção de movimento e IM. Pfurtscheller e Lopes da Silva [100] aplicam EEG e MEG para estudar a sincronização e dessincronização de potenciais evocados (*Event-Related Synchronization (ERS)* e *Event-Related Desynchronization (ERD)*) durante a realização de tarefas motoras. Essas pesquisas buscam reunir

Figura 2.9 – Exemplo de um equipamento de fMRI.

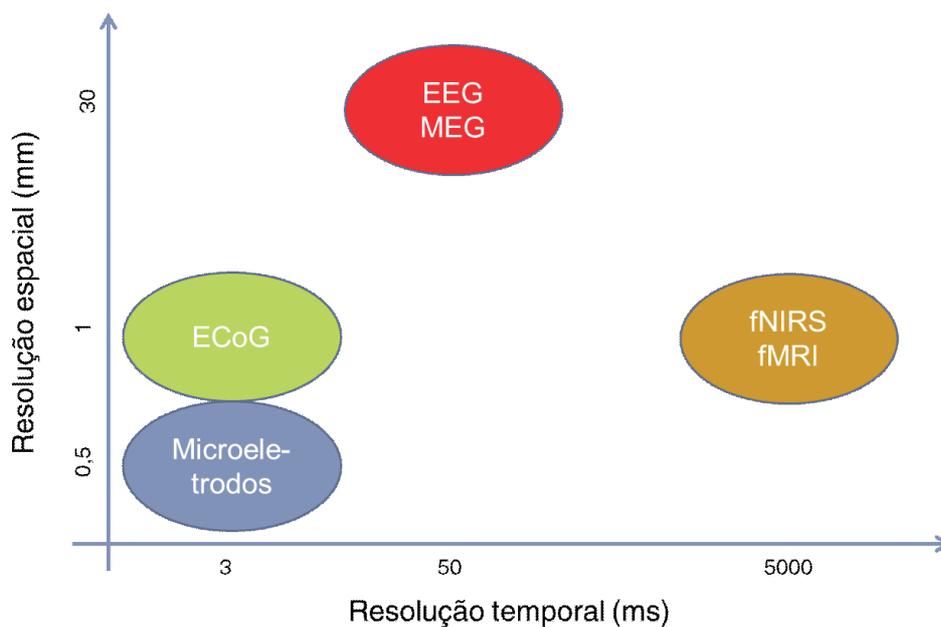


Fonte: c1.staticflickr.com/7/6105/6278833383_5e135ec260_b.jpg. Acessado em 29 nov. 2016.

características específicas de cada técnica para complementar uma a outra.

Em comparação com o MEG, o EEG e fNIRS possuem custo menor e possibilitam maior liberdade de movimentação para o indivíduo. Porém, o MEG possui melhor resolução espacial e temporal frente ao fNIRS e EEG. O EEG possui resolução temporal comparável ao MEG, porém sua resolução espacial é inferior [102]. A Fig. 2.10 apresenta as resoluções espacial e temporal de cada técnica de forma gráfica, e a Tabela 2.3 resume os principais métodos de aquisição de sinais bioelétricos empregados em BCI.

Figura 2.10 – Resumo das resoluções espacial e temporal dos principais métodos de aquisição de sinais bioelétricos empregados em BCI.



Fonte: autor.

Tabela 2.3 – Resumo das técnicas de construção de BCI.

BCI	Aquisição	Prós	Contras
Invasiva	Microeletrodos	Medição de neurônios individuais, resolução espacial entre 0,5 e 0,05 mm, amplitude média $75 \mu V$, frequência < 300 Hz; resolução temporal 3 ms; portátil	Cirurgia, rejeição, infecções, hemorragia, uso limitado a pacientes não sadios
	ECoG	Resolução espacial 1 mm, amplitudes entre 50 e $100 \mu V$, frequência < 200 Hz; resolução temporal 3 ms; portátil	Idem ao microeletrodo porém com sinal de menor qualidade, disponibilidade de pacientes epiléticos
Não invasiva	EEG	Facilidade de aplicação; usuários sadios; portátil; resolução temporal 50 ms	Resolução espacial 30 mm, amplitudes entre 1 e $20 \mu V$, frequência < 40 Hz
	MEG	Menos susceptível a interferências elétricas; usuários sadios	Não portátil, sensível a campos magnéticos externos
	fNIRS	Portátil, menos susceptível a interferências elétricas; usuários sadios	Resolução temporal baixa (5-10 s)
	fMRI	Alta resolução espacial (1-3 mm); usuários sadios	Não portátil, resolução temporal baixa (5-10 s)

Fonte: adaptado de Nicolas-Alonso [103], Hong [104] e Leuthardt [89].

2.5 ANÁLISE DE SINAIS DE EEG USANDO TÉCNICAS DIGITAIS PARA CONSTRUÇÃO DE BCI

O EEG é considerado um sinal não estacionário, não linear e não gaussiano [105] [106]. Além disso a relação sinal-ruído é baixa, possui baixa resolução espacial (aproximadamente 30 mm) e largura de banda entre 0,05 e 40 Hz, que ocasiona uma taxa de transferência de informação (ITR – *Information Transfer Rate*) reduzida [55] [36] [107], pois as estruturas anatômicas que existem entre a fonte dos impulsos nervosos (conjunto de neurônios) e o ponto de captação do sinal (couro cabeludo) atenuam e distorcem o sinal original (vide Seção 2.1). Adicionalmente, as características do EEG variam para cada indivíduo.

A abordagem geralmente relatada na literatura para tratar esses sinais é o reconhecimento de padrões [55] [106], que tem sido um campo de pesquisa por mais de 60 anos e está bem documentado na literatura [108] [109] [110].

Entre os canais de EEG existem potenciais elétricos diferentes a cada instante, que expressam pensamentos e imaginação, atividades motoras, sensoriais, cognitivas e sinais

basais de diferentes partes do cérebro. Determinar quais padrões de sinais se referem a certos tipos de atividades cerebrais é uma questão em aberto [111]. Porém, é possível reconhecer certos tipos de padrões no sinal de EEG de acordo com a atividade executada a partir de uma “dica” ou sinal avisando que a atividade deve ser iniciada [112] [113] [114]. Para movimento e IM são empregadas os ERP, ERS e ERD [115] [116] [117] [118]. As BCI que não adotam estes marcadores precisam determinar os padrões corretos que relacionam atividade motora no EEG bruto de forma contínua, aumentando a complexidade do sistema [119] [120] [121].

Para reconhecer movimento e IM a partir do EEG deve existir uma etapa de treinamento, para que o sistema possa extrair as características desejadas do sinal para certo indivíduo realizando certa atividade, e posteriormente uma etapa de comparação de padrões, também chamada classificação. Técnicas invasivas compartilham a mesma metodologia [107].

Após o treinamento, o sistema terá as características extraídas do sinal e poderá iniciar a classificação com sinais reais. Dependendo do tipo de extração de características (*feature extraction*) e do classificador (*classifier*) empregados, pode-se atingir um percentual de acerto de até 96 % [55] [105] [106].

Uma revisão bibliográfica foi realizada na plataforma Periódicos Capes, buscando-se as diferentes técnicas de reconhecimento de padrões aplicadas em BCI. Foram buscadas as seguintes palavras-chave: EEG, BCI, *feature extraction*, *classifier*, *review*. Não foram colocadas restrições de tempo, para abranger desde as técnicas mais antigas até as mais modernas. Encontram-se relacionadas nas Tabelas 2.4 e 2.5 as principais técnicas de extração de características e classificação para reconhecimento de padrões aplicadas em BCI baseadas em EEG por diversos autores.

O método de extração utilizado neste trabalho foi a DWT (abordagem tempo-frequência) combinada com escalograma. Essa técnica foi aplicada por outro membro (Silva [215]) do Grupo de Pesquisa em Engenharia Biomédica da UFPE que o autor faz parte, e o emprego da transformada DWT para processamento de sinais bioelétricos compõe uma das linhas de pesquisa do grupo. Para construir o sistema que executa esses cálculos e algoritmos foram exploradas as *wavelets* baseadas em filtros digitais de resposta finita. Estes assuntos são abordados nas subseções seguintes.

Filtros FIR

Neste trabalho utilizou-se filtros digitais para executar as DWT, que são implementadas a partir de banco de filtros. Os filtros empregados são conhecidos como FIR (*Finite Impulse Response*). Como o nome sugere, esses filtros possuem resposta finita a uma

Tabela 2.4 – Principais métodos de extração de características do sinal de EEG aplicados em BCI.

Domínio	Método
Tempo	Estimadores de amplitude do EEG: RMS, valor médio absoluto, variância, integral quadrada simples, variação média de amplitude [55] [122] Análise de componentes independentes (ICA – <i>Independent Component Analysis</i>) [36] [106] [123] Predição linear [36] [106] [123]
Frequência	Faixas de potência [55] Densidade espectral de potência (PSD – <i>Power Spectral Density</i>) [55] [106] Transformada rápida de Fourier (FFT – <i>Fast Fourier Transform</i>) [36] Autoregressivo (AR) [55] [36] [127] Eigenvetores [36] Welch [106] [215] <i>Moving average</i> (MA) e <i>Auto regressive moving average</i> (ARMA) [106]
Tempo-frequência	Transformada de Fourier de tempo curto (STFT – <i>Short Time Fourier Transform</i>) [55] [128] [36] [106] Espectrograma [128] [36] Distribuição Wigner-Ville [128] [36] Transformada <i>wavelet</i> discreta (DWT – <i>Discrete Wavelet Transform</i>) [128] [36] [106] [105] [122][123] [127] [129] Transformada <i>wavelet</i> contínua (CWT – <i>Continuous Wavelet Transform</i>) [106] Escalograma [128] [36] Decomposição <i>wavelet</i> (WPD – <i>Wavelet Packet Decomposition</i>) [36] [105] Modo de decomposição empírica (EMD – <i>Empirical Mode Decomposition</i>) [105] [123] Filtros de Kalman [127]
Espaço-temporal	Padrões espaciais comuns (CSP – <i>Common Spatial Patterns</i>) [126] [127] Padrões espaciais comuns de Fisher (FCSP – <i>Fisher’s common spatial pattern</i>) [126] Padrões espaciais comuns estacionários (sCSP – <i>Stationary Common Spatial Patterns</i>) [126] Filtros laplacianos [127]
Espaço-espectral	Padrões espaço-espectrais comuns (CSSP – <i>Common Spatio-spectral pattern</i>) [126] Padrões espaço-espectrais comuns de Fisher (FCSSP – <i>Fisher’s Common Spatio-Spectral Pattern</i>) [126] Padrões interativos de aprendizagem espaço-espectrais (ISSPL – <i>Iterative Spatio-Spectral Patterns Learning</i>) [126]
Outros	EEG multicanal [36] <i>Principal Component Analysis</i> (PCA) [105] [123] <i>Flicker-noise spectroscopy</i> (FNS) [124] <i>Largest Lyapunov Exponent</i> (LLE) [106] Kolmogorov-Sinai <i>entropy</i> [106]

Fonte: autor.

Tabela 2.5 – Classificadores comumente aplicados em BCI.

Tipo	Método
Linear	Análise por discriminante linear (LDA – <i>Linear Discriminant Analysis</i>) [55] [127] <i>Support Vector Machine</i> (SVM) [55] [127] Redes neurais [55] [122] [127] [125]
Não linear	Bayesiano [55] [127] Modelo oculto de Markov (HMM – <i>Hidden Markov Model</i>) [55]
Vizinho próximo	<i>k Nearest Neighbors</i> (k-NN) [55][105] Distância de Mahalanobis [55]

Fonte: autor.

entrada impulso [130]. A função discreta impulso $u[i]$ é definida como

$$u[i] = \begin{cases} 1, & i = 0, \\ 0, & i \neq 0, \end{cases} \quad (2.1)$$

sendo $i \in \mathbb{N}$ a quantidade de amostras de entrada. Um filtro FIR é definido pela Eq. (2.2).

$$y[i] = c_0x[i] + c_1x[i - 1] + \dots + c_kx[i - k], \quad (2.2)$$

em que,

$c_0, c_1, \dots, c_k \in \mathbb{R}$ são os coeficientes do filtro;

$x[\cdot]$ são as i amostras de entrada digitalizadas, desde a entrada atual $x[0]$, as anteriores $x[1], x[2] \dots$ até a última $x[i]$;

$k \in \mathbb{N}$ é a ordem do filtro, definida pela quantidade de coeficientes.

Um filtro FIR é definido por seus coeficientes, e pode ser representado de forma gráfica por um sistema conforme a Fig. 2.11. A aplicação de um entrada impulso revela os coeficientes do filtro na saída $y[i]$. Supondo uma entrada conforme Eq. (2.1) com $i = k$ amostras no filtro FIR representado pela Eq. (2.2) temos:

$$y[0] = c_0u[0] + c_1 \cdot 0 + \dots + c_k \cdot 0, \quad (2.3)$$

$$y[1] = c_0u[1] + c_1u[0] + \dots + c_k \cdot 0, \quad (2.4)$$

...

$$y[i] = c_0u[i] + c_1u[i - 1] + \dots + c_ku[0], \quad (2.5)$$

considerando que as amostras anteriores à primeira são zero. Assim, a saída $y[i]$ do filtro será

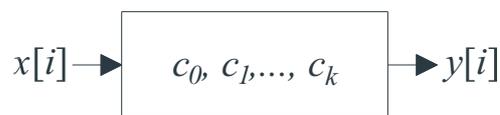
$$y[0] = c_0, \quad (2.6)$$

$$y[1] = c_1, \quad (2.7)$$

...

$$y[i] = c_k. \quad (2.8)$$

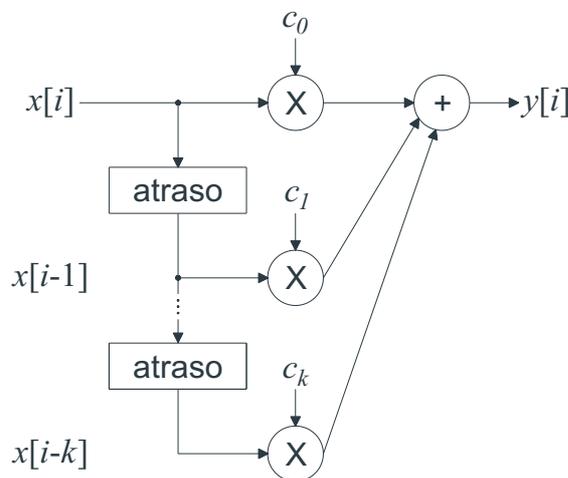
Figura 2.11 – Representação em bloco de um filtro FIR.



Fonte: autor.

A implementação de filtros FIR em circuitos digitais é feita por meio de somadores, multiplicadores e elementos de atraso, estes últimos realizados por registradores. A Fig. 2.12 apresenta a estrutura básica de um filtro FIR.

Figura 2.12 – Estrutura básica de um filtro FIR.



Fonte: autor.

Um filtro FIR deve possuir as seguintes características [130] [131]:

Causalidade A saída $y[i]$ depende somente da entrada atual e/ou das entradas anteriores.

Linearidade Um filtro FIR possui a propriedade da superposição descrita em (2.9):

$$ax_1[i] + bx_2[i] = ay_1[i] + by_2[i]. \quad (2.9)$$

Invariância no tempo Um atraso de tempo na entrada do filtro causa um mesmo atraso na saída. Em outras palavras, os coeficientes de um filtro FIR são constantes.

Filtros FIR podem implementar a função passa-baixa ou passa-alta, dependendo unicamente de seus coeficientes. Por exemplo, pode-se construir dois filtros: um passa-baixa com os seguintes coeficientes

$$y[i] = \frac{1}{2}x[i] + \frac{1}{2}x[i-1] = \frac{1}{2}(x[i] + x[i-1]). \quad (2.10)$$

Este pode ser chamado filtro de média, pois a saída é a média da entrada atual e da anterior. Por sua vez, pode-se implementar um filtro passa-alta com coeficientes

$$y[i] = \frac{1}{2}x[i] + \left(-\frac{1}{2}\right)x[i-1] = \frac{1}{2}(x[i] - x[i-1]). \quad (2.11)$$

A saída é a metade da diferença entre as duas entradas. Neste exemplo, se a variação entre a entrada anterior e a atual for relativamente pequena, caracterizando um oscilação de baixa frequência, a saída do filtro passa-baixa será maior que a saída do passa-alta. Caso a oscilação seja de alta frequência, a diferença entre as entradas será enfatizada na saída do passa-alta, e minimizada na saída do filtro passa-baixa.

Wavelets

A Transformada *Wavelet* Discreta ou DWT (*Discrete Wavelet Transform*) é uma ferramenta de análise de sinais amplamente utilizada em diversas áreas da engenharia elétrica. Com ela é possível decompor um sinal em bandas de frequências chamadas níveis ou oitavas, e a partir destes níveis pode-se reconstruir o sinal sem perdas [130].

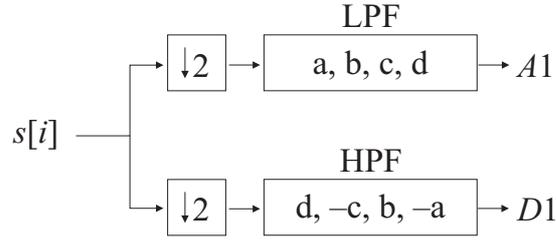
As *wavelets* são construídas a partir de banco de filtros. A técnica utilizada neste trabalho é conhecida como Filtro Conjugado em Quadratura (CQF – *Conjugate Quadrature Filter*). Trata-se de um banco de filtros digitais de dois canais: um passa-baixa (LPF – *Low Pass Filter*) e outro passa-alta (HPF – *High Pass Filter*). Adicionalmente, inclui-se a técnica de *downsampling* para sub-amostrar o sinal, computando as amostras pares e descartando as ímpares. Desta forma, os coeficientes de aproximação $A1$ e detalhes $D1$ terão a metade das amostras do sinal original. O procedimento está ilustrado na Fig. 2.13.

Cada filtro no banco de filtros possui quatro coeficientes. A escolha destes coeficientes definem o filtro. Por exemplo, se cada filtro tiver dois coeficientes e estes forem $a = b = \frac{1}{\sqrt{2}}$ a *wavelet* gerada é conhecida como *Haar*. Com quatro coeficientes escolhidos conforme (2.12) tem-se a *wavelet* Daubechies-4, resultado dos trabalhos de Ingrid Daubechies [132].

$$a = \frac{1 - \sqrt{3}}{4\sqrt{2}}; \quad b = \frac{3 - \sqrt{3}}{4\sqrt{2}}; \quad c = \frac{3 + \sqrt{3}}{4\sqrt{2}}; \quad d = \frac{1 + \sqrt{3}}{4\sqrt{2}}. \quad (2.12)$$

Para reconstruir o sinal a partir dos coeficientes de aproximação $A1$ e detalhes $D1$, utiliza-se um banco de filtros chamado *síntese* (Fig. 2.14). Antes dos filtros de síntese os

Figura 2.13 – A decomposição *wavelets* utiliza banco de filtros para gerar os coeficientes de aproximação $A1$ e detalhes $D1$ a partir do sinal amostrado $s[i]$.

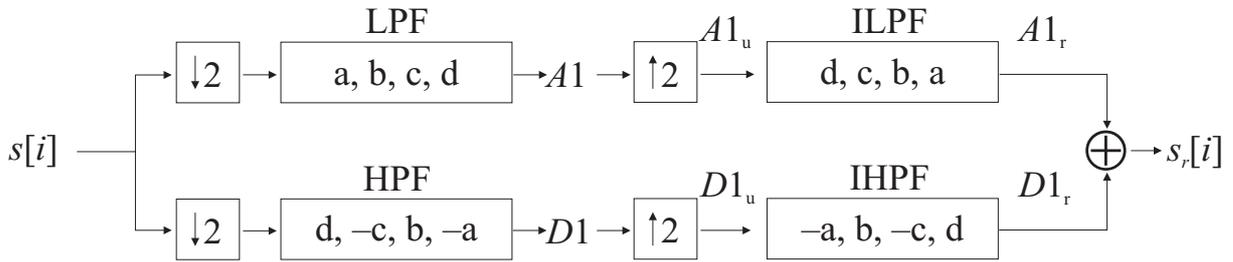


Fonte: adaptado de [130].

coeficientes passam por um *upsampling*, que inclui zeros nas posições ímpares. A saída do ILPF (*Inverse Low Pass Filter*) $A1_r$ e IHPF (*Inverse High Pass Filter*) $D1_r$ do banco de síntese são somadas para se obter o sinal reconstruído

$$s_r[i] = A1_r[i] + D1_r[i]. \quad (2.13)$$

Figura 2.14 – O sinal original $s[i]$ pode ser reconstruído como $s_r[i]$ a partir dos coeficientes $A1$ e $D1$ por meio do banco de síntese formado pelos filtros ILPF e IHPF.



Fonte: adaptado de [130].

Os coeficientes $A1_r$ e $D1_r$ na saída do ILPF e IHPF de síntese são, respectivamente

$$A1_r[i] = d \cdot A1_u[i] + c \cdot A1_u[i - 1] + b \cdot A1_u[i - 2] + a \cdot A1_u[i - 3], \quad (2.14)$$

$$D1_r[i] = (-a) \cdot D1_u[i] + b \cdot D1_u[i - 1] + (-c) \cdot D1_u[i - 2] + d \cdot D1_u[i - 3]. \quad (2.15)$$

Os coeficientes ímpares na saída do *upsampling* são zero, os pares são

$$A1_u[i] = A1[i], \forall i \text{ par}, \quad (2.16)$$

$$A1_u[i] = 0, \forall i \text{ ímpar}, \quad (2.17)$$

$$D1_u[i] = D1[i], \forall i \text{ par}, \quad (2.18)$$

$$D1_u[i] = 0, \forall i \text{ ímpar}. \quad (2.19)$$

Substituindo (2.16) a (2.19) em (2.14) e (2.15) resulta

$$A1_r[i] = d \cdot A1[i] + 0 + b \cdot A1[i - 2] + 0, \forall i \text{ par}, \quad (2.20)$$

$$A1_r[i] = 0 + c \cdot A1[i - 1] + 0 + a \cdot A1[i - 3], \forall i \text{ ímpar}, \quad (2.21)$$

$$D1_r[i] = (-a) \cdot D1[i] + 0 + (-c) \cdot D1[i - 2] + 0, \forall i \text{ par}, \quad (2.22)$$

$$D1_r[i] = 0 + b \cdot D1[i - 1] + 0 + d \cdot D1[i - 3], \forall i \text{ ímpar}. \quad (2.23)$$

Desta forma reescreve-se (2.13)

$$s_r[i] = d \cdot A1[i] + b \cdot A1[i - 2] + (-a) \cdot D1[i] + (-c) \cdot D1[i - 2], \forall i \text{ par}, \quad (2.24)$$

$$s_r[i] = c \cdot A1[i - 1] + a \cdot A1[i - 3] + b \cdot D1[i - 1] + d \cdot D1[i - 3], \forall i \text{ ímpar}. \quad (2.25)$$

Substituindo os seguintes valores de $A1$ e $D1$:

$$A1[i] = a \cdot s[i] + b \cdot s[i - 1] + c \cdot s[i - 2] + d \cdot s[i - 3], \forall i \text{ par}, \quad (2.26)$$

$$D1[i] = d \cdot s[i] + (-c) \cdot s[i - 1] + b \cdot s[i - 2] + (-a) \cdot s[i - 3], \forall i \text{ par}, \quad (2.27)$$

em (2.24) e (2.25) tem-se:

$$\begin{aligned} s_r[i] &= d \cdot (a \cdot s[i] + b \cdot s[i - 1] + c \cdot s[i - 2] + d \cdot s[i - 3]) + \\ &+ b \cdot (a \cdot s[i - 2] + b \cdot s[i - 3] + c \cdot s[i - 4] + d \cdot s[i - 5]) + \\ &+ (-a) \cdot (d \cdot s[i] + (-c) \cdot s[i - 1] + b \cdot s[i - 2] + (-a) \cdot s[i - 3]) + \\ &+ (-c) \cdot (d \cdot s[i - 2] + (-c) \cdot s[i - 3] + b \cdot s[i - 4] + (-a) \cdot s[i - 5]), \forall i \text{ par}; \end{aligned} \quad (2.28)$$

$$\begin{aligned} s_r[i] &= c \cdot (a \cdot s[i - 1] + b \cdot s[i - 2] + c \cdot s[i - 3] + d \cdot s[i - 4]) + \\ &+ a \cdot (a \cdot s[i - 3] + b \cdot s[i - 4] + c \cdot s[i - 5] + d \cdot s[i - 6]) + \\ &+ b \cdot (d \cdot s[i - 1] + (-c) \cdot s[i - 2] + b \cdot s[i - 3] + (-a) \cdot s[i - 4]) + \\ &+ d \cdot (d \cdot s[i - 3] + (-c) \cdot s[i - 4] + b \cdot s[i - 5] + (-a) \cdot s[i - 6]), \forall i \text{ ímpar}. \end{aligned} \quad (2.29)$$

Eliminando os termos que se anulam e reorganizando (2.28) e (2.29) resulta:

$$s_r[i] = (ac + db) \cdot s[i - 1] + (aa + bb + cc + dd) \cdot s[i - 3] + (ac + db) \cdot s[i - 5], \forall i \in \mathbb{N}. \quad (2.30)$$

Impondo as seguintes condições a (2.30)

$$\begin{cases} ac = -db, \\ aa + bb + cc + dd = 1, \end{cases} \quad (2.31)$$

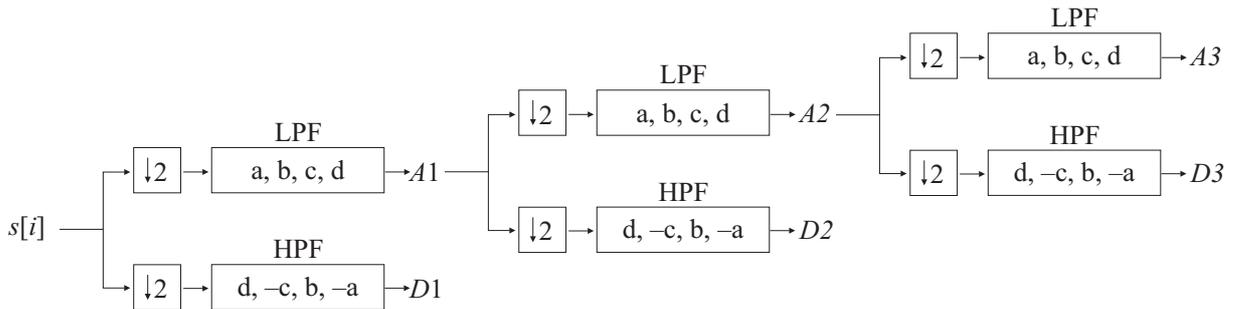
leva a

$$s_r[i] = s[i - 3], \quad (2.32)$$

ou seja, o processo recompõe o sinal com um atraso de três amostras. Para a *wavelet* Daubechies-4 os coeficientes que satisfazem (2.31) são (2.12).

Uma das principais utilizações das *wavelets* é a análise multirresolução. Nessa técnica, a saída $A1$ do LPF se torna a entrada de um segundo banco de filtros de análise. Desta forma, tem-se um segundo nível de decomposição (ou segundo nível), que gera seus próprios coeficientes de aproximação ($A2$) e detalhes ($D2$). A Fig. 2.15 apresenta o esquema para três níveis.

Figura 2.15 – Exemplo de análise multirresolução em três níveis.



Fonte: autor.

Conhecendo-se os coeficientes dos filtros LPF e HPF é possível reconstruir o sinal original $s[i]$ a partir de $A3$, $D3$, $D2$ e $D1$, passando pelos filtros de síntese ILPF e IHPF em cascata.

Na literatura, a *wavelet* mais empregada para reconhecimento de IM em BCI é a Daubechies-4. De acordo com os autores Xu e Song [133], Chatterjee et al. [134] [135] e Yaacoub et al. [136] em suas respectivas pesquisas, ela apresenta a maior taxa de acerto entre as *wavelets* comparadas. Essa mesma abordagem foi utilizada nesta tese. Devido à arquitetura reconfigurável do sistema, outras *wavelets* podem ser estudadas, bastando informar os novos coeficientes e a quantidade de interações necessárias no cálculo. Maiores detalhes encontram-se na Seção 3.4.

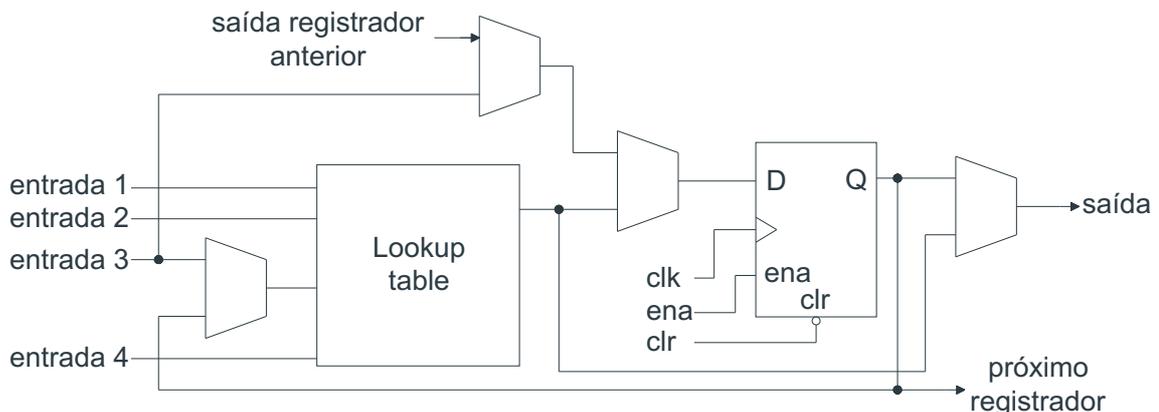
2.6 FPGA

FPGA é a sigla para *Field Programmable Gate Array*, que pode ser traduzido livremente como “Arranjo de Portas Lógicas Programáveis em Campo”. São circuitos integrados que possuem portas lógicas e outros elementos que podem ser interconectados de diferentes formas, para criar sistemas digitais reconfiguráveis. Atualmente, os FPGA possuem outros circuitos digitais além das portas lógicas, como microcontroladores, memórias ROM, RAM e FLASH. Existem circuitos integrados que somam aos elementos de lógica programável componentes analógicos como amplificadores, filtros ativos, comparadores, circuitos ADC e DAC (*Digital to Analog Converter*), chamados por alguns fabricantes de PSoC (*Programmable System on Chip*).

Dados publicados por Morris [137] em 2014 apontam dois principais fabricantes de FPGA que dividem 80% do mercado mundial, Altera e Xilinx. Ambos fabricam FPGA, CPLD (Complex Programmable Logic Device) e PSoC [139] [138]. Analisando os FPGAs de cada fabricante, percebe-se que suas arquiteturas se baseiam em estruturas similares chamadas elementos lógicos (LE - *Logical Elements*) para os dispositivos da Altera e blocos lógicos configuráveis (CLB - *Configurable Logic Blocks*) para os da Xilinx. Neste trabalho, foi empregado o FPGA da Altera família Cyclone III [140], por ser um FPGA de capacidade e velocidade adequadas para este trabalho, além de estar disponível previamente no Laboratório de Engenharia Biomédica da UFPE.

Os elementos lógicos são as unidades fundamentais do FPGA selecionado. São formados basicamente por uma “tabela de consulta” (*lookup table*) de quatro entradas e um registrador (Fig. 2.16). Existe uma lógica de controle adicional para os sinais de *clock*, *enable* e *clear*. Além dos elementos lógicos, a FPGA possui blocos de memória RAM e ROM, multiplicadores integrados, geradores de *clock* e PLL (*Phase Locked Loop*), e portas de entrada e saída (I/O) configuráveis. A família Cyclone III possui diferentes modelos que possuem características similares, mas variam na quantidade de recursos disponíveis. O modelo utilizado no trabalho é apresentado em detalhes na Seção 3.2.

Figura 2.16 – Estrutura simplificada dos elementos lógicos do FPGA EP3C16F484C6.



Fonte: adaptado de [141].

Para programar as interconexões entre os diferentes blocos do FPGA e montar o circuito digital, usa-se uma das linguagens de descrição de *hardware* HDL (*Hardware Description Language*) disponíveis. As mais comuns são VHDL, Verilog e SystemVerilog [142], sendo normatizadas pelo IEEE em [143], [144] e [145], respectivamente. Existem uma abordagem que busca compatibilizar linguagens de programação estruturada como C para descrever os circuitos em FPGA, por exemplo SystemC, Handel-C, Impulse C,

SPARK [142] [146]. Neste trabalho, optou-se pela linguagem HDL, especificamente Verilog, pois permitem maior flexibilidade e otimização dos recursos de *hardware* do FPGA. O programa editor escolhido foi o Quartus II da Altera [147], para criar as interconexões necessárias entre os elementos lógicos.

A finalidade de construir circuitos digitais dedicados que operem em paralelo foi o motivo da aplicação de FPGA neste trabalho. Futuramente, pode-se copiar estes circuitos para tecnologia ASIC (*Application Specific Integrated Circuits*) para produção em maiores quantidades ou registrar o código como *IP core* (núcleo de propriedade intelectual).

2.7 ESTADO DA ARTE DAS BCI BASEADAS EM EEG

A fim de identificar as principais aplicações de BCI baseadas em IM, foi realizada uma revisão bibliográfica sistemática em cinco bases de dados *online* acessíveis pela subscrição da UFPE: Periódicos Capes (periodicos.capes.gov.br), ScienceDirect (sciencedirect.com), IEEE Xplore (ieeexplore.ieee.org), Scopus (scopus.com) e PubMed (ncbi.nlm.nih.gov/pmc). Os requisitos da pesquisa foram:

1. Palavras-chave: “EEG” “motor” “imagery” “BCI” “FPGA”;
2. A pesquisa deve abranger todo texto dos artigos, não se limitando ao título, resumo e palavras-chave;
3. Somente artigos de *Journals* revisados pelo método *peer review*;
4. Faixa de tempo: últimos 5 anos (2012-2017);
5. Analisar primeiramente o título e resumo. Se estiver relacionado com a área de pesquisa analisar o restante do artigo;
6. Critérios de inclusão: BCI operada por IM; tipo de dispositivo controlado pela BCI (imagem em uma tela, dispositivo eletromecânico, outros), *online* ou *offline*; processamento digital usando FPGA, DSP ou PC; frequência de amostragem e resolução do ADC; *feature extraction* e classificador empregado; precisão; taxa de transferência de informação (ITR – *Information Transfer Rate*); potência consumida; tecnologia com ou sem fio.
7. Critérios de exclusão: não ter aplicação direta em BCI, não ser artigos de *Journals* revisado por pares.

A pesquisa inicial foi realizada no mês de dezembro/2016, e atualizada em novembro/2017. A base de dados da Capes retornou vinte e nove resultados, porém foram

contabilizados vinte e seis, pois haviam artigos repetidos. Destes um era artigo de conferência [171] e foi desconsiderado. A pesquisa na base ScienceDirect retornou oito resultados, mas foram retirados dois que eram índices de livros ([177], [178]), dois já haviam retornado na pesquisa da base Periódico Capes ([160], [159]) e um foi publicado antes do ano 2012 ([212]). Quinze resultados foram obtidos na base IEEE Xplore e um foi publicado antes de 2012 sendo desconsiderado ([184]). Um detalhe da pesquisa nessa base de dados é que no *site* deve-se entrar em *Advanced Search*, marcar a opção “*Full Text & Metadata*” e digitar as palavras-chave no campo indicado. Desta forma, mais artigos são retornados. A pesquisa na base Scopus retornou vinte e quatro resultados. Dentre eles nove já haviam sido listados na pesquisa da base Periódicos Capes ([158], [168], [161], [246], [166], [170], [159], [167], [168]), e dez retornaram na base IEEE Xplore ([181], [182], [185], [192], [191], [179], [186], [183], [189], [187]). A base PubMed listou dez resultados e dentre eles quatro foram relacionados anteriormente na base Periódicos Capes ([246], [168], [166], [169]) e um artigo estava nos resultados da base de dados Scopus ([194]). No total, cinquenta e dois artigos atenderam os requisitos iniciais de 1 a 4 da pesquisa.

Comparando a pesquisa atual com a anterior realizada em dezembro/2016 notou-se que três artigos não foram relacionados na pesquisa mais recente, porém atendiam aos requisitos ([204], [205], [206]). Inclusive o artigo [206] havia sido selecionado como de interesse na época. Um quarto artigo ([207]) ficou de fora da pesquisa atual por ter sido publicado em 2011, mas também havia sido selecionado como de interesse e será considerado. Dessa forma, foram contabilizados cinquenta e seis artigos para a próxima fase da revisão bibliográfica sistemática.

A etapa de seleção seguinte envolveu a leitura dos títulos e resumos dos artigos, para separar os que se relacionam diretamente com a área de pesquisa deste trabalho. Um artigo relacionado na pesquisa Scopus não permitia acesso ao texto completo via assinatura da UFPE ([198]), então foi retirado da listagem. Após leitura dos cinquenta e cinco artigos restantes eles foram classificados da seguinte maneira:

- (a) artigos não relacionados com BCI: [193], [196], [183], [166], [170], [172], [188], [175];
- (b) estudo de técnicas de processamento de sinais de EEG, porém não foram aplicadas diretamente no controle de BCI: [148], [149], [150], [151], [152], [153], [105], [154], [155], [156], [157], [158], [246], [164], [168], [179], [185], [189], [192], [195], [199], [201];
- (c) técnicas aplicadas no controle de BCI, porém utilizando paradigmas diferentes da IM: [159], [160], [161], [191], [163], [165], [167], [169], [173], [180], [182], [186], [187], [190], [194], [200], [202], [203], [176], [205], [204];
- (d) técnicas aplicadas diretamente em BCI utilizando IM: [181], [197], [206], [207].

Vinte e um artigos descrevem BCI por paradigmas diferentes, citados no item (c). Em [161] e [191] Lo et al. controlam equipamentos hospitalares como chamada de enfer-

meira, ar condicionado, luzes e televisor utilizando SSVEP. Pan et al. [159] aplica SSVEP para controlar um dispositivo multimídia. Lin et al. [186] ajusta a temperatura e a luz ambiente em uma sala de estar a partir do “estado de alerta” do indivíduo, medindo a energia das ondas α e θ . O estudo de Xu e colegas [167] desenvolveu um soletrador paralelo via SSVEP com controle e processamento implantado em FPGA. Em [187] Shyu et al. empregam a técnica SSVEP para controlar uma cama hospitalar, sendo o processamento digital realizado em FPGA. Uma cadeira de rodas é controlada por pessoas com restrições motoras combinando movimento dos olhos, da cabeça e SSVEP, e foi desenvolvida por Bastos-Filho et al. [180]. Wu e colaboradores [190] aplicavam BCI com o sinal bioelétrico de eletro-oculografia (EOG). Wöhrle et al. [194] constroem um sistema híbrido baseado em FPGA para prever o movimento do antebraço a partir de EEG e EMG (Eletromiografia), usando uma combinação de MRCP (*Movement Related Cortical Potentials*) e onda P300. Évain et al. [200] combinam SSVEP e rastreamento ocular para detectar uma palavra entre várias em uma tela. Sharma e equipe [202] realizaram um estudo para uma neuro-prótese acionada por ECoG com eletroestimulação para dar movimento ao dedo da mão em um quadriplégico. Fukuma e equipe em [169] [203] utilizam MEG para controlar uma prótese de mão. Ramli et al. [173] controlam uma cadeira de rodas por meio de uma combinação de EOG e EEG, que rastreia o movimento ocular para indicar a direção do movimento da cadeira. A equipe de Lin et al. [204] desenvolveu um sistema baseado em FPGA (Xilinx XC3S500E-PQ208 [208]) para controlar uma cadeira de rodas via piscar dos olhos e medindo a amplitude da onda α na parte frontal da cabeça, que segundo os autores reflete o “nível de atenção” do usuário. O sistema de aquisição de EEG foi um *headset* comercial (NeuroSky [209]). Este sistema não usa IM para controlar a BCI. Por fim, uma equipe conjunta das Universidades de Uberlândia, Manaus e do Espírito Santo desenvolveram um sistema de treinamento virtual para usuários de cadeira de rodas aplicando diferentes técnicas de processamento de sinais bioelétricos, incluindo SSVEP.

Dos cinquenta e cinco resultados da pesquisa nas cinco bases de dados restaram quatro artigos de interesse, que aplicam IM via EEG para controlar diretamente uma BCI e acionar um dispositivo de saída. No primeiro artigo, McCrimmon et al. [181] controlam uma BCI pelo movimento da mão usando uma placa Arduino Due que possui um microcontrolador ARM 32 bits [210]. Para a aquisição de EEG eles desenvolveram uma placa com oito canais usando um amplificador de instrumentação e dois operacionais de uso geral. A topologia do circuito é similar a usada nesta tese, conforme detalhado na Seção 3.2. A tarefa do sistema proposto por McCrimmon é reconhecer o movimento de abrir e fechar a mão e acender um led. Os autores usaram LDA como *feature extraction* e o classificador Bayesiano para calcular a probabilidade de movimento. Segundo os autores, foi atingida uma taxa de acertos máxima de 98% com o sistema, que é alimentado por baterias recarregáveis de 5 V.

Um “hexacóptero” real semi-autônomo, controlado sem fio via BCI e alimentado por baterias, é guiado por corredores até atingir um alvo, resultado do trabalho de Shi, Wang e Zhang [197]. A BCI adquire 40 canais de EEG de um equipamento comercial (Compumedics Neuroscan modelo NuAmps), processa de forma *online* em um PC que se comunica com o helicóptero via *wi-fi*. Dez voluntários participaram do experimento onde podiam virar para direita ou esquerda via imaginação do movimento da mão direita ou esquerda. O movimento para frente (evitando colisões) e a altura eram controlados de forma autônoma. Foi alcançada uma taxa de acerto de 94,36 %.

O terceiro trabalho selecionado foi desenvolvido por Wu et al. [206], e aplica técnicas *fuzzy* de reconhecimento de padrões em EEG relacionados com IM da mão direita ou esquerda para movimentar um braço robótico (Kinova) para direita ou esquerda. O grupo desenvolveu um dispositivo sem fio (*Bluetooth*) para aquisição de quatro canais de EEG [211] [212] que se comunica com um PC para processamento digital.

No último artigo, um helicóptero virtual é controlado em um ambiente de realidade virtual para executar tarefas específicas, neste caso, passar por dentro de anéis posicionados de forma aleatória criados pelo sistema, fruto do trabalho de Doud e equipe [207]. O operador pode subir, descer e virar de lado combinando IM de diferentes partes do corpo (braços, língua e pé, mãos direita e esquerda). O sinal de EEG de 64 canais foi adquirido por um equipamento comercial (Compumedics Neuroscan modelo Synamps 2) e processado de forma *online* por um PC rodando o *software* BCI2000 [213] para calcular a PSD em diferentes canais. Três indivíduos sadios operaram o sistema e foi alcançada uma taxa de sucesso de 85 %, segundo os autores.

A aquisição e processamento do EEG nesses quatro artigos são diferentes e essas características estão resumidas na Tabela 2.6 para efeito de comparação.

Analizando os resultados da revisão bibliográfica percebe-se que o trabalho que mais se aproxima do proposto nesta tese é o de McCrimmon e equipe [181], pois utiliza uma sistema de processamento digital independente de um PC. As principais diferenças são o uso de microcontrolador, que possui arquitetura de *hardware* fixa e serial e o grupo não trabalha diretamente com IM. Nesta tese, o processamento do sinal proposto aplica *wavelets* para separação das ondas de EEG, calculando a energia da onda α para de forma síncrona obter a ERD/ERS dos canais C3 e C4. A pesquisa revela que, atualmente, uma plataforma para reconhecimento de IM das mãos usando FPGA (*hardware* reconfigurável) para aplicações em BCI em tempo real é uma questão em aberto.

2.8 CONSIDERAÇÕES FINAIS

Este capítulo abordou a fundamentação teórica sobre a aquisição e processamento de sinais de EEG e introduziu uma abordagem via *hardware*, independente de um PC. Foi realizada uma revisão bibliográfica que embasa as atividades técnicas desenvolvidas.

Tabela 2.6 – Comparativo entre os artigos selecionados na revisão bibliográfica sistemática.

Autor	Aquisição de EEG	Processamento digital	<i>Feature extraction</i>	Classificador	Dispositivo controlado	Tarefa	Taxa de acerto máx. (%)
McCrimmon [181]	Equipamento próprio	Arduino Due	LDA	Bayesiano	Led	Movimentar a mão para acender um led	98
Shi [197]	Neuroscan NuAmps	PC	<i>Improved cross-correlation</i>	<i>Logistic regression pattern classification</i>	Hexacóptero	Atingir um alvo no final de um labirinto	94,36
Wu [206]	Equipamento próprio	PC	<i>Sub-band Common Spatial Pattern</i>	MLDA + fuzzy integral + PSO	Braço robótico	Braço robótico vira para direita ou esquerda e pega um copo	86
Doud [207]	Neuroscan Synamps	PC	ERD, ERS, PSD	(não informado)	Helicóptero virtual	Cruzar anéis aleatórios em um ambiente virtual	85

Fonte: autor.

O próximo capítulo apresenta o sistema desenvolvido para reconhecimento de IM das mãos em tempo real. Serão detalhados os circuitos de aquisição, processamento digital e de comunicação.

3 PLATAFORMA PARA RECONHECIMENTO DA IM DAS MÃOS EM TEMPO REAL

Este capítulo detalha os métodos para construção do sistema para reconhecimento de movimento e imaginação do movimento das mãos em tempo real. O sistema realiza aquisição do sinal de EEG, digitalização, processamento digital, transmissão e *feedback* visual do sinal processado. Descreve-se as especificações do sistema, o diagrama em blocos dos circuitos analógico e digital e os pormenores dos componentes empregados. Os algoritmos para decomposição em *wavelets*, cálculo da energia da onda alfa do EEG e decisão se houve IM são abordados.

No final do capítulo, é apresentado o protótipo do sistema em escala reduzida. Para mostrar a viabilidade do processo decompõe-se três sinais de EEG que são comparados com o *software* computacional Matlab.

3.1 ESPECIFICAÇÃO DO SISTEMA

A plataforma para reconhecimento de IM das mãos em tempo real foi concebida para ser portátil e funcionar com o mínimo de baterias possível, neste caso com quatro pilhas tipo AA. Possui um canal de comunicação sem fio, para enviar os sinais adquiridos e processados para um dispositivo remoto. Para exibir a decomposição do sinal e o resultado do reconhecimento de IM, a plataforma é equipada com uma saída de vídeo e um canal serial que pode ser ligado a um computador, para comparação numérica dos resultados.

A decisão do reconhecimento de IM pelo sistema é dada de forma visual em um monitor de vídeo, confirmando que IM foi reconhecida em tempo real. Todo processamento digital deve ser realizado em FPGA, por se tratar de um sistema portátil que tem a finalidade de dar mobilidade ao sistema.

O sistema foi dividido em três partes: um circuito analógico, um digital e os canais de comunicação. O circuito analógico de aquisição (*front-end*) condiciona e digitaliza dois canais de EEG. Autores como Silva [215] e McCrimmon [181] realizam a detecção de IM utilizando quatro canais (C3, C4, F3 e F4) ou mais [214], que estão sobre o córtex motor e pré-motor cerebral. Porém os pesquisadores Leeb et al. [255] mostram ser possível realizar a detecção por meio de dois canais unipolares C3 e C4 apenas, que torna o sistema mais compacto e prático para os usuários, com menor quantidade de eletrodos e fios sobre o couro cabeludo. O diferencial da plataforma proposta nesta tese é a portabilidade, processamento de sinais em paralelo e menor consumo de energia, visto que Leeb et al. usaram equipamentos comerciais para aquisição de EEG e um PC para processamento digital de sinais.

O circuito analógico foi dividido em: amplificador de instrumentação; filtro passa-alta; amplificador de sinal e filtro passa-baixa. Foi utilizado um amplificador de instrumentação de alta sensibilidade e baixo *offset*, com alta taxa de rejeição de modo comum (CMRR – *Common Mode Rejection Ratio*), devido à natureza do sinal de EEG apresentar baixa relação sinal ruído (SNR – *Signal Noise Ratio*). Os demais amplificadores foram escolhidos pelos mesmos critérios, porém sendo de uso geral, acessíveis no mercado local e de baixo custo. O fato do projeto ser definido como portátil, devendo funcionar à bateria, faz com que seja analisado o consumo de energia e as tensões de alimentação dos circuitos integrados. O sinal de EEG amplificado deve ter amplitude máxima de 3 V, que é o limite de saturação dos amplificadores e igual à tensão de referência do ADC. As amplitudes das ondas α , β , θ e δ do EEG variam entre 1 e $50\mu\text{V}$ (vide Seção 2.2). Para atender esta limitação, a amplificação do circuito analógico foi dimensionada para um ganho total máximo de 10.000, resultando em sinais entre 10 mV e 500 mV. Usou-se um ADC bipolar para a etapa de conversão analógico para digital, configurado com taxa de amostragem 250 sps (*samples per second*). A Seção 3.2 traz maiores detalhes do diagrama em blocos dos circuitos analógico e digital.

A etapa digital é composta por um FPGA, circuitos de interface serial e de vídeo e módulo de transmissão sem fio. No FPGA são realizadas as atividades de decomposição dos canais de EEG em *wavelets*, para separação em bandas de frequência, extração de características do sinal calculando a energia da onda α e execução do algoritmo de classificação, para decidir se o padrão de variação de energia corresponde à IM da mão esquerda ou direita.

Para interação com o usuário e outros dispositivos de análise e registro, foram implantados três formas de comunicação no sistema. O primeiro é um canal serial que opera

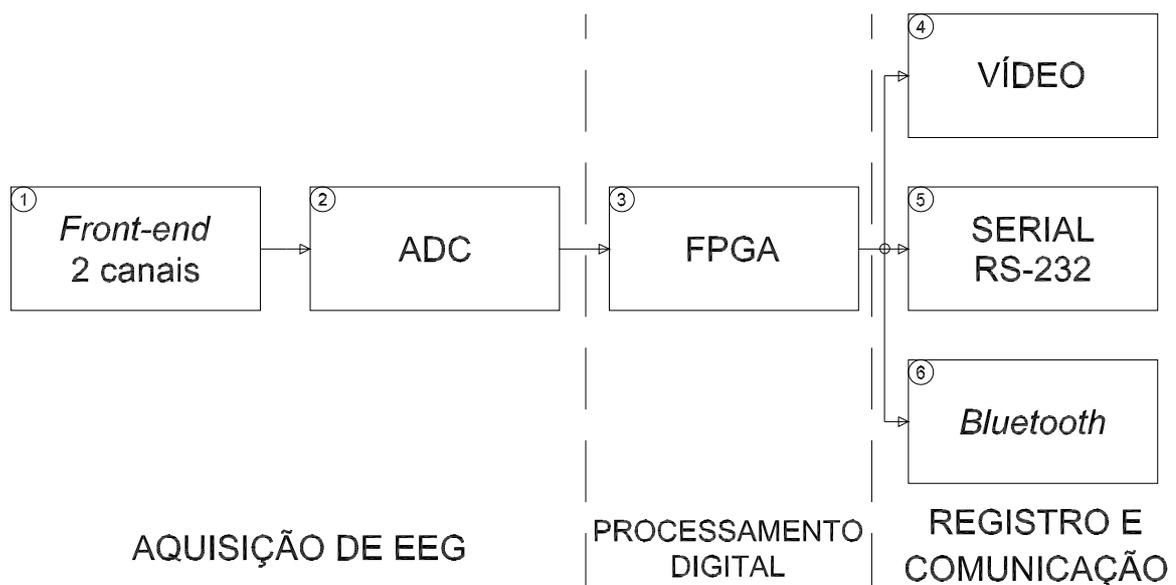
via padrão RS-232, que propicia uma forma de comunicação relativamente simples com um PC. Além deste, o sistema possui um canal de comunicação sem fio *Bluetooth*, para comunicação com dispositivos móveis. A saída de vídeo VGA possui resolução de 1280 colunas por 1024 linhas e fornece um *feedback* visual ao indivíduo que executa as tarefas de treinamento e teste para reconhecimento de IM das mãos.

A energia elétrica para o sistema é fornecida por duas fontes: quatro baterias recarregáveis tipo AA para os circuitos analógicos e uma fonte chaveada de 9V para os circuitos digitais e de comunicação, conforme descritos na próxima seção.

3.2 DIAGRAMA EM BLOCOS DA PLATAFORMA PROPOSTA

Conforme explanado na Seção 3.1, o sistema de reconhecimento de IM das mãos em tempo real foi construído em blocos, conforme diagrama apresentado na Fig. 3.1:

Figura 3.1 – Diagrama em blocos do sistema proposto para reconhecimento de IM das mãos em tempo real.



Fonte: autor.

De acordo com a Fig. 3.1, o sistema foi dividido em três grandes partes: aquisição de EEG, processamento digital e registro. Cada parte é descrita a seguir.

- Aquisição de sinais de EEG:
 1. Circuito analógico de aquisição de EEG (*front-end*) com dois canais unipolares (C3 e C4 do Sistema 10-20). Possui as etapas de amplificação e filtragem.
 2. Circuito para conversão analógico-digital (ADC) bipolar de 12 *bits*, e taxa de conversão de 250 sps. Faz a ligação entre o circuito analógico de aquisição e o FPGA.

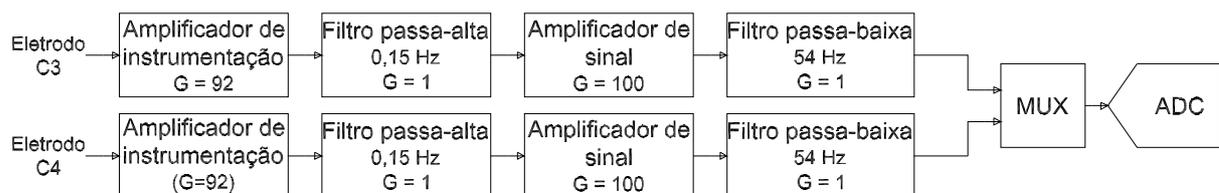
- Processamento digital:
 3. Bloco composto por um FPGA que realiza algoritmos de decomposição em *wavelets*, calcula a energia da onda α e decide se houve IM a partir de parâmetros pre-definidos.
- Registro e comunicação:
 4. Saída de vídeo VGA, para exibição da decomposição *wavelets*, energia da onda α e resultado da IM via *feedback* visual.
 5. Canal serial RS-232 para envio dos dados de processamento para um PC, para efetuar análise e comparações com o FPGA.
 6. Módulo sem fio *Bluetooth*.

As etapas de aquisição de sinais, registro e comunicação são detalhadas nas subseções seguintes. O bloco de processamento digital é pormenorizado na próxima Seção 3.3.

Placa de aquisição de EEG

O bloco de aquisição de EEG é sub-dividido nos circuitos de amplificação e filtragem analógica do sinal, para reduzir interferências de maior frequência que o EEG e limitar a banda passante para o processamento digital. Detalhes do bloco encontram-se na Fig. 3.2.

Figura 3.2 – Detalhe do circuito de aquisição de EEG de dois canais(*front-end*).



Fonte: autor.

Os circuitos de aquisição analógico de EEG foram construído especificamente para o sistema proposto, e montados em uma placa de circuito impresso dedicada. Esses circuitos captam dois canais unipolares chamados C3 e C4 conforme o Sistema 10-20, sendo a referência o canal Cz [227]. O eletrodo terra (GND) é aplicado na posição Fz.

O amplificador de instrumentação INA129 [216] foi escolhido por seus parâmetros de ganho de tensão, CMRR, tensão de alimentação, consumo de energia e disponibilidade no mercado nacional. O ganho de tensão é ajustável por um resistor externo e pode variar entre 1 e 10.000 V/v. Para atender as especificações do circuito, o ganho foi fixado em aproximadamente 92. Para este ganho, a faixa de passagem do amplificador é de 200 kHz,

suficiente para os sinais de EEG que possuem frequência máxima de 50 Hz. Possui tensão de *offset* máxima de $50\ \mu\text{V}$, corrente de entrada máxima de 5 nA e variação na tensão de saída causada pela variação de temperatura menor que $0,5\ \mu\text{V}/^\circ\text{C}$. A CMRR é de 120 dB para o ganho selecionado, valor importante para diminuir as interferências de modo comum nas entradas do amplificador. As tensões de alimentação variam entre $\pm 2,25$ e $\pm 18\ \text{V}$.

O circuito seguinte é um filtro passa-alta passivo com frequência de corte 0,15 Hz a (-3 dB). Na saída do filtro existe um amplificador de sinal não inversor de ganho 100, para aumentar mais a amplitude do sinal vindo do amplificador de instrumentação. O último circuito é um filtro passa-baixa ativo, montado de acordo com a topologia Sallen-Key [217] [218], ajustado para frequência de corte de 54 Hz (-3 dB) e ganho unitário. A amplificação total do circuito ficou em aproximadamente 8.900 V/V.

O filtro ativo passa-baixa e o amplificador de sinais foram projetados com o CI TLC277 [219], um operacional de baixo custo, baixo consumo de energia e disponível no mercado nacional. A faixa de passagem é de 1,7 MHz, tensão de *offset* típica de $200\ \mu\text{V}$, corrente de entrada máxima de 60 pA e flutuação da tensão de *offset* de $1,8\ \mu\text{V}/^\circ\text{C}$. A CMRR típica é de 80 dB. A tensão de alimentação varia entre 3 e 16 V. Todos estes parâmetros são para temperatura ambiente de 25°C .

A energia elétrica para esta placa dedicada e para a placa ADC é fornecida por quatro pilhas recarregáveis tipo AA que geram $\pm 2,5\ \text{V}$.

Placa de conversão analógico para digital

Uma segunda placa de circuito impresso foi criada para receber o CI MCP3304 [220], que é um ADC bipolar com 12 *bits* de resolução mais 1 *bit* de sinal em complemento de dois, e disponível no mercado local. Sua arquitetura interna é baseada no registrador de aproximação sucessiva (SAR – *Successive Approximation Register*) com circuito de *sample and hold*. Conta com até quatro canais bipolares de entrada multiplexados e um canal de comunicação SPI (*Serial Peripheral Interface*). Possui velocidade de conversão máxima de 100 ksps. Essa taxa foi sub-amostrada no FPGA para 250 sps, para atender a especificação do sistema descrita na Seção 3.1. A tensão de referência é de $\pm 2,5\ \text{V}$. A saída de comunicação foi ligada diretamente aos pinos do FPGA, na etapa digital do sistema.

Circuito de processamento digital

Após a aquisição e digitalização, os sinais são encaminhados para o FPGA para processamento digital. Utilizou-se uma placa de prototipação modelo DE0 [221] da marca Terasic Technologies [222], que possui o FPGA EP3C16F484C6 da Altera [141], modelo

Cyclone III (Seção 2.6). Os recursos de *hardware* disponíveis neste FPGA estão listados na Tabela 3.1.

Tabela 3.1 – Recursos disponíveis no FPGA EP3C16F484C6 da Altera.

Recursos	Quantidade
Elementos lógicos	15.408
<i>Bits</i> de memória RAM	516.096
Multiplicadores de 9 <i>bits</i>	112
PLL	4
Pinos de I/O	346
Clock 50 MHz	2

Fonte: autor.

Circuitos de comunicação e interface gráfica

Além do bloco “FPGA” ilustrado na Fig. 3.1, a placa de desenvolvimento DE0 abriga os circuitos elétricos para montagem dos blocos “VÍDEO” e “SERIAL RS-232”.

O bloco “VÍDEO” é composto por um circuito de interface VGA (*Video Graphical Adapter*), formado por uma rede resistiva divisora para cada cor básica do sistema RGB (*Red-Green-Blue*) que funciona como um DAC (*Digital to Analog Converter*) de 4 *bits*. A resolução do monitor de vídeo empregado foi de 1280 colunas por 1024 linhas.

O circuito integrado ADM3202 [263] é um transceptor do protocolo de comunicação serial assíncrono RS-232 (UART - *Universal Asynchronous Receiver Transmitter*) para o padrão de tensão TTL. O canal foi configurado para taxa de transmissão de 115.200 bps, sem paridade e 1 *stop bit*. Esta taxa de transmissão é suficiente para enviar todos os *bits* resultantes do processamento dos dois canais de EEG analisados de forma serial para um PC. Apesar de ser necessário um conversor serial para USB, este ainda é um método simples de transmissão de dados do ponto de vista do transmissor (sistema proposto), se comparado com outros métodos. Por exemplo, numa comunicação USB-USB deve-se ter um microcontrolador dedicado no sistema para adequar os sinais a serem transmitidos para o padrão USB, que tem a vantagem de transmitir em maiores taxas, porém aumentando a complexidade do circuito.

Para o canal de comunicação sem fio, aplicou-se um transceptor *Bluetooth* protocolo v2.0+EDR, que transmite dados na frequência de 2,4 GHz, chamada faixa ISM (*Industrial, Scientific and Medical Radio Bands*). A taxa de transmissão máxima é de 2 MHz. A finalidade deste canal é possibilitar flexibilidade e mobilidade ao sistema, que pode ser lido por um dispositivo móvel (*smartphone, tablet*) ou um PC. O sistema funciona no modo *server* do protocolo *Bluetooth*, enquanto o dispositivo que solicita o serviço é o *client*. Após estabelecida a comunicação com um dispositivo *client* de destino (pareamento), o

sistema envia os sinais e dados resultantes do processamento. A implementação desse canal sem fio se fez por meio do módulo comercial HC-05 [264], de baixo custo e acessível no mercado local. A conexão de dados entre o FPGA e o módulo *Bluetooth* ocorre via UART.

Cada pino do FPGA é ligado a um desses circuitos em pontos específicos descritos no manual do usuário da placa DE0. Esses pinos devem ser mapeados pelo código escrito em linguagem de descrição de *hardware*, para que cada bloco de circuito digital interno acesse o externo correspondente.

A relação detalhada dos componentes utilizados no sistema encontra-se na Tabela 3.2.

Tabela 3.2 – Descrição dos componentes utilizados no protótipo de um canal.

Circuito	Componente principal	Detalhes
Amplificador de instrumentação	INA129	Ganho 89
Filtro passa-alta 0,16 Hz	Resistor, capacitor	Passivo, 1 ^a ordem
Amplificador de sinal	TLC277	Inversor, ganho 100
Filtro passa-baixa 54 Hz	TLC277	Butterworth, 2 ^a ordem, ganho 1
ADC	MCP3304	Resolução 13 <i>bits</i> , 250 sps
FPGA	EP3C16F484C6	Altera, embarcado na placa DE0
Transceptor RS-232	ADM3202	Embarcado na placa DE0
Interface de vídeo	Rede resistiva	Embarcada na placa DE0
Transceptor <i>wireless</i>		Módulo, <i>Bluetooth</i> , ISM 2,4 GHz

Fonte: autor.

A Fig. 3.3 mostra os detalhes do *hardware* completo, enquanto que a Fig. 3.4 apresenta a tela básica com os sinais C3 e C4 do EEG. As barras verticais significam a energia instantânea da onda α de cada canal. Uma imagem da colocação dos eletrodos na cabeça de um voluntário é exibida na Fig. 3.5.

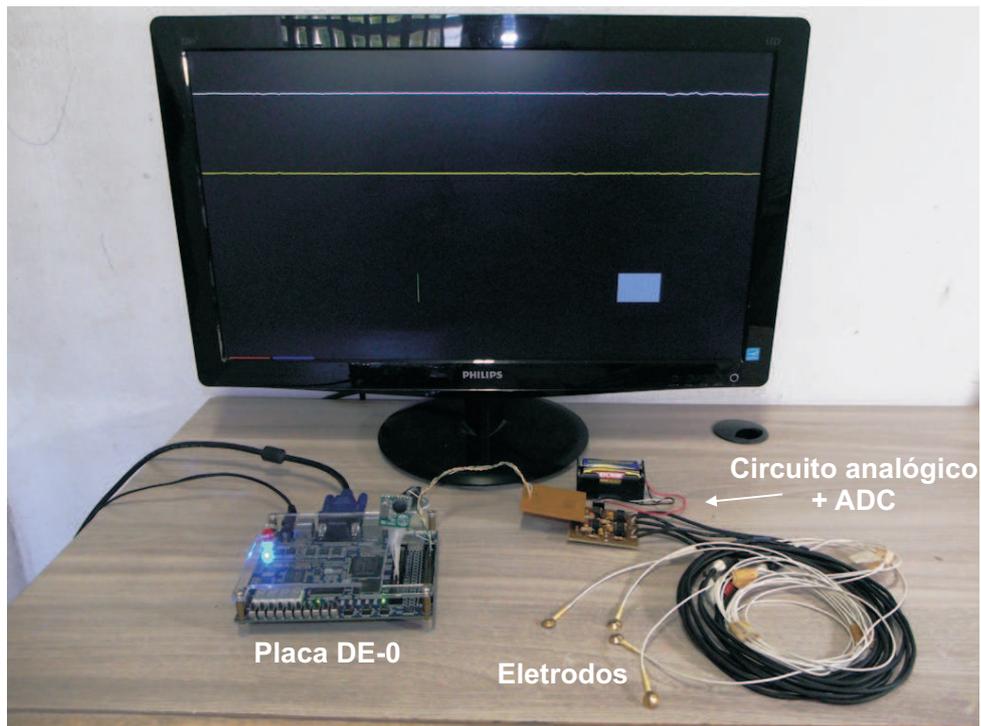
A seção seguinte descreve as funções e características do sistema digital construído no FPGA. É executada a decomposição *wavelets* para separar as ondas (faixas) do sinal de EEG, e calculada a energia da onda α para cada canal. Durante a fase de reconhecimento de IM, são realizados os cálculos de ERD/ERS dos canais C3 e C4 e decisão.

3.3 SUBSISTEMA DIGITAL CONSTRUÍDO NO FPGA

Construiu-se no FPGA um subsistema digital para realizar as seguintes tarefas:

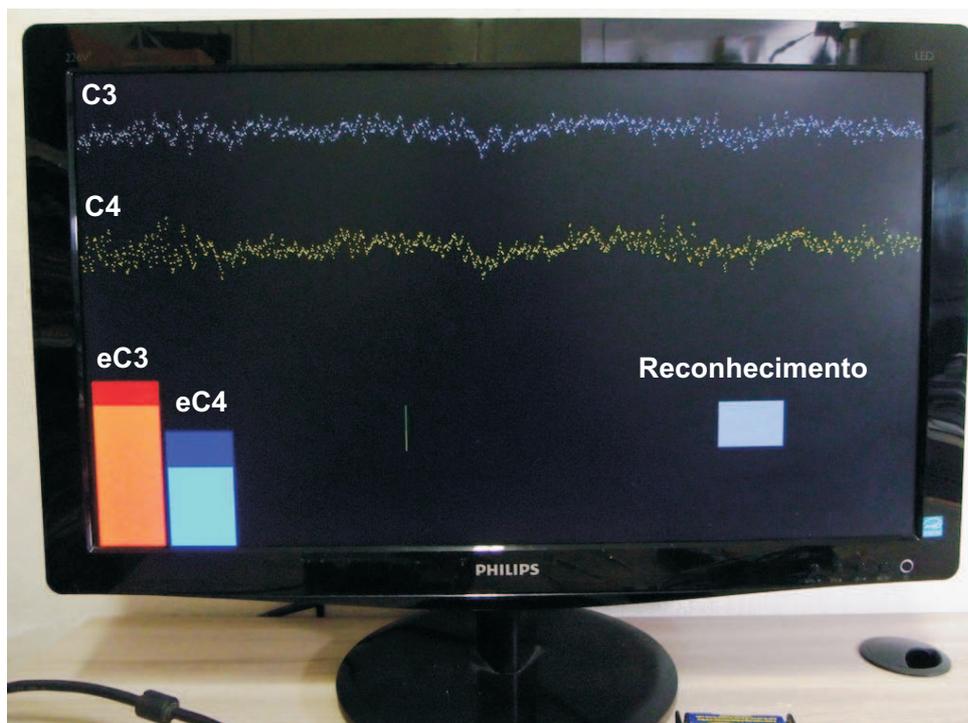
- Comunicar-se via SPI com a placa ADC.

Figura 3.3 – Fotos do *hardware* completo de aquisição, processamento digital e exibição.



Fonte: autor.

Figura 3.4 – Detalhe da tela básica do sistema, apresentando as curvas dos canais C3 e C4 do EEG, energia da onda α de cada canal (eC3 e eC4) e um quadrado cinza para reconhecimento de IM. Caso seja reconhecido, o quadrado muda para um círculo verde.



Fonte: autor.

Figura 3.5 – Fotografia mostrando o posicionamento dos eletrodos na cabeça de um voluntário.



Fonte: autor.

- Executar o algoritmo de separação das ondas β , α , θ e δ do sinal de EEG para cada um dos dois canais utilizando *wavelets* Daubechies-4.
- Calcular a energia da onda α de cada canal recorrendo-se ao método da *Wavelet Power Spectrum* (WPS).
- Decidir se houve IM da mão ou não, aplicando-se a técnica de *threshold* durante o ERD/ERS.
- Mostrar o resultado do processamento em tempo real em um monitor de vídeo VGA.
- Enviar os sinais digitalizados e dados processados via canais de comunicação serial e sem fio.

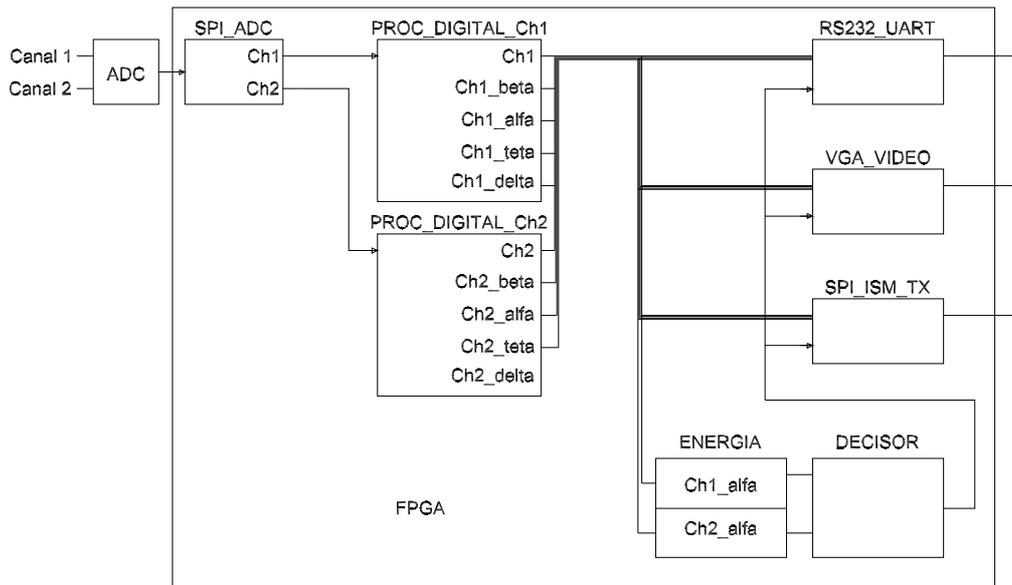
O subsistema digital foi dividido em blocos, um para cada atividade do processamento, conforme ilustrado na Fig. 3.6.

Esses blocos foram descritos no FPGA utilizando linguagem de descrição de circuitos Verilog [144].

O bloco nomeado “SPI_ADC” realiza a interface de comunicação serial síncrona SPI com a placa ADC (Seção 3.2). O conversor digitaliza os dois canais de EEG com uma taxa de amostragem de 250 sps.

A justificativa para escolha da taxa de amostragem de 250 sps é porque esta permite uma decomposição *wavelet* com cinco níveis que se aproxima das faixas de frequências reais

Figura 3.6 – Diagrama em blocos do sistema digital construído no FPGA. O módulo “SPI_ADC” executa a comunicação via SPI com o ADC para obter as amostras do sinal de EEG. O módulo “PROC_DIGITAL” realiza a decomposição em *wavelets*. Os módulos “ENERGIA” e “DECISOR” calculam a energia das ondas α de cada canal e decidem se houve IM ou não da mão. Os módulos “RS232_UART”, “VGA_VIDEO” e “SPI_ISM_TX” enviam o resultado para os dispositivos de registro correspondentes.



Fonte: autor.

do sinal de EEG, conforme detalhado na Tabela 3.3. A largura de banda tradicional do sinal de EEG é 40 Hz, e com uma amostragem de 250 sps se garante a frequência mínima de Nyquist que seria 80 Hz. Caso o sinal fosse amostrado a uma taxa maior seriam necessários mais níveis de decomposição para se chegar nas frequências correspondentes das ondas β , α , θ e δ , o que exigiria maior poder de processamento do FPGA, consequência direta da maior complexidade do sistema.

Tabela 3.3 – Decomposição em *wavelets* para um sinal de EEG amostrado a 250 sps.

Aproximação (LPF)		Detalhe (HPF)	
Nível	Frequência (Hz)	Nível	Frequência (Hz)
A1	0 - 62,5	D1	62,5 - 125
A2	0 - 31,25	D2	31,25 - 62,5
A3	0 - 15,625	D3	15,625 - 31,25
A4	0 - 7,8125	D4	7,8125 - 15,625
A5	0 - 3,90625	D5	3,90625 - 7,8125

Fonte: autor.

No bloco “PROC_DIGITAL” funcionam as máquinas de estado batizadas de “Wave Engines”, que calculam os coeficientes *wavelets* de detalhes D3, D4, D5 e de aproximação

A5, representando as ondas β , α , θ e δ respectivamente. As máquinas trabalham em paralelo, calculando os coeficientes a partir do sinal digitalizado proveniente dos canais C3 e C4 do EEG. Graças a esta arquitetura em paralelo, é possível fornecer os oito coeficientes (quatro para cada canal) ao mesmo tempo a cada ciclo de amostragem de 4 ms (250 sps). Maiores detalhes das *Wave Engines* e do algoritmo de decomposição são encontrados na Seção 3.4.

Importante ressaltar que as *Wave Engines* são ULAs (Unidades Lógico-Aritméticas) construídas especificamente para o cálculo das *wavelets* com números inteiros, conforme o algoritmo descrito na Seção 3.5. Diferente do Matlab, que trabalha com aritmética de ponto flutuante por rodar em um PC com processador de uso geral, não é possível descrever as equações para calcular os coeficientes *wavelets* em linguagem Verilog e sintetizar para o FPGA, pois as linguagens HDL não suportam aritmética de ponto flutuante para sintetizar circuitos digitais, apenas números inteiros [223] [224]. Caso seja necessário trabalhar com ponto flutuante é preciso descrever uma ULA para esse fim [225] [226].

O bloco “ENERGIA” calcula a energia das ondas α de cada canal digitalizado do EEG, e fornece esta informação para o módulo “DECISOR”. Este decide se houve IM ou não da mão comparando a variação de energia entre os canais após um sinal de sincronismo, que serve para informa ao usuário que a imaginação deve ser realizada. As descrições completas destes cálculos e procedimentos são apresentadas nas Seções 3.5 e 3.6.

O bloco “RS232_UART” tem a finalidade de controlar o circuito externo da UART, que transmite os sinais digitalizados, os coeficientes da decomposição em *wavelets* e os cálculos de energia da onda α para um PC. Conforme dito na Seção 3.2, a placa DE0 possui um CI dedicado para comunicação via padrão RS-232.

O bloco “VGA_VIDEO” apresenta o sinal de EEG decomposto pela *wavelet* em monitor de vídeo VGA. Este bloco possui um *buffer* de vídeo construído com memória RAM interna ao FPGA, que armazena os pontos que são exibidos no monitor e são atualizados a cada 4 ms (250 sps). Além de manipular o *buffer*, o bloco gera os sinais de controle e sincronismo para correta operação do monitor.

O último bloco é o “SPI_TX”, responsável por controlar o módulo externo *Bluetooth*, enviando os sinais e coeficientes das *wavelets* para transmissão sem fio. Esses dados são enviados para um receptor *wireless* e podem ser encaminhados a um monitor de vídeo ou outro dispositivo de registro (impressora, PC, *smartphone*, *tablet*).

A Fig. 3.7 traz uma visão geral do sistema digital em formato RTL (*Register Transfer Logic*).

Os resultados obtidos com o sistema completo são apresentados no Capítulo 4. Nas próximas seções são detalhados os algoritmos de cálculo dos coeficientes *wavelets*, energia da onda α e decisão sobre a IM das mãos.

3.4 ALGORITMO PARA CÁLCULO DOS COEFICIENTES DA WAVELET DAUBECHIES-4

Neste trabalho, as ondas β , α , θ e δ do EEG são representadas pelos detalhes e aproximação D3, D4, D5 e A5 do cálculo da *wavelet* respectivamente, considerando uma taxa de amostragem de 250sps. Foram consideradas as frequências das ondas de EEG conforme Tab. 3.4, em comparação com a decomposição *wavelets* realizada pelo algoritmo proposto, que é executado pelos módulos “PROC_DIGITAL” (vide Fig 3.6).

Tabela 3.4 – Relação entre a decomposição em *wavelets* e as frequências do sinal de EEG.

Onda	Frequência (Hz)	Nível	Frequência considerada (Hz)
β	13 - 30	D3	15,625 – 31,25
α	8 - 13	D4	7,8125 – 15,625
θ	4 - 8	D5	3,90625 – 7,8125
δ	< 4	A5	0 – 3,90625

Fonte: autor.

Para a decomposição do sinal de EEG utilizou-se a *wavelet* Daubechies com quatro coeficientes [132], conforme apresentada na Seção 2.5. A *wavelet* Daubechies-4 precisou ser adaptada para construção do circuito digital que realiza os cálculos dos coeficientes, pois os recursos computacionais disponíveis no FPGA são limitados e devem ser otimizados. Além disso, as linguagens HDL atualmente não suportam a aritmética de ponto flutuante, conforme Seção 3.3. Portanto, não é possível escrever um programa em Matlab com as funções “`dwt()`” e gerar um código em HDL para sintetizar um circuito digital, pois as funções convertem as variáveis para o tipo *float*, não permitindo sua execução em FPGA.

De forma a comparar a melhor solução foram montados três esquemas para execução do algoritmo:

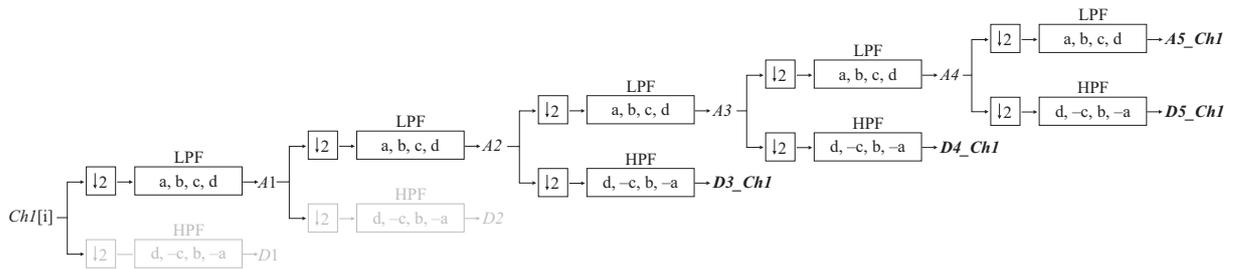
Esquema 1 Cálculo direto da decomposição de cada nível (A1 a A5 e D1 a D5), conforme Seção 2.5;

Esquema 2 Descrição da equação para os coeficientes de interesse D3, D4, D5 e A5 em função das amostras do sinal de entrada, sem calcular os níveis intermediários A1, A2, A3, A4 e D1, D2;

Esquema 3 ULA e máquinas de estados operando em paralelo para realizar os cálculos sobre as parcelas da equação dos coeficientes do esquema 2, uma por vez.

Os esquemas descritos em Verilog foram comparados observando-se o uso de recursos lógicos do FPGA (Tabela 3.1) e o atendimento às restrições de tempo calculadas pela ferramenta de edição Quartus II da Altera [147].

Figura 3.8 – Análise multirresolução.



Fonte: autor.

Esquema 1 - Cálculo direto

Observando-se a Fig. 3.8 nota-se que para calcular os coeficientes de interesse D3_Ch1, D4_Ch1, D5_Ch1 e A5_Ch1 do canal 1, por exemplo, deve-se calcular os coeficientes intermediários A1 e A2.

O primeiro esquema utiliza o cálculo direto do algoritmo para a *wavelet* Daubechies-4. Cada nível de decomposição é calculado e armazenado em variáveis, como segue:

1. O primeiro nível de decomposição gera os coeficientes de Aproximação A1 e Detalhes D1, a partir da amostra atual do sinal de entrada digitalizado.
2. A entrada do segundo nível é a Aproximação A1 do primeiro nível. A saída são os coeficientes de Aproximação A2 e Detalhes D2.
3. O terceiro nível recebe como entrada os coeficientes de Aproximação A2 e gera a Aproximação A3 e Detalhes D3.
4. Este processo se repete até o quinto nível.

Desta forma obtém-se todos os coeficientes da Tab. 3.3 armazenados em variáveis. Porém, para análise do sinal de EEG decomposto utiliza-se os coeficientes D3, D4, D5 e A5, conforme Tab. 3.4. Para este processamento ser executado por um FPGA é necessária uma quantidade de recursos computacionais que serve como parte intermediária dos cálculos dos coeficientes de interesse. Assim, obteve-se um consumo de recursos que não atuavam efetivamente no processamento da análise *wavelet*, e portanto, este esquema foi abandonado.

Esquema 2 - Equação dos coeficientes

Neste esquema, são descritas equações para cálculos dos coeficientes de detalhe D3, D4, D5 e aproximação A5 diretamente da amostra atual e das anteriores do sinal de entrada digitalizado. Este esquema aproveita a propriedade de causalidade das *wavelets*.

Para as amostras digitalizadas do canal 1 ($Ch1[i]$), tem-se a decomposição de primeiro nível, gerando os coeficientes $A1[i]$, conforme expressão a seguir (Fig. 3.8):

$$A1[\frac{i}{2}] = aCh1[i] + bCh1[i-1] + cCh1[i-2] + dCh1[i-3], \quad \forall i = 2k \mid k \geq 2, k \in \mathbb{N}, \quad (3.1)$$

em que a, b, c, d são os coeficientes da *wavelet* Daubechies-4.

Seguindo o mesmo raciocínio, calcula-se os coeficientes do segundo nível $A2[i]$ a partir de $A1[i]$:

$$A2[\frac{i}{4}] = aA1[\frac{i}{2}] + bA1[\frac{i}{2} - 1] + cA1[\frac{i}{2} - 2] + dA1[\frac{i}{2} - 3], \quad \forall i = 4k \mid k \geq 3, k \in \mathbb{N}. \quad (3.2)$$

Substitui-se os coeficientes $A1[i]$ pela expressão (3.1) em função do sinal amostrado $Ch1$:

$$\begin{aligned} A2[\frac{i}{4}] = & a(aCh1[i] + bCh1[i-1] + cCh1[i-2] + dCh1[i-3]) + \\ & b(aCh1[i-2] + bCh1[i-3] + cCh1[i-4] + dCh1[i-5]) + \\ & c(aCh1[i-4] + bCh1[i-5] + cCh1[i-6] + dCh1[i-7]) + \\ & d(aCh1[i-6] + bCh1[i-7] + cCh1[i-8] + dCh1[i-9]), \\ & \forall i = 4k \mid k \geq 3, k \in \mathbb{N}. \end{aligned} \quad (3.3)$$

Os coeficientes de terceiro nível de decomposição $D3[i]$ representam a faixa β do EEG, e são calculados conforme (Fig. 3.8):

$$\begin{aligned} D3[\frac{i}{8}] = & dA2[\frac{i}{4}] + (-c)A2[\frac{i}{4} - 1] + \\ & bA2[\frac{i}{4} - 2] + (-a)A2[\frac{i}{4} - 3], \quad \forall i = 8k \mid k \geq 3, k \in \mathbb{N}. \end{aligned} \quad (3.4)$$

Em função do sinal amostrado $Ch1$ tem-se:

$$\begin{aligned}
D3\left[\frac{i}{8}\right] = & (aad) s[i] + \\
& (abd) s[i - 1] + \\
& (acd + abd) s[i - 2] + \\
& (add + bbd) s[i - 3] + \\
& (bcd + acd - aac) s[i - 4] + \\
& (bdd + bcd - abc) s[i - 5] + \\
& (ccd + add - acc - abc) s[i - 6] + \\
& (cdd + bdd - acd - bbc) s[i - 7] + \\
& (cdd - bcc - acc + aab) s[i - 8] + \\
& (ddd - bcd - bcc + abb) s[i - 9] + \\
& (-ccc - acd + abc + abb) s[i - 10] + \\
& (-ccd - bcd + abd + bbb) s[i - 11] + \\
& (-ccd + bbc + abc - aaa) s[i - 12] + \\
& (-cdd + bbd + bbc - aab) s[i - 13] + \\
& (bcc + abd - aac - aab) s[i - 14] + \\
& (bcd + bbd - aad - abb) s[i - 15] + \\
& (bcd - abc - aac) s[i - 16] + \\
& (bdd - abd - abc) s[i - 17] + \\
& (-acc - aad) s[i - 18] + \\
& (-acd - abd) s[i - 19] + \\
& (-acd) s[i - 20] + \\
& (-add) s[i - 21], \quad \forall i = 8k \mid k \in \mathbb{N}.
\end{aligned} \tag{3.5}$$

Para calcular os coeficientes de detalhes D4, D5 e aproximação A5 segue-se o mesmo procedimento descrito para o detalhe D3. As constantes a , b , c e d em (3.5) são substituídas por seus respectivos valores da *wavelet* Daubechies-4 (2.12) e computadas. Estes são armazenados em memória ROM descrita no código Verilog, que os disponibiliza para o circuito digital executar o algoritmo. Assim, calcula-se o coeficiente $D3[i]$ multiplicando a amostra atual do sinal de entrada $Ch1[i]$ e as anteriores armazenadas em registradores por constantes gravadas na memória, e soma-se os termos conforme (3.5). Essa atividade é realizada por um circuito MAC (*Multiplier Accumulate Cell*).

O número de parcelas para calcular cada coeficiente aumenta com o número de níveis. Com isso aumenta a quantidade de amostras anteriores do sinal de entrada $Ch1$ que precisam ser armazenadas, consumindo os recursos computacionais do FPGA. Pela expressão (3.6) [265] é possível determinar a quantidade de amostras e parcelas necessárias

para computar os coeficientes de aproximação e detalhe uma determinado nível da *wavelet*:

$$q(n) = 3 \cdot 2^n \left(\sum_{i=1}^n \frac{1}{2^i} \right) + 1, \quad (3.6)$$

em que $q(n)$ é a quantidade de amostras, em consequência a quantidade de parcelas para computar os coeficientes do nível desejado, e n é o nível que se deseja decompor em *wavelets*.

Prova.

1. Para $n = 1 \Rightarrow q(1) = 4 = 2 \cdot 1 + 2$.
2. Para $q(n + 1) = 2 \cdot q(n) + 2, \forall n \in \mathbb{N}$.

$$\begin{aligned} q(n + 1) &= 3 \cdot 2^{n+1} \left(\sum_{i=1}^{n+1} \frac{1}{2^i} \right) + 1 \\ &= 3 \cdot 2^n \cdot 2 \left[\left(\sum_{i=1}^n \frac{1}{2^i} \right) + \frac{1}{2^{n+1}} \right] + 1 \\ &= \left(3 \cdot 2^n \cdot 2 \sum_{i=1}^n \frac{1}{2^i} \right) + \left(3 \cdot 2^{n+1} \cdot \frac{1}{2^{n+1}} \right) + 1 \\ &= \left(2 \cdot 3 \cdot 2^n \sum_{i=1}^n \frac{1}{2^i} \right) + 2 + 2 \\ &= 2 \left(3 \cdot 2^n \sum_{i=1}^n \frac{1}{2^i} + 1 \right) + 2 \\ &= 2 \cdot q(n) + 2. \quad \square \end{aligned}$$

Como exemplo, para calcular o coeficiente de aproximação A5 são necessárias 94 amostras do sinal de EEG. Desta forma, garante-se que sempre serão computados dados válidos a partir do sinal de entrada.

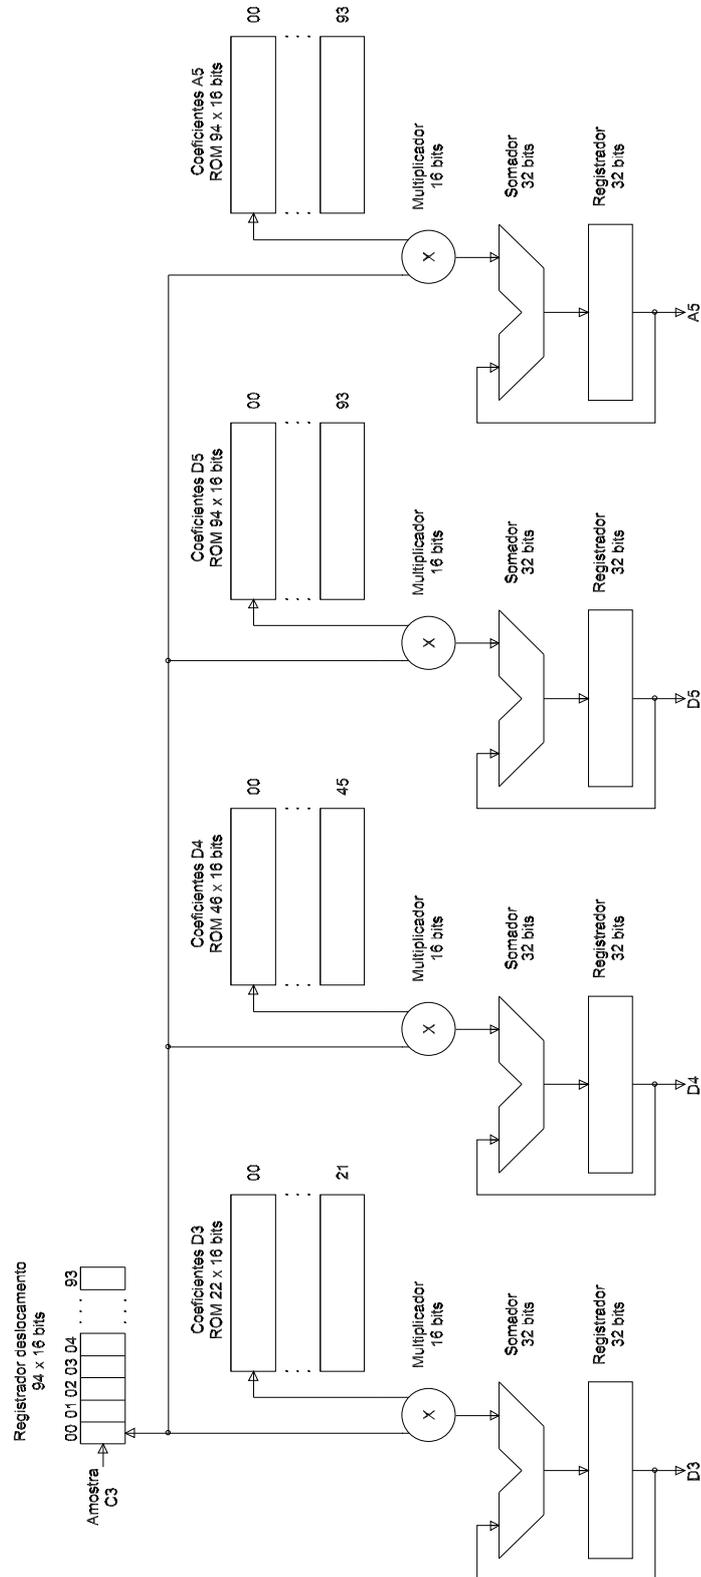
Esquema 3 - Máquina de estados para cálculo dos coeficientes

Para tornar o processo de cálculo dos coeficientes mais eficiente, do ponto de vista do uso dos recursos do FPGA, foi construída uma máquina de estados nomeada *Wave Engine* para realizar em paralelo a multiplicação e soma das parcelas descritas na Seção 3.4 (Fig. 3.9).

O núcleo das *Wave Engines* é uma estrutura aritmética comum na construção de filtros digitais conhecida como MAC (*Multiplier Accumulate Cell*) [130] [266] [267]. O trabalho da máquina é alimentar sua MAC em sincronismo com a digitalização do sinal de EEG, acionar os sinais operacionais de controle dos cálculos e armazenar o resultado.

O multiplicador foi descrito em HDL para usar um dos que se encontram embutidos no *hardware* do FPGA, enquanto o conjunto somador e registrador (conhecido por acumulador), são construídos com elementos lógicos: 36 *lookup tables* e 34 registradores.

Figura 3.9 – Diagrama esquemático das *Wave Engines* para cálculo dos coeficientes D3, D4, D5 e A5 em paralelo. Em cada *Wave Engine* o sinal de EEG bruto ("Amostra sinal") é multiplicado pelo seu coeficiente que foi salvo anteriormente numa memória não volátil, somado ao resultado anterior e armazenado no registrador de saída de 32 bits.



Fonte: autor.

Conforme (3.6), escreve-se a Tabela 3.5 com a quantidade de interações da *Wave Engine* para calcular os coeficientes D3, D4, D5 e A5 da *wavelet* Daubechies-4.

Tabela 3.5 – Quantidade de interações necessárias para calcular os coeficientes da *wavelet* Daubechies-4.

Coeficiente	Interações
D3	22
D4	46
D5	94
A5	94

Fonte: autor.

Pela Tabela 3.5 percebe-se que a maior quantidade de interações ocorre no cálculo dos coeficientes D5 e A5. A taxa de amostragem definida de 250 sps gera uma nova amostra do sinal de entrada a cada 4 ms. Então, são necessários aproximadamente $4\text{ms}/94 \approx 42 \mu\text{s}$ no máximo para realizar cada interação. Foi escolhido o tempo de $10 \mu\text{s}$, que é suficiente para que os multiplicadores e acumuladores da *Wave Engine* executarem os cálculos. O relógio (*clock*) do sistema é 50 MHz, e o acumulador leva dois ciclos de *clock* para calcular, ou seja, $0,04 \mu\text{s}$. O multiplicador pode operar até 340 MHz, porém trabalha na velocidade do *clock* do sistema. Portanto, o tempo de processamento de cada *Wave Engine* é $0,02 \mu\text{s}$ do multiplicador mais $0,04 \mu\text{s}$ do acumulador, totalizando $0,06 \mu\text{s}$.

Para o cálculo de D3, D4, D5 e A5 o sistema deve aguardar o preenchimento inicial do registrador de deslocamento até a 94^a amostra para calcular D5 e A5, que são os piores casos ou “gargalos” do processamento, pois possuem a maior quantidade de parcelas para cada coeficiente calculado (ver (3.6)). Após o preenchimento inicial cada interação das *Wave Engine* leva $10 \mu\text{s}$ e os cálculos dos coeficientes D5 levam no máximo $10 \mu\text{s} \cdot 94$ interações = $0,94\text{ms}$. Porém, por definição de projeto, os coeficientes são liberados quando uma nova amostra do sinal chega ao registrador de deslocamento, ou seja, a saída é atualizada a cada 4 ms. Resumindo, o sistema possui os tempos de operação descritos na Tabela 3.6. Com isso, são liberados 8 novos coeficientes a cada 4 ms.

Um ponto deve ser observado. Caso se deseje aumentar a taxa de amostragem, em busca de maior resolução no sinal de EEG, deve-se ter maior quantidade de níveis da *wavelet*. O aumento do número de níveis altera o tempo de configuração inicial, para preencher mais amostras de acordo com o nível desejado em (3.6). Depois que o registrador de deslocamento está preenchido, os tempos de processamento são os mesmos. Porém, existe um limite de níveis que podem ser processados. Esse limite é dado pela velocidade de operação dos multiplicadores. Por exemplo, com taxa de amostragem de 250 sps e velocidade de processamento de 340 MHz para os multiplicadores do FPGA escolhido [140], a quantidade máxima de interações que podem ser executadas é 1.360.000. Aplicando (3.6), a quantidade máxima de níveis para o FPGA selecionado é 18, resultado em $q(18) =$

Tabela 3.6 – Tempos de processamento do sistema para cálculo da *wavelet* Daubechies-4.

Operação	Tempo (ms)
Configuração inicial	376
<i>Wave Engine</i>	0,96
Amostragem canais C3, C4	4
Atualização dos coeficientes D3	32
Atualização dos coeficientes D4	64
Atualização dos coeficientes D5, A5	128

Fonte: autor.

786.430 interações. Caso se deseje mais níveis deve-se utilizar um FPGA com maior capacidade de processamento, ou seja, mais memória disponível e multiplicadores mais rápidos.

Desta forma, foi projetada uma *Wave Engine* para cada coeficiente, totalizando oito, funcionando em paralelo, conforme Fig. 3.6. A cada amostra do sinal são gerados diretamente os quatro coeficientes (D3, D4, D5 e A5) dos dois canais C3 e C4 digitalizados, sem a necessidade de computar os coeficientes A1, A2, A3, A4, D1, D2. Porém, estes podem ser disponibilizados caso sejam necessários para aplicações futuras, pois suas *Wave Engines* encontram-se descritas nos códigos do sistema, estando apenas desligadas.

3.5 CÁLCULO DA ENERGIA DA ONDA α

Ainda no FPGA foi desenvolvido um algoritmo para calcular a energia da onda α de cada canal usando a técnica de escalograma (*scalogram*). Diversos autores aplicam a técnica em diferentes tipos de sinais. Por exemplo, De Oliveira [228] aplica o escalograma em sinais de áudio a partir dos coeficientes da Transformada *Wavelet* Contínua (CWT – *Continuous Wavelet Transform*). Chiann e Morettin [230] aplicam escalogramas no estudo de padrões de EEG durante o sono em recém-nascidos. Uma análise detalhada das DWT (*Discrete Wavelet Transform*) aplicadas em sinais cardiológicos (ECG – Eletrocardiografia) é descrita por Addison [231]. Bialasiewicz [232] analisa sinais biomédicos em geral a partir de escalograma. Maraun e Kurths [229] analisam processos geofísicos e Clerc e Mallat [233] em processamento de imagens. Aplicações de *wavelets* e escalograma para análise de vibração em máquinas rotativas são encontrados em Peng [234] e Addison [235].

Neste trabalho foi aplicado o escalograma a partir da DWT implementada em FPGA, especificamente na onda α de cada canal (C3 e C4). O cálculo do escalograma para análise das características do sinal de EEG é apoiado pelo trabalho de Bostanov [236].

O sinal de EEG pode ser modelado como um processo estocástico não estacionário [237] [238] [239] [240]. Será adaptado o escalograma (ou espectro) definido por Ariño [241], e de forma similar por Maraun [229], como um vetor composto pelas energias $E(j)$ em

cada nível j . Ariño representa a energia como

$$E(j) = \sum_{k=1}^{\frac{N}{2^j}} d_{j,k}^2, \forall j = 1, \dots, M, \quad (3.7)$$

em que $d_{j,k}$ são os k coeficientes do nível j , e M a quantidade de níveis da decomposição em *wavelets* e N o número de amostras digitalizadas do sinal original C3 ou C4. Neste trabalho $N = 1280$, que é a quantidade de pontos que serão exibidos no monitor de vídeo VGA durante o treinamento e testes de IM. A DWT implantada na FPGA decompõe em cinco níveis, neste caso $M = 5$.

O valor específico da energia da onda α , também conhecida como espectro de potência da *wavelet* (WPS – *Wavelet Power Spectrum*) [242], representada pelos coeficientes D4 da DWT ($j = 4$), é calculado da seguinte forma:

$$E_\alpha = \sum_{k=1}^{80} (D4[k])^2. \quad (3.8)$$

Detalhes sobre o emprego de *wavelets* para estimativa da densidade espectral de energia são encontrados em [243] e [244]. O escalograma descrito em (3.7) possui consistência adequada como estimador estatístico da energia da DWT. Conforme afirmado por Percival [245], a DWT é um estimador prático da variância da *wavelet*. Deve-se considerar as observações descritas por Liu [246] que multiplica os coeficientes ao quadrado pelo fator de escala 2^j para o cálculo do espectro de potência da *wavelet*.

Em Torrence [242] é calculada a média temporal do espectro de potência da *wavelet* (TAWPS – *Time Average Wavelet Power Spectrum*) em uma janela de largura $k - k_0 + 1$ a partir da expressão

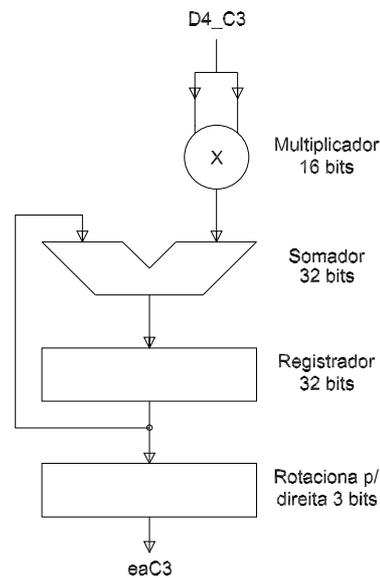
$$\overline{E}_\alpha[k] = \frac{1}{k - k_0 + 1} \sum_{k_0}^k (D4[k])^2, \quad (3.9)$$

em que k_0 é o índice do primeiro elemento da janela (mais antigo) e k o atual. Neste trabalho definiu-se de forma empírica uma janela de tamanho oito.

Seguindo a mesma ideia de calcular os coeficientes *wavelets* por uma máquina de estados, construiu-se outra para a TAWPS (Fig. 3.10). A máquina controla o circuito MAC e acumula oito pontos, conforme o tamanho da janela. Por fim, é realizada uma rotação de 3 *bits* para a direita, que equivale a dividir por oito em notação binária. Desta forma, a cada 64 ms (vide Tabela 3.6) é disponibilizado um novo valor de \overline{E}_α , que é a TAWPS de oito pontos calculada para a onda α .

Os resultados do escalograma, a partir de (3.9), são encaminhados para o módulo de classificação para decidir se houve ou não o movimento ou IM da mão.

Figura 3.10 – Diagrama em blocos da “Energy Engine”, para calcular a energia da onda α , uma para cada canal C3 e C4.



Fonte: autor.

3.6 ALGORITMO DE CLASSIFICAÇÃO

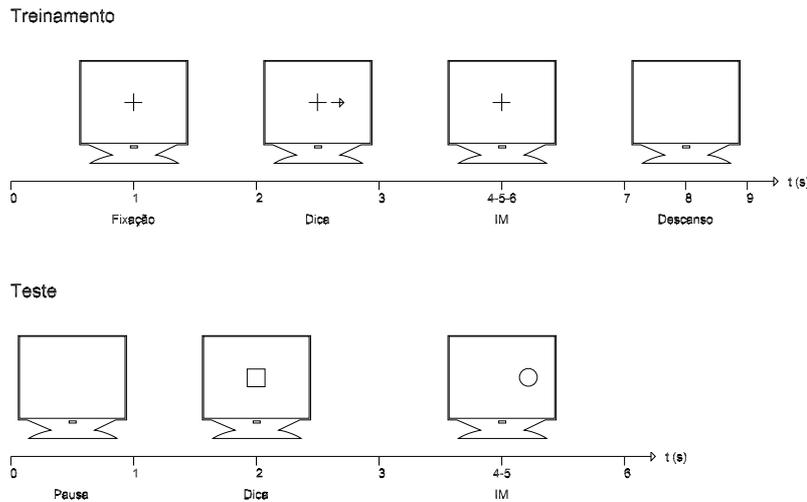
Existem algoritmos para classificar os parâmetros extraídos de EEG, explanados na Seção 2.7. Os mais simples são *thresholding* e análise de máximo valor. Durante a etapa de implantação do algoritmo no sistema serão avaliados os diferentes métodos e escolhido o que possuir melhor equilíbrio entre consumo de recursos físicos e eficiência na decisão de acordo com métricas estabelecidas na literatura.

A técnica escolhida para classificar o EEG e decidir entre IM ou não foi *threshold*, por exigir baixo poder computacional e ser capaz de mostrar a viabilidade da plataforma proposta. A partir da onda alfa adquirida nos canais C3 e C4 calcula-se o índice ERD/ERS e é tomada a decisão caso o valor ultrapasse um certo limiar (*threshold*). Como exemplo de aplicação da técnica na literatura, Rebsamen et al. construíram uma cadeira de rodas controlada via onda P300 [247] e a equipe de Pfurtscheller permitiu que um paciente paralisado pudesse pegar um copo utilizando IM das mãos e pés [248].

A técnica de ERD/ERS para identificar IM da MD e ME é suportada por Tang et al. [249], Gao et al. [250], Graimann e Pfurtscheller [251], Pfurtscheller e Aranibar [252] [253], Kalcher e Pfurtscheller [254].

É preciso treinar o sistema para ele ser capaz de reconhecer IM. Após o treino é possível informar ao sistema qual o valor limitante (*threshold*) para decidir se houve IM e qual foi a mão imaginada. Então, pode-se iniciar a fase de testes, para reconhecimento de IM com *feedback* visual para o indivíduo que está operando o sistema.

Figura 3.11 – Diagramas de tempo dos protocolos de treinamento e teste do sistema.



Fonte: autor.

O princípio básico envolve a sincronização e dessincronização das ondas α na região motora do córtex cerebral que comanda os movimentos das mãos. Os eletrodos C3 e C4 ficam sobre essa região e são utilizados em diversas publicações na área, por exemplo [261], [262] e demais referências da Seção 2.4.

Cada indivíduo se comporta de forma diferente. Em geral, indivíduos destros apresentam uma diferença maior entre as ERD dos canais C3 e C4, facilitando o reconhecimento de IM [115] [117]. Em resumo, ocorre a ERD no canal contralateral e ERS no canal ipsilateral da mão imaginada.

Antes da tarefa de classificação deve-se treinar o sistema para extração do valor ótimo para o *threshold*. A etapa de treino consiste em 10 seções de 10 tentativas cada, sem *feedback* visual, para não alterar a resposta natural ao estímulo visual. O indivíduo deve sentar-se confortavelmente em uma cadeira com encosto e de frente para um monitor de vídeo distante aproximadamente 1 m no nível dos olhos. É exibido um sinal “+” no centro do monitor por 2 s para que o indivíduo olhe fixamente. É instruído para não ter pensamento nesse instante e se concentrar na tela. Em seguida, uma seta (dica) surge por 1 s indicando a direção da IM, seja mão direita (MD) ou mão esquerda (ME). Logo após vem o período de IM por 4 s, finalizando com um tempo de descanso de 2 s com a tela em branco. Este protocolo foi adaptado de Leeb et al. [255], Pfurtscheller et al. [256] [257] e Yi [258] e está resumido na Fig. 3.11.

Os sinais do treinamento são analisados posteriormente para identificar o ERD/ERS conforme a dica. Aplica-se o mesmo algoritmo que será usado na etapa de teste.

A classificação para decidir se houve IM inicia com o cálculo da energia da onda α dos canais C3 e C4 simultaneamente, 1 s antes da dica aparecer na tela. Esse é o nível de referência que será comparado com a energia no período de IM, conforme (3.10) e (3.11)

a seguir:

$$E_{ref_{C3}} = \frac{1}{16} \sum_{k=1}^{16} (D4_{C3}[k])^2, \quad (3.10)$$

$$E_{ref_{C4}} = \frac{1}{16} \sum_{k=1}^{16} (D4_{C4}[k])^2. \quad (3.11)$$

Um segundo após a dica é calculado o TAWPS com janela de tamanho 1 s para o primeiro ponto, um para cada canal ((3.12) e (3.13)). Os pontos subsequentes são calculadas a cada 0,5 s com janela de 1 s. São calculados nove pontos no total:

$$\begin{aligned} ERD/ERS_{C3}[i] &= \frac{\frac{1}{16} \sum_{k=17+8(i-1)}^{32+8(i-1)} (D4_{C3}[k])^2}{E_{ref_{C3}}} \cdot 100 \% \\ &= \frac{\sum_{k=17+8(i-1)}^{32+8(i-1)} (D4_{C3}[k])^2}{\sum_{k=1}^{16} (D4_{C3}[k])^2} \cdot 100 \%, \quad i = 1, \dots, 9, \end{aligned} \quad (3.12)$$

$$\begin{aligned} ERD/ERS_{C4}[i] &= \frac{\frac{1}{16} \sum_{k=17+8(i-1)}^{32+8(i-1)} (D4_{C4}[k])^2}{E_{ref_{C4}}} \cdot 100 \% \\ &= \frac{\sum_{k=17+8(i-1)}^{32+8(i-1)} (D4_{C4}[k])^2}{\sum_{k=1}^{16} (D4_{C4}[k])^2} \cdot 100 \%, \quad i = 1, \dots, 9. \end{aligned} \quad (3.13)$$

Ocorre uma ERD nos respectivos canais C3 ou C4 quando $ERD/ERS_{C3}[i] < 100 \%$ ou $ERD/ERS_{C4}[i] < 100 \%$, indicando que a energia na fase de IM foi menor que no período de referência (1 s antes da dica). Quando $ERD/ERS_{C3}[i] > 100 \%$ ou $ERD/ERS_{C4}[i] > 100 \%$ ocorre uma ERS no canal C3 ou C4, respectivamente.

Os critérios para decidir se houve IM da MD são os seguintes:

1. Ocorrer ERD no canal C3.
2. $ERD/ERS_{C3}[i] < ERD/ERS_{C4}[i]$, ou seja, o canal C3 teve uma dessincronização maior que o canal C4.
3. A condição “2” deve ocorrer em três pontos consecutivos durante a fase de IM do teste. Segundo Pfurtscheller [100] [117] [256] [257] [260] e Neuper [259] a ERD dura em média 2 s na onda α , que equivalem a três pontos no sistema.

Para IM ME basta inverter a ordem dos sinais.

Para retornar ao operador do sistema que a IM foi reconhecida, durante a fase de teste, utiliza-se um *feedback* visual. O módulo de classificação “DECISOR” (Fig. 3.6) envia o sinal binário com o resultado para os canais de comunicação. O módulo de vídeo receberá o sinal e exibirá na tela o símbolo “●”, passando a informação de reconhecimento.

3.7 CONSIDERAÇÕES FINAIS

Este Capítulo apresentou a metodologia de construção do sistema de aquisição de sinais e processamento digital para reconhecimento de IM das mãos. Os canais C3 e C4 do EEG são adquiridos, amplificados, filtrados, convertidos e encaminhados para o circuito digital em FPGA. Nele são executadas de forma paralela para cada canal as *wavelets* Daubechies-4, que decompõem o sinal de EEG em seus ritmos constituintes α , β , θ e δ . Em seguida, é realizado o cálculo da energia da onda α , e enviados para o módulo de decisão (classificação), que calcula a ERD/ERS de cada canal e a diferença entre eles, para decidir se houve IM das mãos, e qual mão foi imaginada.

Um protótipo foi construído para validação dos circuitos e algoritmos projetados. Os resultados obtidos a partir de base de banco de dados são apresentados no Capítulo 4. São disponibilizados três canais de comunicação para análise dos resultados: um canal serial RS-232 para comunicação com um PC; um transmissor *wireless* e uma saída de vídeo VGA.

A infraestrutura utilizada para montagem dos circuitos e confecção das placas foi a do Laboratório de Interface Homem-Máquina – Lihom, sala 412 do CTG – UFPE. Este laboratório dispõem de placas de desenvolvimento em FPGA DE0, materiais para confecção de placas para os protótipos e equipamentos de medição como osciloscópios digitais, multímetros de bancada, geradores de função e fontes reguladas estabilizadas.

O projeto teve um cronograma de quatro anos, iniciando em 2013 e finalizando em out. 2017.

4 RESULTADOS

Os resultados obtidos com plataforma proposta são apresentados neste Capítulo. Na Seção 4.1 quatro sinais de EEG diferentes provenientes de base de dados foram gravados no FPGA e a execução do algoritmo da *wavelet* Daubechies-4 em *hardware* foi comparada com a realizada pelo *software* Matlab sobre os mesmos sinais de teste. O sinal processado do FPGA foi enviado ao PC via canal serial RS-232. Ainda nesta seção, utilizou-se a placa de aquisição para amostrar um sinal de EEG real de um voluntário, medido no canal O2. Diferente dos sinais de teste que estavam gravados no FPGA, este sinal do voluntário foi processado em tempo real e os resultados enviados via serial para comparação. São calculados os erros absolutos e relativos para todas as ondas analisadas via *wavelets*. Os resultados são apresentados na Seção 4.2.

Um segundo conjunto de sinais de base de dados foi gravado no FPGA calcular a energia da onda α e para testes de reconhecimento de IM. Os resultados deste teste e de outro com sinais reais estão nas seções 4.4 e 4.5 respectivamente.

4.1 SINAIS DE EEG DE BASE DE DADOS E SINAIS REIAS PARA TESTE DO ALGORITMO DA WAVELET

A avaliação do algoritmo implantado no FPGA, para executar a decomposição do sinal de EEG em *wavelets*, ocorre de forma comparativa com resultados conhecidos. Neste trabalho, comparou-se o resultado produzido pelo FPGA com a decomposição Daubechies-4 realizada pelo *software* Matlab.

Foram comparados duas amostras de 5s do canal C3 de dois indivíduos da base de dados BNCI Horizon 2020 [268], chamados “A” e “C”, totalizando quatro sinais. Foram comparados os coeficientes de aproximação e detalhes da decomposição em *wavelets* Daubechies-4 para os níveis de 1 a 5 utilizando a função “`dwt()`” do Matlab.

Esses sinais foram salvos no FPGA em uma memória ROM. Um módulo foi descrito em Verilog (Seção 2.6) para ler a ROM e disponibilizar os dados para o módulo “PROC_DIGITAL”, realizando a função do módulo “SPI_ADC”. Portanto, estes sinais serão processados normalmente pelo algoritmo, pois representam sinais que seriam digitalizados pelo ADC externo ao FPGA. Os sinais de testes estão representados na Figura 4.1.

Os resultados da decomposição em *wavelets* são apresentado nas Figs. 4.2 e 4.3, para a amostra 1 dos indivíduos A e C respectivamente.

No Apêndice são exibidos mais gráficos da decomposição da amostra 2 dos indivíduos do banco de dados. Também são apresentados em forma de tabela os resultados numéricos dos cálculos realizados pelo Matlab e FPGA, para comparação.

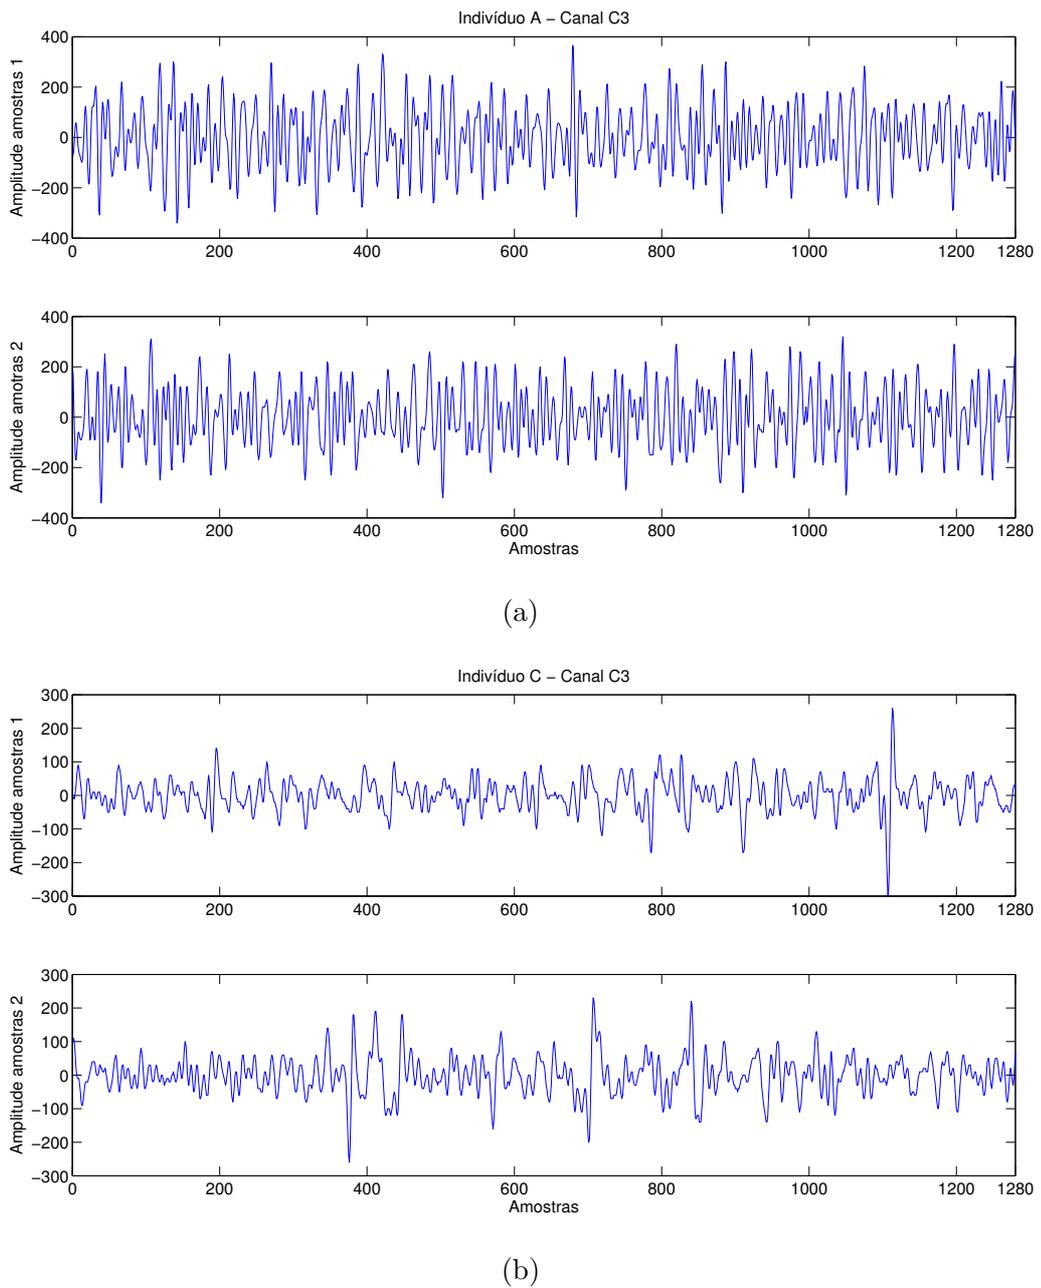
Comparação com sinal de EEG real

O passo seguinte foi testar o algoritmo executado pelo FPGA com um sinal real de EEG adquirido pela placa analógica. Um voluntário (próprio autor) realizou um simples movimento de abrir e fechar os olhos enquanto o canal O2 era adquirido. Neste canal percebe-se claramente as ondas alfa e beta com os olhos fechados e abertos, respectivamente. O protocolo foi: 2s com olhos abertos seguido de 3s com olhos fechados; tempo de amostragem 5,12s e taxa de 250sps (Fig. 4.4).

Na Fig. 4.5 são apresentados os gráficos dos coeficientes A1 até D5 da decomposição *wavelets* em FPGA do sinal adquirido na Fig. 4.4.

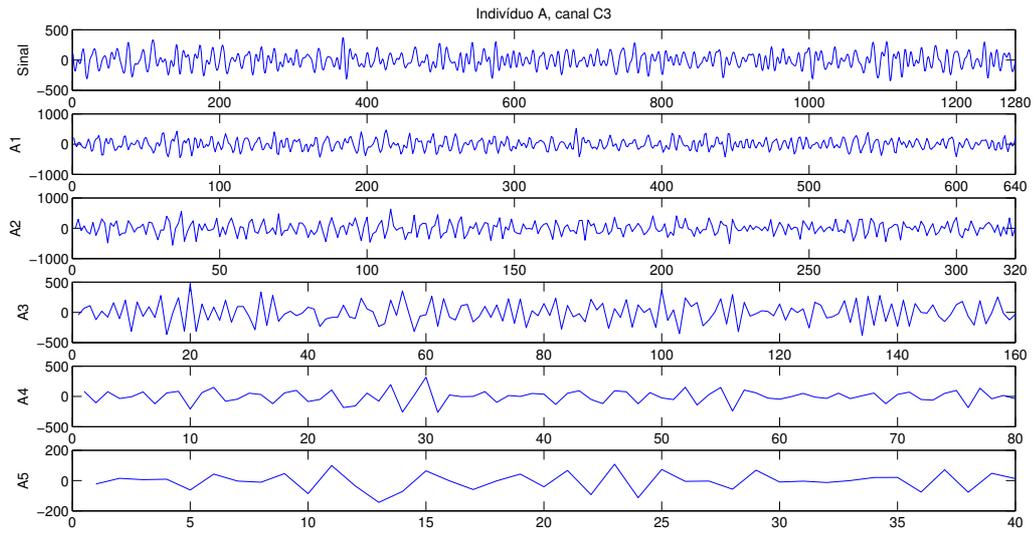
O Apêndice exibe em forma de tabela os resultados numéricos dos cálculos realizados pelo Matlab e FPGA, para comparação.

Figura 4.1 – Amostras dos sinais de teste obtidos de base de dados de EEG gravados no FPGA. (a) Indivíduo “A”, canal C3, amostras 1 e 2; (b) Indivíduo “C”, canal C3, amostras 1 e 2.

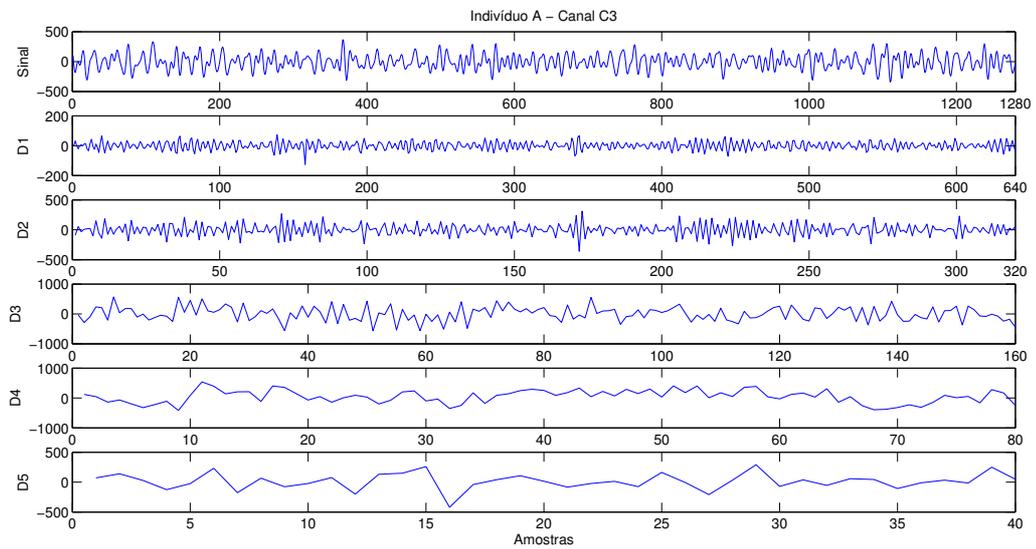


Fonte: autor.

Figura 4.2 – Exemplo de decomposição em *wavelets* do sinal de EEG da Fig. 4.1a (Canal C3 do indivíduo A do banco de dados). (a) coeficientes de aproximação e (b) coeficientes de detalhe. O sinal de EEG bruto está no primeiro gráfico de cada figura.



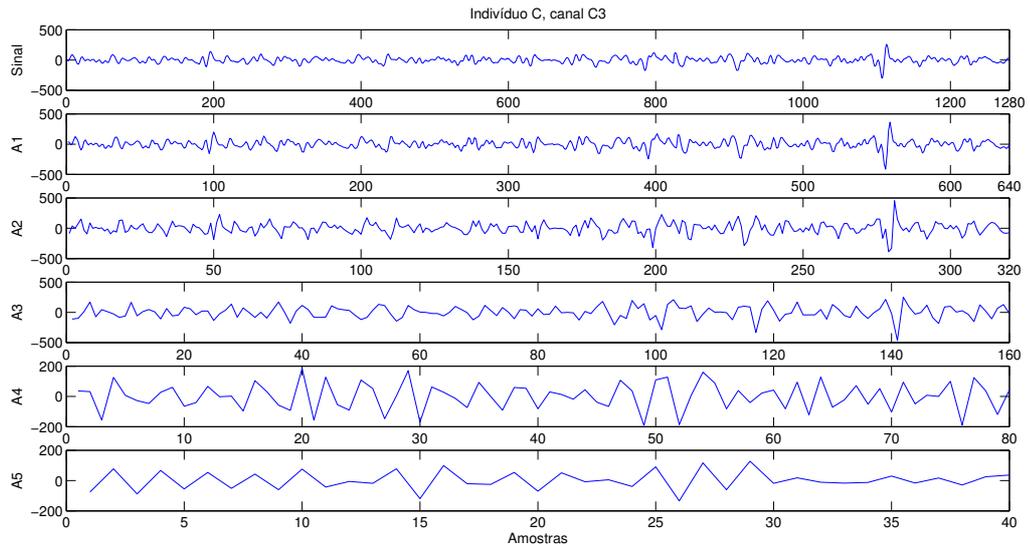
(a)



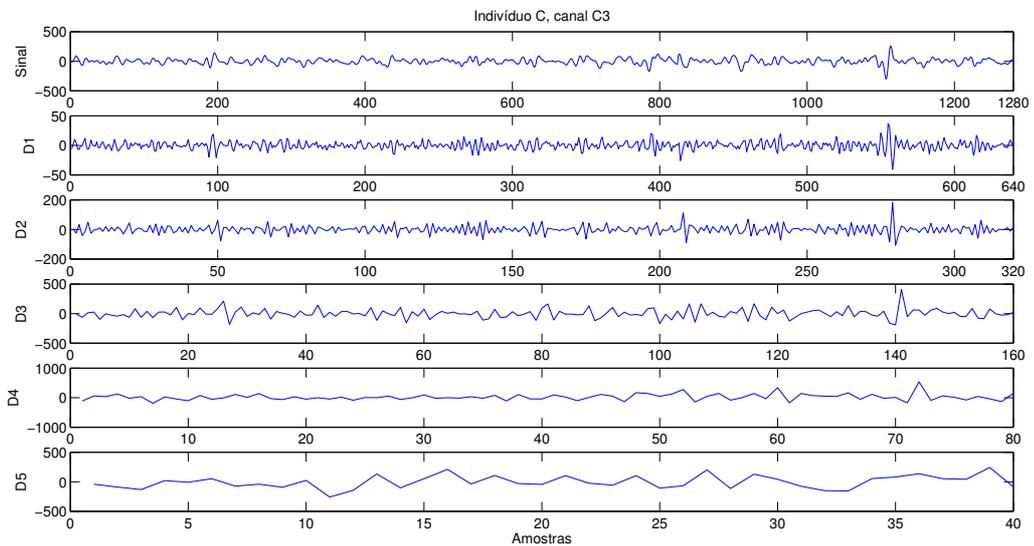
(b)

Fonte: autor.

Figura 4.3 – Exemplo de decomposição em *wavelets* do sinal de EEG da Fig. 4.1b (Canal C3 do indivíduo C do banco de dados). (a) coeficientes de aproximação e (b) coeficientes de detalhe. O sinal de EEG bruto está no primeiro gráfico de cada figura.



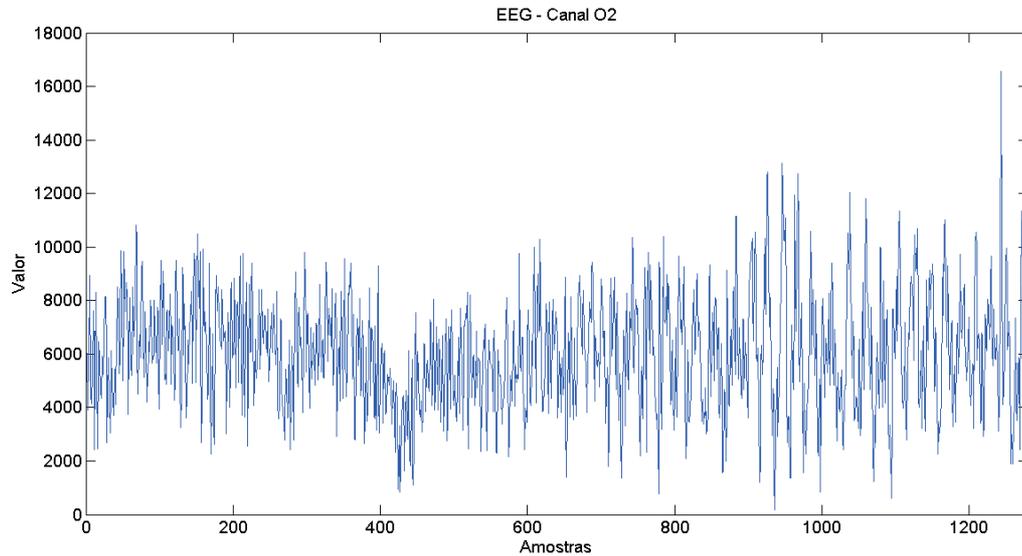
(a)



(b)

Fonte: autor.

Figura 4.4 – Exemplo de sinal de EEG (canal O2, sobre o córtex visual) obtido de um voluntário usando a placa de aquisição desenvolvida neste trabalho, amostrado a 250 sps. Neste gráfico, tem-se um protocolo de 3 s com olhos abertos seguido de 2 s com olhos fechados. Observa-se a diminuição perceptível na frequência e amplitude do sinal quando o voluntário fica de olhos fechados, ilustrando o aumento de amplitude da onda α .



Fonte: autor.

4.2 CÁLCULOS DE ERRO E CORRELAÇÃO DOS COEFICIENTES DA WAVELET

Cada sinal processado pelo FPGA, juntamente com os coeficientes da decomposição em *wavelet*, foi enviado via comunicação serial para um PC. Neste utilizou-se a função “`dwt()`” do Matlab para realizar a decomposição do sinal recebido, e seus coeficientes foram comparados com os do FPGA.

Foram comparados o erro absoluto e o erro relativo, e calculado o coeficiente de correlação. Antes dos cálculos três repetições de processamento foram realizadas com os quatro sinais gravados na FPGA, para avaliar a repetibilidade do algoritmo. Todas as repetições apresentaram os mesmos resultados, garantindo uma repetibilidade de 100% para as amostras.

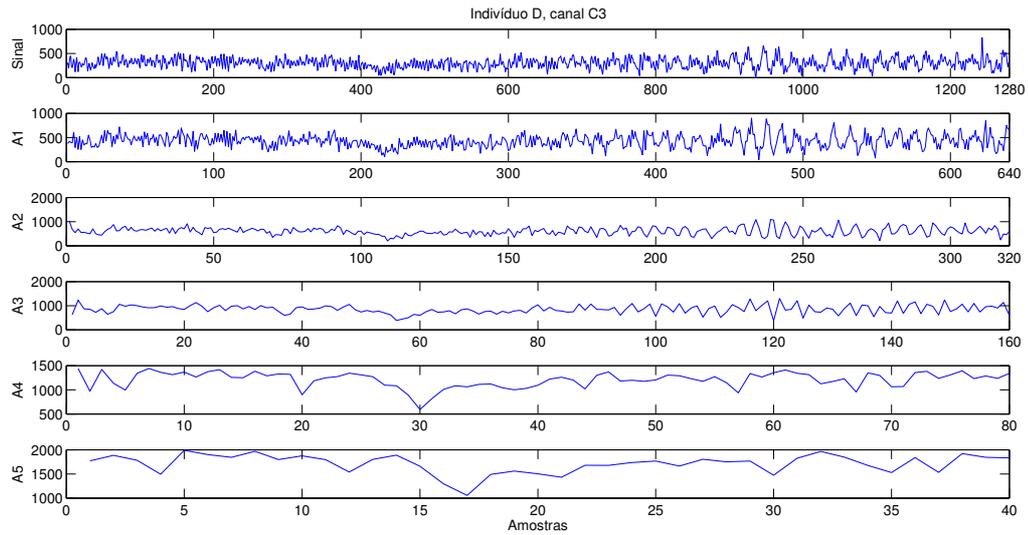
O erro absoluto $\Delta A1$ e o erro relativo ε entre os coeficientes processados pelo FPGA e pelo Matlab foram calculados utilizando as expressões (4.1) e (4.2) respectivamente [269].

$$\Delta A1 = A1[i] - cA1[i], \quad (4.1)$$

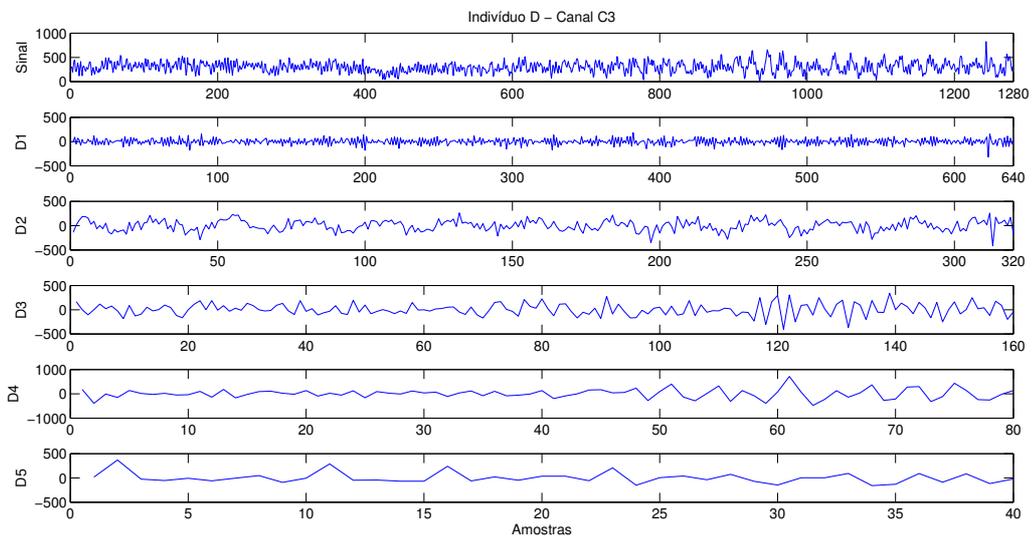
$$\varepsilon = \frac{A1[i] - cA1[i]}{cA1[i]} \cdot 100\%. \quad (4.2)$$

Em (4.1) e (4.2) $A1[i]$ representa o coeficiente A1 calculado pelo FPGA e $cA1[i]$ o calculado

Figura 4.5 – Exemplo de decomposição em *wavelets* do sinal de EEG bruto da Fig.4.4. (a) coeficientes de aproximação e (b) coeficientes de detalhe. O sinal de EEG original está no primeiro gráfico de cada figura.



(a)



(b)

Fonte: autor.

pelo Matlab para a amostra i . Os coeficientes do Matlab foram arredondados para o inteiro mais próximo e considerou-se como o valor verdadeiro esperado. Foram considerados números inteiros pois a linguagem Verilog não sintetiza em *hardware* números em ponto flutuante (reais).

Os erros absolutos foram listados ponto a ponto no Apêndice , para as ondas de interesse β , α , θ e δ . Analisando as Tabelas .1 até .5 nota-se que o maior erro absoluto em todos os coeficientes foi 1. Para se ter uma ideia desse resultado o valor máximo das amostras varia de -32768 a 32768 (resolução de 2^{15} mais 1 *bit* de sinal em complemento de dois). O cálculo do erro relativo em (4.2) leva a interpretações errôneas, pois a média dos coeficientes de detalhes de D1 a D5 é zero e fatalmente o denominador terá este valor, levando o resultado a um erro infinito. Portanto, esta métrica não foi computada.

Foram calculadas as médias e o desvio padrão a partir dos erros absolutos de cada coeficiente. O desvio padrão do erro absoluto s_{erro} foi calculado da seguinte forma [270]:

$$s_{erro} = \sqrt{\frac{1}{n-1} \sum_{k=1}^n (x_{erro}[k] - \bar{x}_{erro})^2}, \quad (4.3)$$

em que n é a quantidade de coeficientes, $x_{erro}[k]$ é o erro de cada coeficiente k e \bar{x}_{erro} a média do erro absoluto.

Outro parâmetro calculado foi o coeficiente de correlação r [270] entre os coeficientes do algoritmo do FPGA e do Matlab. Para cada nível M de decomposição, foi calculada a correlação $r[M]$ conforme (4.4):

$$r[M] = \frac{\sum_{k=1}^n (x_k - \bar{x})(y_k - \bar{y})}{\sqrt{\sum_{k=1}^n (x_k - \bar{x})^2 \sum_{k=1}^n (y_k - \bar{y})^2}}, \quad M = 1, \dots, 5. \quad (4.4)$$

Em (4.4) as variáveis x_k são os coeficientes do FPGA, \bar{x} a média, y_k são os coeficientes calculados pelo Matlab e \bar{y} a média.

As Tabelas 4.1 e 4.2 trazem o resumo dos parâmetros calculados a partir dos erros absolutos dos coeficientes do algoritmo executado em FPGA em relação ao Matlab.

O Apêndice inclui as tabelas que comparam, ponto a ponto, o resultado do processamento para as ondas de interesse β , α , θ e δ , representadas pelos coeficientes D3, D4, D5 e A5 respectivamente.

4.3 CORRELAÇÃO ENTRE A ENERGIA CALCULADA PELO FPGA E O MATLAB

De forma similar à realizada com os coeficientes da *wavelet*, foram calculadas no Matlab as energias da onda α de cada canal a partir dos coeficientes D4_C3 e D4_C4, que representa as ondas α de C3 e C4 respectivamente, recebidos via serial. O objetivo é comparar os cálculos e confirmar que a execução no FPGA está coerente.

Para os sinais de banco de dados processados pelo FPGA do indivíduo 1, foram executados os seguintes comandos no Matlab:

Tabela 4.1 – Comparativo dos erros absolutos dos coeficientes do algoritmo em relação aos coeficientes do Matlab. São calculados a média do erro \bar{x}_{erro} , o desvio padrão do erro s_{erro} e a correlação r entre os coeficientes, para os indivíduos “A” e “C”, amostras 1 e 2.

Coeficiente	Indivíduo A-1			Indivíduo A-2		
	\bar{x}_{erro}	s_{erro}	r	\bar{x}_{erro}	s_{erro}	r
A1	0,0016	0,6130	1,0000	-0,0220	0,6536	1,0000
A2	0,0095	0,5708	1,0000	0,0284	0,6181	1,0000
A3	0,0127	0,6979	1,0000	0,0064	0,6862	1,0000
A4	0,0395	0,7383	1,0000	-0,0921	0,6962	1,0000
A5	0,0556	0,6299	1,0000	-0,1944	0,6684	1,0000
D1	-0,0141	0,7428	0,9997	-0,0047	0,7192	0,9997
D2	-0,0347	0,7685	1,0000	-0,0315	0,7328	1,0000
D3	-0,0446	0,7280	1,0000	0,0064	0,7139	1,0000
D4	-0,2105	0,6989	1,0000	-0,0395	0,6820	1,0000
D5	-0,0556	0,6299	1,0000	0,0556	0,7149	1,0000

Coeficiente	Indivíduo C-1			Indivíduo C-2		
	\bar{x}_{erro}	s_{erro}	r	\bar{x}_{erro}	s_{erro}	r
A1	-0,0235	0,6830	1,0000	0,0377	0,6432	1,0000
A2	-0,0032	0,6820	1,0000	-0,0063	0,6512	1,0000
A3	0,0191	0,7203	1,0000	0,0513	0,6796	1,0000
A4	-0,2368	0,7093	1,0000	-0,0395	0,7013	1,0000
A5	0,0000	0,6761	1,0000	-0,0556	0,5828	1,0000
D1	0,0031	0,6776	0,9972	-0,0078	0,6856	0,9974
D2	-0,0284	0,7264	0,9998	-0,0315	0,7197	0,9998
D3	0,0318	0,6833	1,0000	-0,0641	0,7245	1,0000
D4	0,0658	0,7364	1,0000	-0,1842	0,7250	1,0000
D5	0,0833	0,7700	1,0000	0,0833	0,6036	1,0000

Fonte: autor.

```
% salva na variável 'eaC3' os coef D4_C3 ao quadrado
```

```
eaC3 = D4_C3_bd .^ 2;
```

```
% passa o vetor por um filtro de média móvel de tamanho 8
```

```
eaC3 = movmean( eaC3, 8 );
```

```
% arredonda os resultados
```

```
eaC3 = round( eaC3 );
```

```
% alinha os vetores 'energia_C3' recebido via serial e a variável 'eaC3'
```

```
% calculada pelo Matlab.
```

```
% Calcula o coef de correlação entre os dois vetores
```

Tabela 4.2 – Comparativo dos erros absolutos dos coeficientes do algoritmo em relação aos coeficientes do Matlab. São calculados a média do erro \bar{x}_{erro} , o desvio padrão do erro s_{erro} e a correlação r entre os coeficientes, para o indivíduo “D”, amostra obtida em tempo real.

Coeficiente	Indivíduo D		
	\bar{x}_{erro}	s_{erro}	r
A1	-0,2433	0,4294	1,0000
A2	-0,5110	0,5007	1,0000
A3	-0,5541	0,4987	1,0000
A4	-0,6364	0,4842	1,0000
A5	-0,4324	0,5022	1,0000
D1	0,2496	0,6311	1,0000
D2	0,5994	0,5957	1,0000
D3	-0,0573	0,6626	1,0000
D4	0,0519	0,7236	1,0000
D5	0,0541	0,7050	1,0000

Fonte: autor.

```
ans = corrcoef( energia_C3(8:15680), eaC3(5:15677) );
ans =
1.0000    0.9997
0.9997    1.0000
```

Repetiu-se o processo para os sinais reais adquiridos pela plataforma em um voluntário:

```
% salva na variável 'eaC3' os coef D4_C3 ao quadrado
eaC3_vol = D4_C3_vol .^ 2;

% passa o vetor por um filtro de média móvelde tamanho 8
eaC3_vol = movmean( eaC3_vol, 8 );

% arredonda os resultados
eaC3_vol = round( eaC3_vol );

% alinha os vetores 'energia_C3' recebido via serial e a variável 'eaC3'
% calcula pelo Matlab.
% Calcula o coef de correlação entre os dois vetores
ans = corrcoef( energia_C3(8:4900), eaC3_vol(5:4897) );
ans =
1.0000    0.9996
```

0.9996 1.0000

Como se observa nas variáveis “ans”, o coeficiente de correlação entre as variáveis de energia calculadas pelo FPGA, a partir do banco de dados, e a variável do Matlab foi 0,9997. Para os sinais adquiridos pela plataforma obteve-se um coeficiente de 0,9996. A diferença entre os dois vetores de energia é que o do banco de dados é maior, por ser um teste mais longo (aproximadamente 16 min) que o teste do voluntário (5 min). Estes resultados sinalizam que os cálculos do FPGA estão de acordo com o Matlab.

4.4 RECONHECIMENTO DE IM DAS MÃOS A PARTIR DE SINAIS DA BASE DE DADOS

Descrição da base de dados

Uma base de dados com três indivíduos foi escolhida para teste do algoritmo de reconhecimento de IM. A base de dados está disponível em [271] e foi referenciada nos trabalhos de Leeb [255]. Trata-se de um protocolo com duas classes de IM chamadas “mão esquerda” e “mão direita”. Os indivíduos realizaram duas seções, sendo uma de treinamento sem *feedback*, para extrair as características do EEG, e a segunda com *feedback* visual para testar o sistema sugerido por Leeb.

Segundo a descrição do banco de dados em [272], os voluntários foram instruídos para sentar em uma cadeira com encosto e olhar para um monitor colocado aproximadamente 1 m de distância, na altura dos olhos. O protocolo de treinamento se resume a 3 s com um sinal de fixação do olhar (“+”) exibido no monitor de vídeo. Uma dica, uma seta para a direita ou esquerda, é exibida no monitor indicando qual das mãos deve ser imaginada por 1,25 s. Em seguida, vem o tempo de 3 s para IM, sendo exibida na tela apenas o sinal de fixação do olhar. Ao final a tela fica em branco para descanso do voluntário por 2 s. Esta sequência se repete por dez vezes, e cada ciclo completo é repetido seis vezes. Depois houve um momento de descanso e uma nova seção é iniciada. No final, cada indivíduo gera 120 repetições de IM em uma seção. No banco de dados estão registrados os sinais de duas seções para cada voluntário, totalizando 240 repetições de IM. Ainda no banco de dados, é registrada a direção da seta solicitada para cada repetição, para comparar os resultados do que foi solicitado com o que foi executado.

O protocolo de teste (*trial*) com *feedback* visual é composto de 3 s com um sinal de fixação do olhar. Em seguida, uma dica é exibida na tela por 4,5 s indicando a direção da IM solicitada ao voluntário. Se a IM coincidir com a dica aparece na tela uma “carinha feliz” (☺), caso contrário uma “carinha triste” (☹). No final há um tempo de 2 s com a tela em branco, para descanso. O processo se repete por dez vezes. Oito repetições desse protocolo foram realizados para cada voluntário em duas seções diferentes, resultando em

oitenta testes. Em um dia posterior foram tomadas mais duas seções. Ao final tem-se 160 testes com *feedback* para cada voluntário. A dica exibida foi gravada junto com os sinais de EEG para posterior comparação.

O banco de dados consta dos canais C3, Cz e C4 do sinal de EEG e mais três sinais de eletro-oculografia. Estes foram tomados dos voluntários durante as fases de treinamento e testes (*trials*), sendo amostrados a 250 Hz, e filtrados na faixa de 0,5 a 100 Hz.

Teste do sistema com os sinais da base de dados

Precisou-se de algumas adaptações para testar o sistema com os sinais armazenados na base de dados, como multiplicar e arredondar para o inteiro mais próximo, para se ter aproximadamente a mesma amplitude dos sinais adquiridos pela placa analógica da plataforma. Os sinais dos canais C3 e C4 da etapa de treinamento foram gravados no FPGA para decomposição e cálculo da energia das ondas α de cada canal. Os resultados foram enviados via serial para ser processados no Matlab. Os pontos da WPS calculada no FPGA foram então gravados em uma matriz para contabilizar a ERD/ERS.

No Matlab foi calculada a ERD/ERS (Seção 3.6) usando como referência a energia da onda α 1 s antes da dica para iniciar a IM. Um gráfico foi construído com o resultado da média das 120 tentativas, como exemplificado na Fig. 4.6.

Observa-se na Fig. 4.6a um evento de ERD para o canal C4 quando ocorre IM da mão esquerda, após 1,5 s da exibição da dica na tela (valor menor que 100% da energia de referência). A ERD foi maior no canal C3 em comparação com C4 durante IM da mão direita, conforme observado na Fig. 4.6b. Nota-se que o desvio padrão das amostras foi menor para o lado contralateral em cada mão, contrastando com um desvio maior no lado ipsilateral. A partir da diferença entre a energia média dos canais C3 e C4, observando se houve ERD/ERS e comparando com a dica salva no banco de dados, decidiu-se pelo valor de *threshold* para a etapa de teste (*trial*).

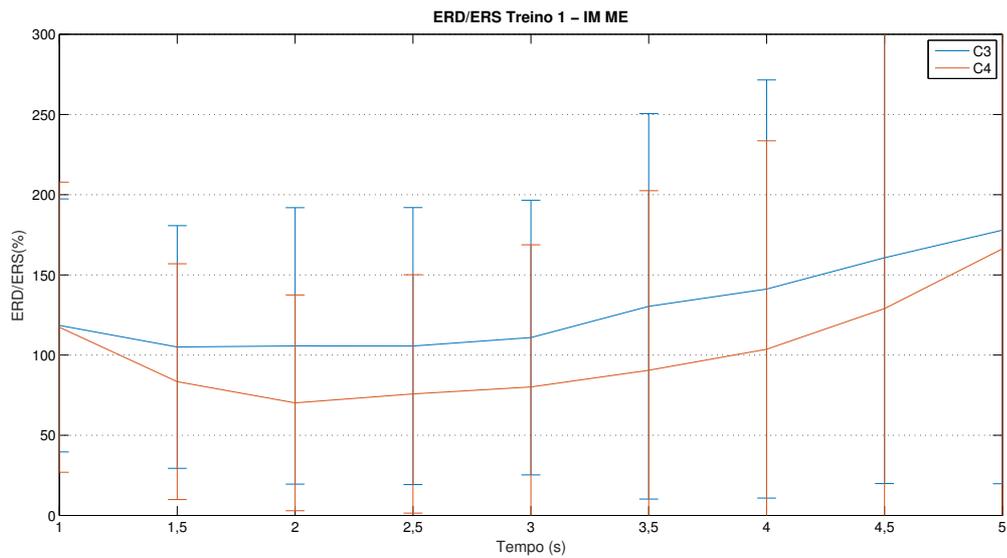
Em seguida, gravou-se na memória flash da placa DE0 os sinais C3 e C4 da etapa de teste de cada indivíduo. Foi programado o sistema para ler esta memória e realizar a teste de reconhecimento de IM. Para cada indivíduo, foram repetidas as mesmas 160 tentativas de IM gravadas no banco de dados, que dura aproximadamente 16 min. O sistema exibe um quadrado cinza no centro do monitor indicando o início da etapa de IM. Um círculo verde do lado direito ou esquerdo do monitor é apresentado de acordo com a IM da mão identificada, conforme representado na Fig. 4.7).

A Fig. 4.8 apresenta fotografias das telas do sistema durante a fase de teste (*trial*). Nota-se a mudança de um quadrado cinza no centro da tela para um círculo do lado direito ou esquerdo, indicado o reconhecimento de IM da mão direita ou esquerda, respectivamente.

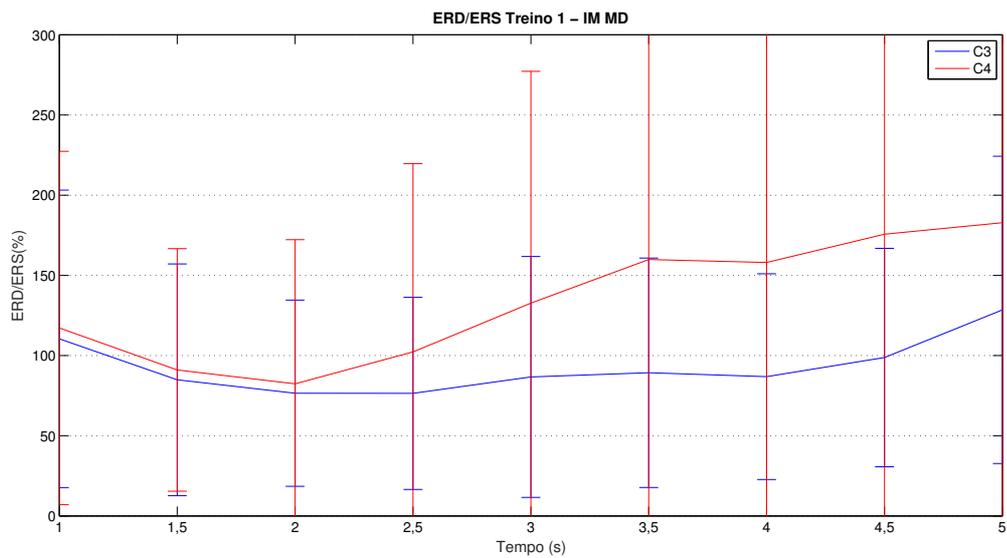
Para detalhar o resultado do reconhecimento de IM, foi separado um trecho de

Figura 4.6 – Exemplos de ERD/ERS obtido na etapa de treinamento para o indivíduo 1. Nota-se que em (4.6a) houve reconhecimento de IM da mão esquerda (ME), pois a ERD/ERS no canal C4 foi menor que o canal C3 durante três pontos consecutivos, conforme critérios de classificação descritos na Seção 3.6. Em (4.6b) houve reconhecimento de IM da mão direita (MD) pelos mesmos critérios.

(a)

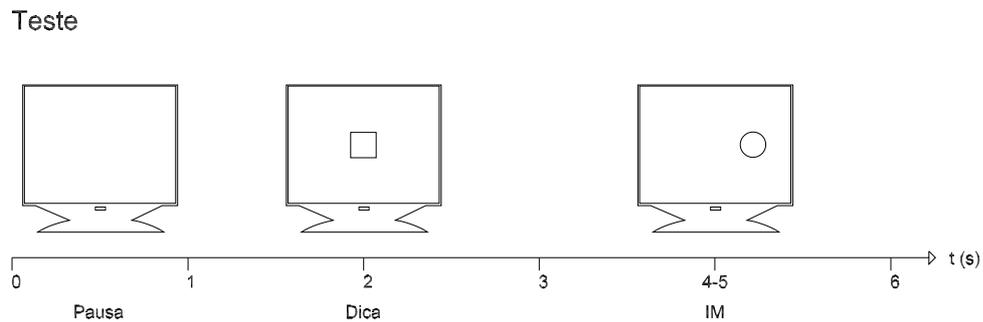


(b)



Fonte: autor.

Figura 4.7 – Tempos da etapa de teste para reconhecimento de IM.



Fonte: autor.

Figura 4.8 – Fotografia do monitor do sistema durante as fases do teste de reconhecimento de IM. A primeira sequência é para IM da mão direita e a segunda da mão esquerda. Caso não seja reconhecida a IM o quadrado não muda para um círculo.

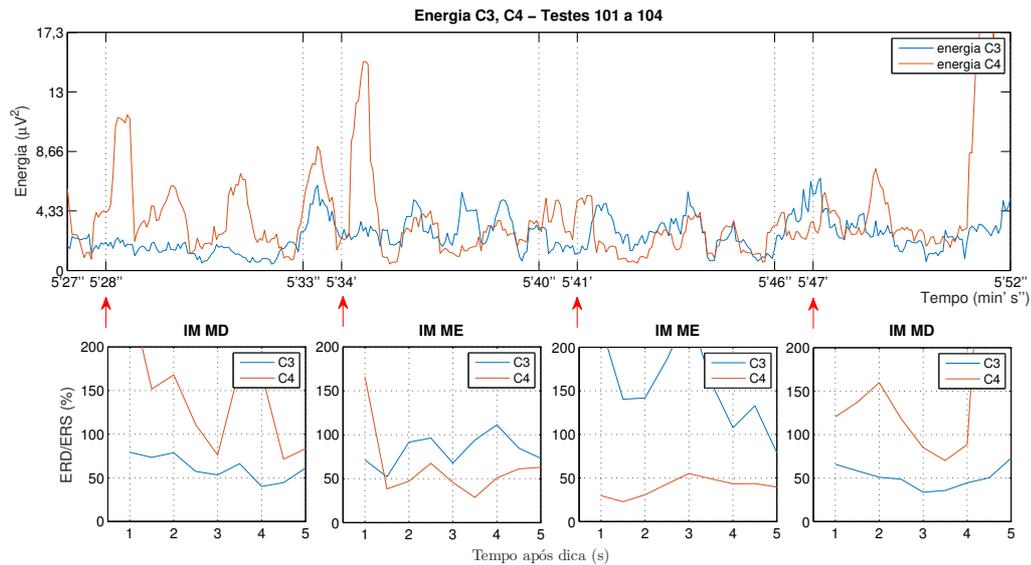


Fonte: autor.

energia de aproximadamente 25s, que representa os teste 101 a 104 do indivíduo 1 do banco de dados gravado no FPGA, apresentado na Fig. 4.9. As setas vermelhas indicam o momento que a dica é exibida para o usuário realizar a IM da mão indicada.

Os pormenores do reconhecimento do teste 101 do indivíduo 1 são exibidos na Fig. 4.10. Observa-se no gráfico superior da Figura a região chamada “Energia referência”, onde é calcula a energia de referência da onda α do EEG, conforme (3.10) e (3.11) da Seção 3.6. A partir do instante em que a “Dica” é exibida, inicia-se o cálculo de ERD/ERS da onda α , conforme (3.12) e (3.13) (gráfico inferior da Fig. 4.10). Caso os critérios para decidir se houve IM MD ou ME sejam atendidos, conforme a Seção 3.6, o monitor de

Figura 4.9 – Trecho de 25 s ilustrando quatro reconhecimentos de IM de mãos diferentes (testes 101 a 104), para os sinais do banco de dados gravados no FPGA. No gráfico superior, as setas vermelhas indicam o momento que a dica é exibida para o usuário. Nos gráficos inferiores, próximos às setas, são exibidos os pontos de ERD/ERS para cada canal C3 e C4. Foram reconhecidas as IM da mão direita (MD), mão esquerda (ME), ME e MD, nesta ordem.



Fonte: autor.

vídeo exibe o resultado correspondente do reconhecimento de IM (círculo verde à direita ou esquerda do monitor, respectivamente), conforme ilustrado na Fig. 4.8.

O sistema executado pelo FPGA obteve 100 % de resposta coincidentes com os cálculos realizados no Matlab para reconhecimento de IM, para os sinais de três indivíduos testados, que foram no total 480 tentativas.

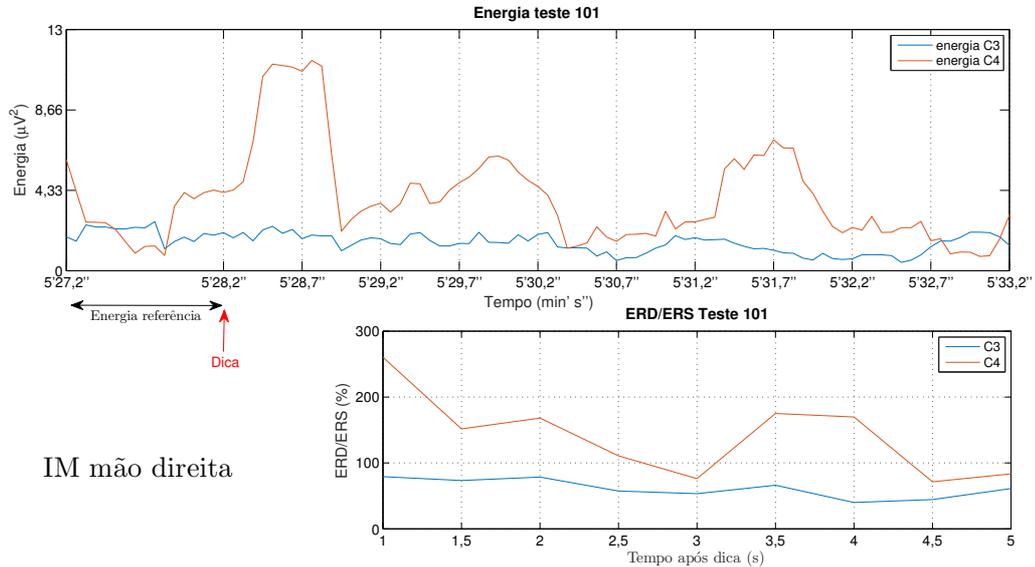
4.5 RECONHECIMENTO DE IM DAS MÃOS A PARTIR DE SINAIS DE EEG DE UM VOLUNTÁRIO

Um voluntário realizou as etapas de treinamento e teste na plataforma. Dois canais de EEG foram adquiridos C3 e C4 pela placa de aquisição desenvolvida. Estes sinais foram digitalizados, processados e o resultado exibido no monitor de vídeo. A Fig. 4.11 mostra o detalhe da conexão entre o voluntário e o sistema.

Na fase de treinamento foram realizadas 50 repetições, e foi obtida a curva de ERD/ERS da Fig. 4.12 para as 10 melhores, ou seja, as que obtiveram maior diferença de ERD/ERS entre os canais C3 e C4.

Na etapa de teste foram obtidos os seguintes resultados de reconhecimento de IM: para detalhar, foi separado um trecho de energia de aproximadamente 25 s, que representa

Figura 4.10 – Detalhe dos pontos do cálculo de ERD/ERS do teste 101 da Fig. 4.9. Observa-se que a escala das ordenadas do ERD/ERS (gráfico inferior) é maior nesta figura que na anterior.



IM mão direita

Fonte: autor.

o teste 3 até o teste 6 do voluntário, apresentado na Fig. 4.13.

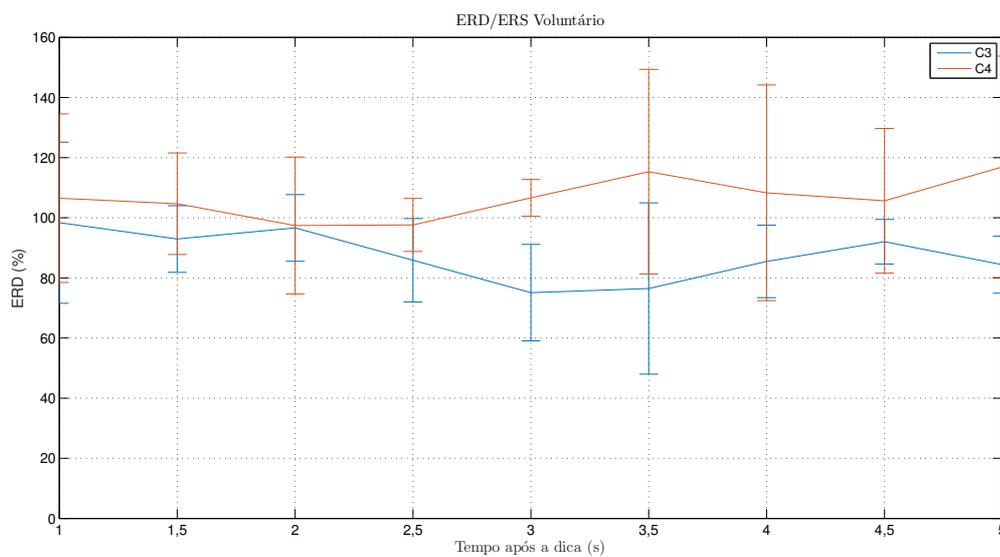
Percebe-se que as duas primeiras tentativas foram corretamente reconhecidas, enquanto que as duas últimas não atingiram valores mínimos de ERD/ERS para sensibilizar o sistema. Este resultado é previsto na literatura [255] [115] [117], pois escolhe-se os melhores voluntários destros para operar as BCI, que são aqueles que conseguem apresentar os maiores valores de ERD durante a fase de treinamento. O voluntário destes testes declarou se ambidestro. Existem teste específicos para estimar a laterização do uso dos membros, especialmente das mãos [273]. Outros voluntários não foram recrutados, pois exigiria tempo e não faz parte dos objetivos desta tese abordar a quantidade de acertos no reconhecimento de IM. Os pormenores do reconhecimento do teste 4 do voluntário são exibidos na Fig. 4.14, que seguem o mesmo procedimento descrito para a análise do sinal de EEG da base de dados da Seção 4.4 e Fig. 4.10.

Figura 4.11 – Fotografia mostrando o detalhe da conexão entre a plataforma e o voluntário. No centro à esquerda é mostrada a placa de aquisição de EEG juntamente com a placa de desenvolvimento em FPGA. No canto superior esquerdo ve-se o monitor de vídeo, que fornece o *feedback* visual ao voluntário sobre o reconhecimento da IM das mãos. O *laptop* ao centro recebe os sinais processados pelo FPGA para posterior comparação com o algoritmo *offline* desenvolvido na Seção 3.4.



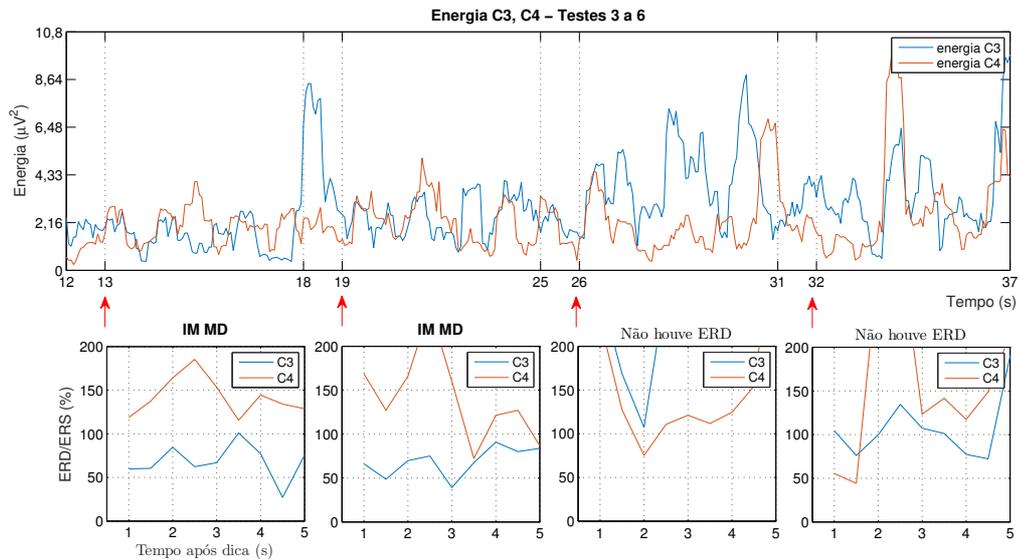
Fonte: autor.

Figura 4.12 – Média da ERD/ERS para as 10 melhores repetições realizadas pelo voluntário (as melhores são as que obtiveram maior diferença de ERD/ERS entre os canais C3 e C4).



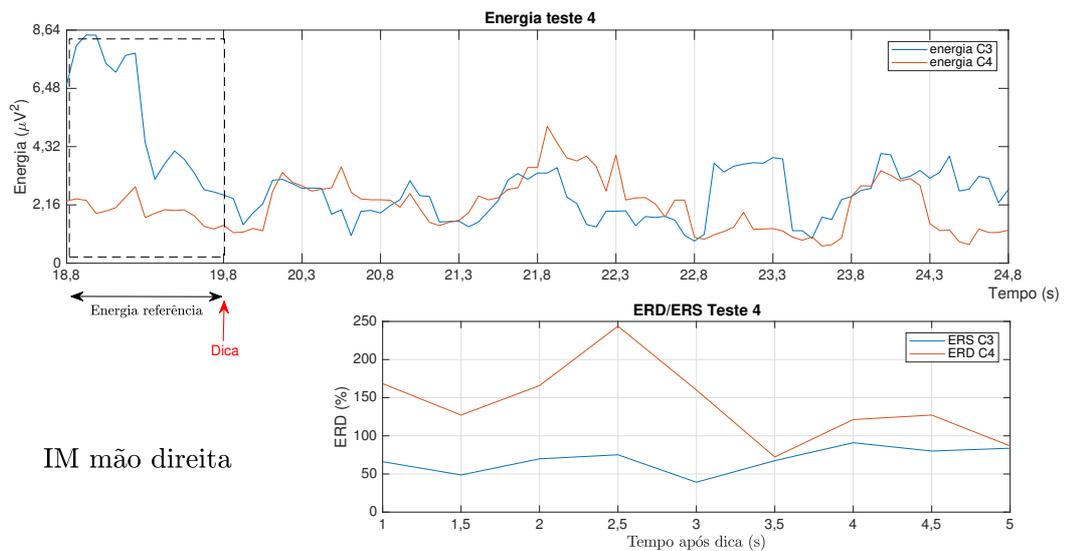
Fonte: autor.

Figura 4.13 – Trecho de 25 s apresentando quatro resultados de IM do voluntário. No gráfico superior, as setas vermelhas indicam o momento da apresentação da dica para o usuário da BCI realizar a IM. Nos gráficos inferiores, próximos às setas, são exibidos os pontos de ERD/ERS para cada canal C3 e C4. Foram reconhecidas as IM da mão direita (MD), MD, não reconhecido duas vezes, nesta ordem.



Fonte: autor.

Figura 4.14 – Detalhe dos pontos do cálculo de ERD do teste 4 da Fig. 4.13.



Fonte: autor.

4.6 VELOCIDADE DE PROCESSAMENTO E QUANTIDADE DE RECURSOS CONSUMIDOS PELO FPGA

Os tempos de processamento dos coeficientes A1 até D5 foram comparados para confirmar os tempo esperados apresentados na Tabela 3.6 da Seção 3.4. Completa-se apresentando na Tabela 4.3 a seguir os tempos de cálculos dos 10 coeficientes. Pelo fato do processamento de cada coeficiente ser em paralelo, o tempo máximo para o cálculo é determinado pelos níveis que exigem as maiores interações, que são A5 e D5, exigindo 94 interações conforme a Tabela 3.5 e (3.6), levando 128 ms para serem atualizados.

Tabela 4.3 – Tempos de processamento do sistema para cálculo da *wavelet* Daubechies-4.

Operação	Tempo (ms)
Amostragem dos canais C3 e C4	4
Atualização dos coeficientes A1, D1	8
Atualização dos coeficientes A2, D2	16
Atualização dos coeficientes A3, D3	32
Atualização dos coeficientes A4, D4	64
Atualização dos coeficientes A5, D5	128

Fonte: autor.

A Tabela 4.4 mostra o resumo dos recursos consumidos do FPGA escolhido para o projeto. Foram utilizados 14.545 para construir o sistema digital dos 15.408 elementos lógicos disponíveis, excluindo o ADC que é externo ao FPGA. Para processar oito coeficientes (D3, D4, D5 e A5 para cada canal), calcular a ERD/ERS e tomar decisão se houve IM, foram empregados 46 multiplicadores dos 112 incorporados no FPGA. Um PLL embutido foi utilizado para o módulo de vídeo, para gerar o relógio de 108 MHz a partir do principal de 50 MHz, exigido pela resolução de 1280 colunas por 1024 linhas. O *software* utilizado foi o Quartus II versão 9.0 *Web Edition*. O consumo máximo de energia do sistema é de 6 W, incluindo o canal de comunicação *Bluetooth*. Esse valor pode ser reduzido, pois existem no mercado outras placas de desenvolvimento FPGA com apenas os circuitos de gravação e I/O. A placa onde foi construída a plataforma proposta possui diversos circuitos periféricos que consomem energia e que não estão sendo usados.

4.7 CONSIDERAÇÕES FINAIS

Neste Capítulo foram apresentados os dados da decomposição *wavelets* realizados sobre cinco sinais para testar o algoritmo proposto. Os resultados são coerentes com os executados pelo Matlab. Desta forma fica demonstrado que o algoritmo é válido e pode ser utilizado para a análise via *wavelet* Daubechies-4.

Tabela 4.4 – Recursos consumidos do FPGA EP3C16F484C6 para construir o sistema digital.

Item	Consumo
Elementos lógicos	14.545 / 15.408 (94 %)
Funções combinacionais	13.699 / 15.408 (89 %)
Registradores dedicados	4.569 / 15.408 (30 %)
Pinos	82 / 347 (24 %)
<i>Bits</i> de memória	49.664 / 516,096 (10 %)
Multiplicadores 9 <i>bits</i> integrados	46 / 112 (41 %)
PLL	1 / 4 (25 %)

Fonte: autor.

Adicionalmente foram testados os algoritmos de cálculo da ERD/ERS e decisão sobre IM das mãos. Os resultados concordam 100% com o algoritmo executado pelo *software* computacional Matlab. Os resultados da técnica aplicada em sinais gravados de banco de dados de três indivíduos na memória flash da placa DE0 e para um voluntário que utilizou diretamente a plataforma proposta mostram que o sistema pode reconhecer IM após treinamento adequado e configuração dos valores de *threshold*.

5 CONCLUSÃO

As BCIs têm sido tema de estudo de diversos grupos de pesquisa e empresas pelo mundo. Investimentos milionários tem sido destinados para esta área, que envolve a neurociência, física, matemática e engenharia em suas diversas especialidades.

A revisão bibliográfica apresentada no Capítulo 2 mostrou que a maior parte das BCI pesquisadas são aplicadas em estudos *offline*. Um percentual de 7,8 %, que representa quatro entre 51 artigos de interesse em nosso universo pesquisa, são voltados para sistemas em tempo real (*online*). Além do pequeno percentual ainda foi mostrado que eles são sistemas baseados em PCs e *softwares* voltados para essa arquitetura de *hardware*, que não permite a mobilidade e portabilidade do operador, além de consumir mais energia que uma abordagem dedicada.

O trabalho apresentou uma abordagem alternativa de uma BCI *online*, construída em *hardware* reconfigurável e dedicado para este fim. Esta BCI realiza a aquisição e condicionamento do sinal de EEG, conversão analógico-digital, processamento digital para extrair a característica de energia da onda alfa e classificação de padrões para decidir se houve IM das mãos, e qual delas foi imaginada. O resultado dessa decisão é exibido na forma de um *feedback* visual para o usuário da BCI. Desta forma, os objetivos relacionados na Introdução foram cumpridos.

As implicações deste trabalho são permitir a construção de sistemas de reabilitação neuro-motora portáteis e de baixo custo, uma necessidade real conforme apresentado no Capítulo 1; permitir que amputados possam operar próteses via EEG e IM; treinar operadores para manipular dispositivos eletromecânicos, como braços robóticos, por exemplo,

para aplicações severas e nocivas para o ser humano, em ambientes industriais ou militares; ambientes virtuais e dispositivos interativos para entretenimento.

Em resumo, as principais contribuições deste trabalho são:

1. Desenvolvimento de uma plataforma embarcada de aquisição de EEG e reconhecimento de IM das mãos em tempo real, com canais de comunicação e independente de um PC.
2. Construção de uma ULA (nomeada *Wave Engine*) específica em FPGA para calcular os coeficientes da *wavelet* Daubechies-4, aplicada no processamento de sinais de EEG em tempo real.
3. Algoritmo dedicado em HDL para calcular os coeficientes *wavelets* de níveis maiores sem a necessidade de se computar os níveis anteriores. A simples conversão de um código em Matlab para HDL não é possível diretamente, pois as funções não são sintetizadas em *hardware* pela ferramenta do FPGA.
4. Circuito exclusivo em FPGA para cálculo de ERD/ERS a partir da energia da onda α de cada canal de EEG, representada pela decomposição de nível quatro da WDT e determinação da WPS e TAWPS.

5.1 TRABALHOS FUTUROS

A contribuição abordada neste trabalho é apresentar a viabilidade da plataforma de reconhecimento da IM das mãos em tempo real construída no FPGA, possuindo circuitos paralelos de processamento de sinais e canais de comunicação, para futuro desenvolvimento de BCIs *online*. Em trabalhos futuros, as mesmas técnicas ou outras mais adequadas para a abordagem paralela serão estudadas e apresentadas posteriormente utilizando a plataforma desenvolvida.

Uma limitação da plataforma proposta é basear-se somente na onda α para o algoritmo de reconhecimento de IM (cálculo de ERD/ERS). Um nível de acerto maior é conseguido quando se considera a onda β nos cálculos, conforme demonstrado por Pfurtscheller et al. em [115] e [117]. Assim será possível usar classificadores mais poderosos, com maior taxa de acerto que o *threshold* utilizado. São sugeridos os seguintes trabalhos, para sanar as limitações e dar continuidade às pesquisas aplicando a plataforma proposta para reconhecimento de IM baseado em EEG:

1. Implantar um classificador mais robusto em *hardware* para aumentar a taxa de acertos.
2. Aplicar diferentes técnicas de reconhecimento de padrões para avaliar as que possuem maior taxa de acerto para a plataforma proposta.

3. Incluir as ondas β na lógica de decisão, conforme abordagem de Pfurtscheller et al. em [115] [117], para avaliar o aumento do desempenho do sistema.
4. Realizar estudo comparativo entre voluntários para determinar a taxa média de acertos do sistema usando análise ROC (*Receiver Operating Characteristics*), baseado na proposta de Townsend [119].
5. Implantar como *feedback* um braço robótico com um grau de liberdade (sistema eletromecânico) para ser operado via EEG e IM.

REFERÊNCIAS

- [1] J. Huggins, P. Wren, K. Gruis, “What would brain-computer interface users want? Opinions and priorities of potential users with amyotrophic lateral sclerosis”, *Amyotroph Lateral Scler*, vol. 12, no. 5, pp. 318-324, 2011. doi: 10.3109/17482968.2011.572978
- [2] H. Anupama, N. Cauvery, G. Lingaraju, “Brain Computer Interface and its Types - A Study”, *Int. Journal of Advances in Engineering & Technology*, vol. 3, no. 2, pp. 739-745, 2012. ISBN 2231-1963.
- [3] W. Hsu, “Motor Imagery EEG Discrimination Using the Correlation of Wavelet Features”, *Clinical EEG and neuroscience*, vol. 46, no. 2, pp. 94-99, 2014. doi: 10.1177/1550059413514974
- [4] G. R. Müller-Putz, R. Scherer, G. Pfurtscheller, R. Rupp, “EEG-based neuroprosthesis control: A step towards clinical practice”, *Neuroscience Letters*, vol. 382, no. 1-2, pp. 169-174, 2005. doi: 10.1016/j.neulet.2005.03.021
- [5] S. Bhattacharyya, A. Khasnobish, A. Konar, D. N. Tibarewala, A. K. Nagar, “Performance analysis of left/right hand movement classification from EEG signal by intelligent algorithms”, em *IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain*, pp. 1-8, 2011.
- [6] C. Guger, S. Daban, E. Sellers, C. Holzner, G. Krausz, R. Carabalona, F. Gramatica, G. Edlinger, “How many people are able to control a P300-based brain-computer interface (BCI)?”, *Neuroscience Letters*, vol. 462, no. 1, pp. 94-98, 2009.

- [7] F. Lotte, “Brain-computer interfaces for 3D games: Hype or Hope?”, *Proc. 6th Int. Conf. Foundations of Digital Games - FDG '11*, pp. 325-327, 2011. doi: 10.1145/2159365.2159427
- [8] H. Hwang, S. Kim, S. Choi, C. Im, “EEG-Based Brain-Computer Interfaces: A Thorough Literature Survey”, *Inter. Journal of Human-Computer Interaction*, vol. 29, pp. 814-826, 2013. doi: 10.1080/10447318.2013.780869
- [9] E. A. Curran, M. J. Stokes, “Learning to control brain activity: A review of the production and control of EEG components for driving brain-computer interface (BCI) systems”, *Brain and Cognition*, vol. 51, no. 3, pp. 326-336, 2003. doi: 10.1016/S0278-2626(03)00036-8
- [10] M. F. M. Shafique, Z. H. Khan, “Towards a Low Cost Brain-computer Interface for Real time Control of a 2 DOF Robotic Arm”, em *2015 Int. Conf. Emerging Technologies (ICET)*, pp. 1-6. 2015.
- [11] C. Kranczoch, C. Zich, I. Schierholz, A. Sterr, “Mobile EEG and its potential to promote the theory and application of imagery-based motor rehabilitation”, *International Journal of Psychophysiology*, vol. 91, no. 1, pp. 10-15, 2014. doi: 10.1016/j.ijpsycho.2013.10.004
- [12] W. Penny, S. Roberts, E. Curran, M. Stokes, “EEG-Based Communication: A Pattern Recognition Approach”, *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 214-215, 2000. doi: 10.1109/86.847820
- [13] K. C. Veluvolu, Y. Wang, S. S. Kavuri, “Adaptive estimation of EEG-rhythms for optimal band identification in BCI” *Journal of Neuroscience Methods*, vol. 203, no. 1, pp. 163-172, 2012. doi: 10.1016/j.jneumeth.2011.08.035
- [14] W. Hairston, K. Whitaker, A. Ries, J. Vettel, J. Bradford, S. Kerick, K. McDowell, “Usability of four commercially-oriented EEG systems”, *Journal of Neural Engineering*, vol. 11, 2014. doi: 10.1088/1741-2560/11/4/046018
- [15] N. Chadwick, D. McMeekin, T. Tan, “Classifying eye and head movement artifacts in EEG signals”, em *IEEE Int. Conf. Digital Ecosystems and Technologies*, Daejeon, 2011. doi: 10.1109/DEST.2011.5936640
- [16] L. Sherwood, *Human Physiology*, 7^a ed. Brooks/Cole, Cengage Learning, 2010, pp. 139-143.
- [17] E. Micheli-Tzanakou, “Nervous System” em *The Biomedical Engineering Handbook*, 2^a ed. Boca Raton: CRC Press LLC, 2000.

- [18] D. G. Amaral, P. L. Strick, “The Organization of the Central Nervous System” em *Principles of Neural Science*, E. R. Kandel, J. H. Schwartz, T. M. Jessell, S. A. Siegelbaum, A. J. Hudspeth, Eds. 5^a ed. McGraw-Hill, 2013.
- [19] A. C. Guyton, J. E. Hall, *Textbook of Medical Physiology*, 11^a ed. Elsevier Inc., 2006.
- [20] R. G. Northcutt, J. H. Kaas, “The emergence and evolution of mammalian neocortex”, *Trends Neurosci.*, vol. 18, pp. 373-379, 1995.
- [21] B. Fischl and A. M. Dale, “Measuring the thickness of the human cerebral cortex from magnetic resonance images”, *Proc. Natl. Acad. Sci. USA*, vol. 97, no. 20, 2000. doi: 10.1073/pnas.200033797
- [22] P. Rakic, “Specification of Cerebral Cortical Areas”, *Nature*, vol. 241, pp. 170-176, 1988.
- [23] J. H. Kaas, “Evolution of the neocortex”, *Current Biology*, vol. 16, no. 21, pp. R910-R914, 2006. doi: dx.doi.org/10.1016/j.cub.2006.09.057
- [24] I. Bystron, C. Blakemore, P. Rakic, “Development of the human cerebral cortex: Boulder Committee revisited”, *Nature Reviews Neuroscience*, vol. 9, pp. 110-122, 2008. doi: 10.1038/nrn2252
- [25] D. C. Van Essen, H. A. Drury, “Structural and Functional Analyses of Human Cerebral Cortex Using a Surface-Based Atlas”, *Journal of Neuroscience*, vol. 17, no. 18, pp. 7079-7102, 1997.
- [26] D. G. Amaral, P. L. Strick, “Voluntary Movement: The Primary Motor Cortex” em *Principles of Neural Science*, E. R. Kandel, J. H. Schwartz, T. M. Jessell, S. A. Siegelbaum, A. J. Hudspeth, Eds. 5^a ed. McGraw-Hill, 2013.
- [27] J. Tanji, “The supplementary motor area in the cerebral cortex”, *Neuroscience Research*, vol. 19, no. 3, pp. 251-268, 1994. doi: dx.doi.org/10.1016/0168-0102(94)90038-8
- [28] G. Rizzolatti, L. Fadiga, V. Gallese, L. Fogassi, “Premotor cortex and the recognition of motor actions”, *Cognitive Brain Research*, vol. 3, no. 2, pp. 131-141, 1996. doi: dx.doi.org/10.1016/0926-6410(95)00038-0
- [29] P. R. Huttenlocher, “Synaptic Density in Human Frontal Cortex – Developmental Changes and Effects of Aging”, *Brain Research*, vol. 163, pp. 195-205, 1979.
- [30] M. Erecińska, I. A. Silver, “ATP and Brain Function”, *Journal of Cerebral Blood Flow and Metabolism*, vol. 9, pp. 2-19, 1989.

- [31] J. Koester, S. A. Siegelbaum, “Membrane Potential and the Passive Electrical Properties of the Neuron” em *Principles of Neural Science*, E. R. Kandel, J. H. Schwartz, T. M. Jessell, S. A. Siegelbaum, A. J. Hudspeth, Eds. 5^a ed. McGraw-Hill, 2013.
- [32] A. L. Hodgkin, A. F. Huxley, “A quantitative description of membrane current and its application to conduction and excitation in nerve”, *The Journal of Physiology*, vol. 117, no. 4, pp. 500-544, 1952.
- [33] S. J. Mitchell, R. A. Silver, “Shunting Inhibition Modulates Neuronal Gain during Synaptic Excitation”, *Neuron*, vol. 38, no. 3, pp. 433-445, 2003. doi: 10.1016/S0896-6273(03)00200-9
- [34] R. Elul, “The genesis of the EEG”, *Int. Review of Neurobiology*, vol. 15, pp. 227-272, 1972.
- [35] G. L. Westbrook, “Seizures and Epilepsy” em *Principles of Neural Science*, E. R. Kandel, J. H. Schwartz, T. M. Jessell, S. A. Siegelbaum, A. J. Hudspeth, Eds. 5^a ed. McGraw-Hill, 2013.
- [36] S. Vaid, “EEG Signal Analysis for BCI Interface: A Review” em *5th Int. Conf. Advanced Computing & Communication Technologies*, pp. 143-147, 2015. doi: 10.1109/ACCT.2015.72
- [37] J. D. Bronzino, “Principles of Electroencephalography” em *The Biomedical Engineering Handbook*, 2^a ed. Boca Raton: CRC Press LLC, 2000.
- [38] P. L. Nunez, R. Srinivasan, “The Physics-EEG Interface” em *Electric Fields of the Brain: The Neurophysics of EEG*, 2^a ed. Oxford University Press, Inc. 2006.
- [39] R. J. Davidson, D. C. Jackson, C. L. Larson, “Human Electroencephalography” em *Handbook of Psychophysiology*, J. T. Cacioppo, L. G. Tassinary, G. G. Berntson, Eds. 2^a ed. Cambridge University Press, 2000.
- [40] S. Baijal, N. SrinivasanEmail, “Theta activity and meditative states: spectral changes during concentrative meditation”, *Cognitive Processing*, vol. 11, no. 1, pp. 31-38, 2009. doi: doi.org/10.1007/s10339-009-0272-0
- [41] E. V. Orekhova, T. A. Stroganova, I. N. Posikera, M. Elam, “EEG theta rhythm in infants and preschool children”, *Clinical Neurophysiology*, vol. 117, no. 5, pp. 1047-1062, 2006. doi: doi.org/10.1016/j.clinph.2005.12.027
- [42] E. J. Kennedy, J. V. Wait, “Operational Amplifier” em *The Electrical Engineering Handbook*, R. C. Dorf, Ed. Boca Raton: CRC Press LLC, 2000.

- [43] R. E. Massara, J. W. Steadman, B. M. Wilamowski, J. A. Svoboda, “Active Filters” em *The Electrical Engineering Handbook*, R. C. Dorf, Ed. Boca Raton: CRC Press LLC, 2000.
- [44] S. A. R. Garrod, “D/A and A/D Converters” em *The Electrical Engineering Handbook*, R. C. Dorf, Ed. Boca Raton: CRC Press LLC, 2000.
- [45] M. Teplan, “Fundamentals of EEG Measurement”, *Measurement Science Review*, Vol. 2, Sec. 2, 2002. Disponível em [measurement.sk/2002/S2/Teplan.pdf](#). Acessado em 25 abr. 2016.
- [46] K. Blinowska, P. Durka, “Electroencephalography (EEG)” em *Wiley Encyclopedia of Biomedical Engineering*. John Wiley & Sons, Inc. 2006.
- [47] L. Tüshaus, X. Omlin, R. Tuura, A. Federspiel, R. Luechinger, P. Staempfli, T. Koenig, P. Achermann, “In human non-REM sleep, more slow-wave activity leads to less blood flow in the prefrontal cortex”, *Scientific Reports*, vol. 7, 2017. doi: 10.1038/s41598-017-12890-7
- [48] F. Ede, “Mnemonic and attentional roles for states of attenuated alpha oscillations in perceptual working memory: a review”, *European Journal of Neuroscience*, 2017. doi: 10.1111/ejn.13759
- [49] H. Schaefer, “Music and Man – Current Studies of Music-Evoked Emotions”, *Frontiers in Neuroscience*, 2017. Disponível em [frontiersin.org/articles/10.3389/fnins.2017.00600](#). Acessado em 12 nov. 2017. doi: 10.3389/fnins.2017.00600
- [50] B. Kerous, F. Skola, F. Liarokapis, “EEG-based BCI and video games: a progress report”, *Virtual Reality*, 2017. Disponível em [link.springer.com/article/10.1007/s10055-017-0328-x](#). Acessado em 12 nov. 2017. doi: 10.1007/s10055-017-0328-x
- [51] Y. Liang, W. Horrey, M. Howard, M. Lee, C. Anderson, M. Shreeve, C. O’Brien, C. Czeisler, “Prediction of drowsiness events in night shift workers during morning driving”, *Accident Analysis & Prevention*, 2017, ISSN 0001-4575. Disponível em [sciencedirect.com/science/article/pii/S0001457517303913](#). Acessado em 12 nov. 2017. doi: [doi.org/10.1016/j.aap.2017.11.004](#)
- [52] L. Angrisani, P. Arpaia, D. Casinelli, “Instrumentation and measurements for non-invasive EEG-based brain-computer interface”, em *2017 IEEE Int. Workshop Measurement and Networking*, Naples, Italy, 2017, pp. 1-5. doi: 10.1109/IWMN.2017.8078383
- [53] M. Neuman, “Biopotential Electrodes”, em *Medical Instrumentation – Application and Design*, J. Webster, Ed. John Wiley & Sons, Inc, 2010. ISBN 978-0471-67600-3

- [54] D. O. Weaver and Company, “Material Safety data sheet – TEN20 Conductive Paste”, 2006. Disponível em <https://bio-medical.com/media/support/10208.pdf>. Acessado em 14 out. 2017.
- [55] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, B. Arnaldi, “A Review of Classification Algorithms for EEG-based Brain-Computer Interfaces”, *Journal of Neural Engineering*, vol. 4, no. 2, 2007.
- [56] R. Chaudhari, H. Galiyawala, “A Review on Motor Imagery Signal Classification for BCI”, *Signal Processing: An International Journal (SPIJ)*, vol. 11, no. 2, 2017. ISSN 1985-2339
- [57] J. Rajeswari, M. Jagannath, “Advances in biomedical signal and image processing – A systematic review”, *Informatics in Medicine Unlocked*, vol. 8, pp. 13-19, 2017. doi: doi.org/10.1016/j.imu.2017.04.002
- [58] K. Ang, C. Guan, “EEG-Based Strategies to Detect Motor Imagery for Control and Rehabilitation”, *IEEE Trans. Neural Systems and Rehabilitation Engineering*, vol. 25, no. 4, pp. 392-401, 2017. doi: [10.1109/TNSRE.2016.2646763](https://doi.org/10.1109/TNSRE.2016.2646763)
- [59] A. Glória, F. Cercas, N. Souto, “Comparison of communication protocols for low cost Internet of Things devices”, em *2017 South Eastern European Design Automation, Computer Engineering, Computer Networks and Social Media Conference (SEEDA-CECNSM)*, Kastoria, Greece, 2017, pp. 1-6. doi: [10.23919/SEEDA-CECNSM.2017.8088226](https://doi.org/10.23919/SEEDA-CECNSM.2017.8088226)
- [60] M. Haus, M. Waqas, A. Y. Ding, Y. Li, S. Tarkoma, J. Ott, “Security and Privacy in Device-to-Device (D2D) Communication: A Review”, *IEEE Communications Surveys & Tutorials*, vol. 19, no. 2, pp. 1054-1079, 2017. doi: [10.1109/COMST.2017.2649687](https://doi.org/10.1109/COMST.2017.2649687)
- [61] “Printed Circuit Board (PCB) Design Issues”, em *Basic Linear Design*, H. Zumbahlen ed. Analog Devices, Inc, 2007. ISBN 0-916550-28-1. Disponível em analog.com/media/en/training-seminars/design-handbooks/Basic-Linear-Design/Basic_Linear_Design.zip. Acessado em 22 out. 2017.
- [62] E. Ratti, S. Waninger, C. Berka, G. Ruffini, A. Verma, “Comparison of Medical and Consumer Wireless EEG Systems for Use in Clinical Trials”, *Frontiers in Human Neuroscience*, 2017. doi: doi.org/10.3389/fnhum.2017.00398
- [63] Emotiv Epoc+ – 14 Channel Wireless EEG Headset. Disponível em emotiv.com/epoc. Acessado em 21 nov. 2017.

- [64] MindWave. Disponível em store.neurosky.com/pages/mindwave. Acessado em 21 nov. 2017.
- [65] OpenBCI – Open Source Biosensing Tools. Disponível em openbci.com. Acessado em 21 nov. 2017.
- [66] Arduino – Home. Disponível em arduino.cc. Acessado em 21 nov. 2017.
- [67] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, T. M. Vaughan, “Brain computer interfaces for communication and control”, *Clin. Neurophysiology*, vol. 113, pp. 767-791, 2002.
- [68] A. Vallabhaneni, T. Wang, B. He, “Brain Computer Interface” em *Neural Engineering*. Springer US, 2005, pp. 85-121.
- [69] J. J. Vidal, “Toward direct brain-computer communication”, *Annual review of Biophysics and Bioengineering*, vol. 2, no. 1, pp. 157-180, 1973.
- [70] J. J. Vidal, “Real-time detection of brain events in EEG”, *Proc. IEEE*, vol. 65, no. 5, pp. 633-641, 1977.
- [71] E. Donchin, “A Multivariate Approach to the Analysis of Average Evoked Potentials”, *IEEE Trans. Bio-Medical Engineering*, vol. 13, no. 3, pp. 131-139, 1966.
- [72] E. Callaway, R. S. Layne, “Interaction between the visual evoked response and two spontaneous biological rhythms: the EEG alpha cycle and the cardiac arousal cycle”, *Annals of the New York Academy of Sciences*, vol. 112, no. 1, pp. 421-431, 1964.
- [73] P. Beaudry, M. Doms, E. Lewis, “Should the Personal Computer Be Considered a Technological Revolution? Evidence from U.S. Metropolitan Areas”, *Journal of Political Economy*, vol. 118, no. 5, pp. 988-1036, 2010. doi: 10.1086/658371
- [74] N-W.F.P University of Engineering & Technology, Pakistan. *Country wise list of BCI Labs & Research Groups*. Disponível em braincomputerinterface.weebly.com/other-bci-researchers-and-labs.html. Acessado em 16 jan. 2017.
- [75] BNCI Horizon 2020. *Research Groups*. Disponível em bnci-horizon-2020.eu/community/research-groups. Acessado em 16 jan. 2017.
- [76] UFPE. Grupo de Pesquisa em Engenharia Biomédica. Disponível em ufpe.br/propesq/images/dpq/catalogo_grupos_de_pesquisa_2015_ufpe.pdf. Acessado em 16 jan. 2017.
- [77] USP. Laboratório de Engenharia Biomédica. Disponível em leb.usp.br. Acessado em 16 jan. 2017.

- [78] G.Tec Medical Engineering Gmbh. Disponível em gtec.at. Acessado em 16 jan. 2017.
- [79] Compumedics Neuroscan. Disponível em compumedicsneuroscan.com. Acessado em 16 jan. 2017.
- [80] The BRAIN Initiative. Disponível em braininitiative.nih.gov. Acessado em 22 nov. 2016.
- [81] C. Park, W. Chang, M. Lee, G. Kwon, L. Kim, S. Kim, Y. Kim, “Which motor cortical region best predicts imagined movement?”, *NeuroImage*, vol. 113, pp. 101-110, 2015. doi: [dx.doi.org/10.1016/j.neuroimage.2015.03.033](https://doi.org/10.1016/j.neuroimage.2015.03.033)
- [82] J. K. Chapin, K. A. Moxon, R. S. Markowitz, M. A. L. Nicolelis, “Real-time control of a robot arm using simultaneously recorded neurons in the motor cortex”, *Nature Neuroscience*, vol. 2, no. 7, pp. 664-670, 1999. doi: [dx.doi.org/10.1038/10223](https://doi.org/10.1038/10223)
- [83] J. M. Carmena, M. A. Lebedev, R. E. Crist, J. E. O’Doherty, D. M. Santucci, D. F. Dimitrov, P. G. Patil, C. S. Henriquez, M. A. L. Nicolelis, “Learning to Control a Brain-Machine Interface for Reaching and Grasping by Primates”, *PLoS Biology*, vol. 1, no. 2, 2003. doi: [10.1371/journal.pbio.0000042](https://doi.org/10.1371/journal.pbio.0000042)
- [84] J. E. O’Doherty, M. A. Lebedev, P. J. Ifft, K. Z. Zhuang, S. Shokur, H. Bleuler, M. A. L. Nicolelis, “Active tactile exploration using a brain-machine interface”, *Nature*, vol. 479, no. 7372, pp. 228-231, 2011. doi: [dx.doi.org/10.1038/nature10489](https://doi.org/10.1038/nature10489)
- [85] P. Konrad, T. Shanks, “Implantable brain computer interface: Challenges to neurotechnology translation”, *Neurobiology of Disease*, vol. 38, no. 3, pp. 369-375, 2010. doi: [dx.doi.org/10.1016/j.nbd.2009.12.007](https://doi.org/10.1016/j.nbd.2009.12.007)
- [86] L. Hochberg, M. Serruya, G. Friehs, J. Mukand, M. Saleh, A. Caplan, A. Branner, D. Chen, R. Penn, J. Donoghue, “Neuronal ensemble control of prosthetic devices by a human with tetraplegia”, *Nature*, vol. 442, no. 7099, pp. 164-171, 2006.
- [87] T. Lal, T. Hinterberger, G. Widman, M. Schröder, J. Hill, W. Rosenstiel, C. Elger, B. Schölkopf, N. Birbaumer, “Methods Towards Invasive Human Brain Computer Interfaces” em *Advances in neural information processing systems*, pp. 737-744. 2004.
- [88] D. Moran, “Evolution of brain-computer interface: action potentials, local field potentials and electrocorticograms”, *Current Opinion in Neurobiology*, vol. 20, pp. 741-745, 2010. doi: [10.1016/j.conb.2010.09.010](https://doi.org/10.1016/j.conb.2010.09.010)
- [89] E. Leuthardt, G. Schalk, J. Wolpaw, J. Ojemann, D. Moran, “A brain-computer interface using electrocorticographic signals in humans”, *Journal of Neural Engineering*, vol. 1, pp. 63-71, 2004.

- [90] E. Leuthardt, G. Schalk, D. Moran, J. Wolpaw, J. Ojemann, “Brain Computer Interface”, U.S. patente US7120486 B2, 10 out. 2006.
- [91] D. Krusienski, M. Grosse-Wentrup, F. Galán, D. Coyle, K. Miller, E. Forney, C. Anderson, “Critical issues in state-of-the-art brain-computer interface signal processing”, *Journal of neural engineering*, vol. 8, 2011. doi: 10.1088/1741-2560/8/2/025002
- [92] F. Lopes da Silva, “EEG and MEG: Relevance to Neuroscience”, *Neuron*, vol. 80, no. 5, pp. 1112-1128, 2013. doi:dx.doi.org/10.1016/j.neuron.2013.10.017. Disponível em [cell.com/neuron/fulltext/S0896-6273\(13\)00920-3](http://cell.com/neuron/fulltext/S0896-6273(13)00920-3). Acessado em 30 mai. 2016.
- [93] D. Cohen, “Magnetoencephalography: Detection of the Brain’s Electrical Activity with a Superconducting MAGnetometer”, *Science*, vol. 175, pp. 664-666, 1972. Disponível em [davidcohen.mit.edu/sites/default/files/documents/1972ScienceV175\(SquidMEG\).pdf](http://davidcohen.mit.edu/sites/default/files/documents/1972ScienceV175(SquidMEG).pdf). Acessado em 30 mai. 2016.
- [94] N. Naseer, K. Hong, “fNIRS-based Brain-computer Interfaces:a review”, *Frontiers in Human Neuroscience*, vol. 9, 2015. doi:10.3389/fnhum.2015.00003. Disponível em frontiersin.org/Journal/Abstract.aspx?s=537&name=human_neuroscience&ART_DOI=10.3389/fnhum.2015.00003. Acessado em 9 mai. 2016.
- [95] J. León-Carrión, U. León-Domínguez, “Functional Near-Infrared Spectroscopy (fNIRS): Principles and Neuroscientific Applications”, *Neuroimaging - Methods*, Peter Bright Ed. ISBN 978-953-51-0097-3, InTech, 2012. Disponível em intechopen.com/books/neuroimaging-methods/functional-nearinfrared-spectroscopy-fnirs-brain-studies-and-others_-clinical-uses. Acessado em 9 mai. 2016.
- [96] D. Hermes, M. Vansteensel, A. Albers, M. Bleichner, M. Benedictus, C. Orellana, E. Aarnoutse, N. Ramsey, “Functional MRI-based identification of brain areas involved in motor imagery for implantable brain-computer interfaces”, *Journal of Neural Engineering*, vol. 8, 2011. doi: 10.1088/1741-2560/8/2/025007
- [97] J. Lee, J. Ryu, F. Jolesz, Z. Cho, S. Yoo, “Brain-machine interface via real-time fMRI: Preliminary study on thought-controlled robotic arm”, *Neuroscience Letters*, vol. 450, pp. 1-6, 2009. doi: 10.1016/j.neulet.2008.11.024
- [98] X. Yin, B. Xu, C. Jiang, Y. Fu, Z. Wang, H. Li, G. Shi, “A hybrid BCI based on EEG and fNIRS signals improves the performance of decoding motor imagery of both force and speed of hand cleching”, *Journal of Neural Engineering*, vol. 12, 2015. doi:10.1088/1741-2560/12/3/036004

- [99] S. Fazli, J. Mehnert, J. Steinbrink, G. Curio, A. Villringer, K. R. Müller, B. Blankertz, “Enhanced performance by a hybrid NIRS-EEG brain computer interface”, *Neuroimage*, vol. 59, pp. 519-529, 2012. Disponível em sciencedirect.com/science/article/pii/S1053811911008792. Acessado em 25 abr. 2016.
- [100] G. Pfurtscheller, F. H. Lopes da Silva, “Event-related EEG/MEG synchronization and desynchronization: basic principles”, *Clinical Neurophysiology*, vol. 110, pp. 1842-1857, 1999.
- [101] A. Meyer-Lindenberg, “From maps to mechanisms through neuroimaging of schizophrenia”, *Nature*, vol. 468, pp. 194-202, 2010. doi:10.1038/nature09569
- [102] S. Amiri, R. Fazel-Rezai, V. Asadpour, “A Review of Hybrid Brain-Computer Interface Systems”, *Advances in Human-Computer Interaction*, vol. 2013, 2013. doi: [dx.doi.org/10.1155/2013/187024](https://doi.org/10.1155/2013/187024)
- [103] L. Nicolas-Alonso, J. Gomez-Gil, “Brain Computer Interfaces, a Review”, *Sensors*, vol. 12, pp. 1211-1279, 2012. doi: [10.3390/s120201211](https://doi.org/10.3390/s120201211)
- [104] K. Hong, H. Santosa, “Current BCI Technologies in Brain Engineering” em *Int. Conf. on Robotics, Biomimetics, Intelligent Computational Systems*, Yogyakarta, pp. 1-4, 2013. doi: [10.1109/ROBIONETICS.2013.6743567](https://doi.org/10.1109/ROBIONETICS.2013.6743567)
- [105] J. Kevric, A. Subasi, “Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system”, *Biomedical Signal Processing and Control*, vol. 31, pp. 398-406, 2017. doi: [dx.doi.org/10.1016/j.bspc.2016.09.007](https://doi.org/10.1016/j.bspc.2016.09.007)
- [106] D. Subha, P. Joseph, R. Acharya, C. Lim, “EEG signal analysis: a survey”, *Journal of medical systems*, vol. 34, no. 2, pp. 195-212, 2010. doi: [10.1007/s10916-008-9231-z](https://doi.org/10.1007/s10916-008-9231-z)
- [107] M. Lebedev, M. Nicolelis, “Brain-machine interfaces: past, present and future”, *Trends in Neurosciences*, vol. 29, no. 9, pp. 536-546, 2006.
- [108] A. Jain, R. Duin, J. Mao, “Statistical Pattern Recognition: A Review”, *Trans. Pattern Analysis Machine Intelligence*, vol. 22, no. 1, 2000. doi: [10.1109/34.824819](https://doi.org/10.1109/34.824819)
- [109] R. Duda, P. Hart, D. Stork, *Pattern Classification*, 2^a ed. John Wiley & Sons Inc. 2001.
- [110] K. Fukunaga, *Introduction to Statistical Pattern Recognition*, 2^a ed. Academic Press. 1990.
- [111] P. Ahmadian, S. Cagnoni, L. Ascari, “How capable is non-invasive EEG data of predicting the next movement? A mini review”, *Frontiers in Human Neuroscience*, vol. 7, 2013. doi: [10.3389/fnhum.2013.00124](https://doi.org/10.3389/fnhum.2013.00124)

- [112] V. Morash, O. Bai, S. Furlani, P. Lin, M. Hallett, “Classifying EEG signals preceding right hand, left hand, tongue, and right foot movements and motor imageries”, *Clinical Neurophysiology*, vol. 119, no. 11, pp. 2570-2578, 2008. doi: 10.1016/j.clinph.2008.08.013
- [113] C. Neuper, R. Scherer, M. Reiner, G. Pfurtscheller, “Imagery of motor actions: Differential effects of kinesthetic and visual-motor mode of imagery in single-trial EEG,” *Cognitive Brain Research*, vol. 25, no. 3, pp. 668-677, 2005. doi: 10.1016/j.cogbrainres.2005.08.014
- [114] R. Beisteiner, P. Höllinger, G. Lindinger, W. Lang, A. Berthoz, “Mental representations of movements. Brain potentials associated with imagination of hand movements”, *Electroencephalography and clinical Neurophysiology*, vol. 96, pp. 183-193, 1995.
- [115] G. Pfurtscheller, C. Neuper, D. Flotzinger, M. Pregenzer, “EEG-based discrimination between imagination of right and left hand movement”, *Electroencephalography and Clinical Neurophysiology*, vol. 103, no. 6, pp. 642-651, 1997. doi: 10.1016/S0013-4694(97)00080-1
- [116] G. Pfurtscheller, “Functional brain imaging based on ERD/ERS”, *Vision Research*, vol. 41, no. 10-11, pp. 1257-1260, 2001. doi: 10.1016/S0042-6989(00)00235-2
- [117] G. Pfurtscheller, C. Neuper, “Motor imagery activates primary sensorimotor area in humans”, *Neuroscience Letters*, vol. 239, pp. 65-68, 1997.
- [118] Y. Jeon, C. S. Nam, Y. Kim, M. C. Whang, “Event-related (De)synchronization (ERD/ERS) during motor imagery tasks: Implications for brain-computer interfaces”, *International Journal of Industrial Ergonomics*, vol. 41, no. 5, pp. 428-436, 2011. doi: 10.1016/j.ergon.2011.03.005
- [119] G. Townsend, B. Graimann, G. Pfurtscheller, “Continuous EEG classification during motor imagery-simulation of an asynchronous BCI”, *IEEE Trans. Neural Systems Rehabilitation Engineering*, vol. 12, no. 2, pp. 258-265, 2004. doi: 10.1109/TNSRE.2004.827220
- [120] S. Suzuki, T. Matsui, Y. Sakaguchi, K. Ando, N. Nishiuchi, M. Ishihara, “The possibility of determination of accuracy of performance just before the onset of a reaching task using movement-related cortical potentials”, *Medical and Biological Engineering and Computing*, vol. 48, no. 9, pp. 845-852, 2010. doi: 10.1007/s11517-010-0664-4
- [121] E. López-Larraz, L. Montesano, Á. Gil-Agudo, J. Minguez, “Continuous decoding of movement intention of upper limb self-initiated analytic movements from pre-movement EEG correlates”, *PLoS One*, vol. 11, no. 4, p. 13, 2014. Disponível em jneuroengrehab.com/content/11/1/153. Acessado em 3 out. 2016.

- [122] M. Alomari, A. Samaha, K. AlKamha, “Automated Classification of L/R Hand Movement EEG Signals using Advanced Feature Extraction and Machine Learning”, *Int. Journal of Advanced Computer Science and Applications*, Vol. 4, no. 6, 2013.
- [123] J. Urigüen, B. Garcia-Zapirain, “EEG artifact removal – State-of-the-art and guidelines”, *Journal of Neural Engineering*, vol. 12, no. 3, 2015. doi: 10.1088/1741-2560/12/3/031001
- [124] A. Broniec, “Analysis of EEG signal by flicker-noise spectroscopy: identification of right-/left-hand movement imagination”, *Medical & Biological Engineering & Computing*, 2016. doi: 10.1007/s11517-016-1491-z
- [125] E. Forney, C. Anderson, “Classification of EEG During Imagined Mental Tasks by Forecasting with Elman Recurrent Neural Networks”, *Proc. Int. Joint Conf. Neural Networks*, 2011. pp. 2749-2755. doi: 10.1109/IJCNN.2011.6033579
- [126] D. Fattahi, B. Nasihatkon, R. Boostani, “A general framework to estimate spatial and spatio-spectral filters for EEG signal classification”, *Neurocomputing*, vol. 119, pp. 165-174, 2013. doi: 10.1016/j.neucom.2013.03.044
- [127] A. Ortiz-Rosario, H. Adeli, “Brain-computer interface technologies: From signal to action”, *Reviews in the Neurosciences*, vol. 24, no. 5, pp. 537-552, 2013. doi: 10.1515/revneuro-2013-0032
- [128] A. Madhu, V. K. Jayasree, V. Thomas, “A Survey Paper on Time Frequency Analysis of EEG Signal”, *Progress In Science and Engineering Research Journal*, vol. 2, no. 3, pp. 46-51, 2014. ISSN 2347-6680 (E).
- [129] M. Tolić, F. Jović, “Classification of Wavelet Transformed EEG Signals with Neural Network for Imagined Mental and Motor Tasks”, *Kinesiology*, vol. 45, pp. 130-138, 2013. Disponível em hrcak.srce.hr/104591. Acessado em 5 nov. 2017.
- [130] M. Weeks, *Digital Signal Processing using Matlab and Wavelets*, 2^a ed. Jones & Bartlett Learning, mar. 2010.
- [131] A. Oppenheim, R. Schaffer, J. Buck, *Discrete-Time Signal Processing*, 2^a ed. Prentice Hall, 1999.
- [132] I. Daubechies, “Orthonormal Bases of Compactly Supported Wavelets”, *Communications on Pure and Applied Mathematics*, vol. XLI, pp. 909-996, 1988.
- [133] B. Xu, A. Song, “Pattern recognition of motor imagery EEG using wavelet transform”, *Journal of Biomedical Science and Engineering*, no. 1, pp. 64-67, 2008. doi: 10.4236/jbise.2008.11010

- [134] R. Chatterjee, T. Bandyopadhyay, D. K. Sanyal, “Effects of wavelets on quality of features in motor-imagery EEG signal classification”, em *2016 Int. Conf. Wireless Communications, Signal Processing and Networking (WiSPNET)*, Chennai, 2016, pp. 1346-1350. doi: 10.1109/WiSPNET.2016.7566356
- [135] R. Chatterjee and T. Bandyopadhyay, “EEG Based Motor Imagery Classification Using SVM and MLP”, em *2016 2nd Int. Conf. Computational Intelligence and Networks (CINE)*, Bhubaneswar, 2016, pp. 84-89. doi: 10.1109/CINE.2016.22
- [136] C. Yaacoub, G. Mhanna, S. Rihana, “A Genetic-Based Feature Selection Approach in the Identification of Left/Right Hand Motor Imagery for a Brain-Computer Interface”, *Brain Sciences*, vol. 7, no. 1, 2017. doi: 10.3390/brainsci7010012
- [137] K. Morris. (25 fev. 2014). *Xilinx vs. Altera – Calling the Action in the Greatest Semiconductor Rivalry*. Disponível em eejournal.com/archives/articles/20140225-rivalry/. Acessado em 11 jun. 2016.
- [138] *Programmable Devices*, Xilinx Inc. Disponível em xilinx.com/products/silicon-devices.html. Acessado em 11 jul. 2016.
- [139] *Altera Product Selector*, Altera Corporation. Disponível em altera.com/products/product-selector-guide/psg-selector.html. Acessado em 11 jul. 2016.
- [140] “Cyclone III Device Datasheet” em *Cyclone III Device Handbook*, vol. 2, Altera, San Jose, CA, jul. 2012. Disponível em altera.com/content/dam/altera-www/global/en_US/pdfs/literature/hb/cyc3/cyclone3_handbook.pdf. Acessado em 29 set. 2015.
- [141] *Cyclone III Device Handbook*, vol. 1, Altera, San Jose, CA, jul. 2012. Disponível em altera.com/content/dam/altera-www/global/en_US/pdfs/literature/hb/cyc3/cyclone3_handbook.pdf. Acessado em 29 set. 2015.
- [142] A. Rashed, B. Yousif, A. Samra, “Review of FPD Languages, Compilers, Interpreters and Tools”, *Int. Journal of Novel Research in Computer Science and Software Engineering*, vol. 3, no. 1, pp. 140-158, 2016. ISSN 2394-7314.
- [143] *IEEE Standard VHDL Language Reference Manual*, IEEE Standard 1076, 2008.
- [144] *IEEE Standard for Verilog Hardware Description Language*, IEEE Standard 1364, 2005.
- [145] *IEEE Standard for SystemVerilog–Unified Hardware Design, Specification, and Verification Language*, IEEE Standard 1800, 2012.

- [146] J. Sérot, F. Berry, S. Ahmed, “CAPH: A Language for Implementing Stream-Processing Applications on FPGAs”, em *Embedded Systems Design with FPGAs*, P. Athanas, D. Pnevmatikatos, N. Sklavos, Eds. Springer, 2013, ISBN 978-1-4614-1362-2.
- [147] *Introduction to the Quartus II Software Version 9.0*, Altera, San Jose, CA, 2009.
- [148] S. Taran, V. Bajaj, D. Sharma, S. Siuly, A. Sengur, “Features based on analytic IMF for classifying motor imagery EEG signals in BCI applications”, *Measurement*, vol. 116, pp. 68-76, 2018. ISSN 0263-2241 doi: doi.org/10.1016/j.measurement.2017.10.067
- [149] L. Gao, W. Cheng, J. Zhang, J. Wang, “EEG classification for motor imagery and resting state in BCI applications using multi-class Adaboost extreme learning machine”, *Review of scientific instruments*, vol. 87, no. 8, 2016. doi: [dx.doi.org.ez16.periodicos.capes.gov.br/10.1063/1.4959983](https://dx.doi.org/ez16.periodicos.capes.gov.br/10.1063/1.4959983)
- [150] M. Miao, H. Zeng, A. Wang, F. Zhao, F. Liu, “Index finger motor imagery EEG pattern recognition in BCI applications using dictionary cleaned sparse representation-based classification for healthy people”, *Review of Scientific Instruments*, vol. 88, art. no. 094305, 2017. doi: doi.org/10.1063/1.5001896
- [151] R. Liu, Y. Wang, G. Newman, N. Thakor, S. Ying, “EEG Classification with a Sequential Decision-Making Method in Motor Imagery BCI”, *International Journal of Neural Systems*, vol. 27, no. 8, 2017. doi: doi.org/10.1142/S0129065717500460
- [152] Y. Liu, M. Li, H. Zhang, H. Wang, J. Li, J. Jia, Y. Wu, L. Zhang, “A tensor-based scheme for stroke patients’ motor imagery EEG analysis in BCI-FES rehabilitation training”, *Journal of Neuroscience Methods*, vol. 222, no. 30, pp. 238-249, 2014. doi: dx.doi.org/10.1016/j.jneumeth.2013.11.009
- [153] X. Yu, P. Chum, K. Sim, “Analysis the effect of PCA for feature reduction in non-stationary EEG based motor imagery of BCI system”, *Optik – International Journal for Light and Electron Optics*, vol. 125, no. 3, pp. 1498-1502, 2014. doi: dx.doi.org.ez16.periodicos.capes.gov.br/10.1016/j.ijleo.2013.09.013
- [154] H. Zhang, C. Guan, K. Ang, C. Wang, “BCI Competition IV – Data Set I: Learning Discriminative Patterns for Self-Paced EEG-Based Motor Imagery Detection”, *Frontiers in Neuroscience*, vol. 6, no. 7, 2012. doi: [10.3389/fnins.2012.00007](https://doi.org/10.3389/fnins.2012.00007)
- [155] J. Gomez-Pilar, R. Corralejo, L. F. Nicolas-Alonso, D. Álvarez, R. Hornero, “Neurofeedback training with a motor imagery-based BCI: neurocognitive improvements and EEG changes in the elderly”, *Medical & Biological Engineering & Computing*, vol. 54, no. 11, pp. 1655-1666, 2016. doi: dx.doi.org/10.1007/s11517-016-1454-4

- [156] A. Jafarifarmand, M. Badamchizadeh, S. Khanmohammadi, M. Nazari, B. Tazehkand, “A new self-regulated neuro-fuzzy framework for classification of EEG signals in motor imagery BCI”, *IEEE Trans. Fuzzy Systems*, a ser publicado. Disponível em 10.1109/TFUZZ.2017.2728521 Acessado em nov. 2017.
- [157] X. Yin, B. Xu, C. Jiang, Y. Fu, Z. Wang, H. Li, G. Shi, “A hybrid BCI based on EEG and fNIRS signals improves the performance of decoding motor imagery of both force and speed of hand clenching”, *Journal of Neural Engineering*, vol. 12, no. 3, 2015. doi: [stacks.iop.org/1741-2552/12/i=3/a=036004](https://doi.org/10.1071/1741-2552/12/i=3/a=036004)
- [158] K. Belwafi, F. Ghaffari, R. Djemal, O. Romain, “A Hardware/Software Prototype of EEG-based BCI System for Home Device Control”, *Journal of Signal Processing Systems*, pp. 1-17, 2016. doi: 10.1007/s11265-016-1192-8
- [159] J. Pan, C. Lo, S. Tsai, B. Lin, “Design of novel non-contact multimedia controller for disability by using visual stimulus”, *Computer Methods and Programs in Biomedicine*, vol. 122, no. 3, pp. 384-392, 2015. doi: [dx.doi.org/10.1016/j.cmpb.2015.08.010](https://doi.org/10.1016/j.cmpb.2015.08.010)
- [160] P. Diez, S. Müller, V. Mut, E. Laciari, E. Avila, T. Bastos-Filho, M. Sarcinelli-Filho, “Commanding a robotic wheelchair with a high-frequency steady-state visual evoked potential based brain-computer interface”, *Medical Engineering & Physics*, vol. 35, pp. 1155-1164, 2013.
- [161] C. Lo, S. Tsai, B. Lin, “Novel non-contact control system of electric bed for medical healthcare”, *Medical & Biological Engineering & Computing*, vol. 55, no. 3, pp. 517-526, 2017. doi: 10.1007/s11517-016-1533-6
- [162] R. Liu, Z. Zhang, F. Duan, X. Zhou, Z. Meng, “Identification of Anisomeric Motor Imagery EEG Signals Based on Complex Algorithms”, *Computational Intelligence and Neuroscience*, vol. 2017, art. no. 2727856, 2017. doi: <https://doi.org/10.1155/2017/2727856>
- [163] P. Diez, A. Correa, L. Orosco, E. Laciari, V. Mut, “Attention-level transitory response: a novel hybrid BCI approach”, *Journal of Neural Engineering*, vol. 12, 2015. doi: 10.1088/1741-2560/12/5/056007
- [164] X. Zhang, F. Vialatte, C. Chen, A. Rathi, G. Dreyfus, “Embedded Implementation of Second-Order Blind Identification (SOBI) for Real-Time Applications in Neuroscience”, *Cognitive Computation*, vol. 7, no. 1, pp. 56-63, 2015. doi: 10.1007/s12559-014-9282-z
- [165] P. Diez, V. Mut, E. Laciari, E. Perona, “Mobile robot navigation with a self-paced brain-computer interface based on high-frequency SSVEP”, *Robotica*, vol. 32, pp. 695-709, 2013. doi: 10.1017/S0263574713001021

- [166] R. Djemal, K. AlSharabi, S. Ibrahim, A. Alsuwailem, “EEG-Based Computer Aided Diagnosis of Autism Spectrum Disorder Using Wavelet, Entropy, and ANN”, *BioMed Research International*, vol. 2017, art. no. 9816591, 2017. doi: doi.org/10.1155/2017/9816591
- [167] M. Xu, L. Chen, L. Zhang, H. Qi, L. Ma, J. Tang, B. Wan, D. Ming, “A visual parallel-BCI speller based on the time-frequency coding strategy”, *Journal of Neural Engineering*, vol. 11, no. 2, 2014.
- [168] C. Yeh, P. Lee, W. Chen, C. Chang, Y. Wu, G. Lan, “Improvement of classification accuracy in a phase-tagged steady-state visual evoked potential-based brain computer interface using multiclass support vector machine”, *BioMedical Engineering OnLine*, vol. 12, no. 46, 2013. doi: [10.1186/1475-925X-12-46](https://doi.org/10.1186/1475-925X-12-46)
- [169] R. Fukuma, T. Yanagisawa, S. Yorifuji et al., “Closed-Loop Control of a Neuroprosthetic Hand by Magnetoencephalographic Signals”, *PLOS ONE*, vol. 10, no. 7, 2015. doi: doi.org/10.1371/journal.pone.0131547
- [170] M. Wodziński, A. Krzyżanowska, “Sequential Classification of Palm Gestures Based on A* Algorithm and MLP Neural Network for Quadcopter Control”, *Metrology and Measurement Systems*, vol. 24, no. 2, pp. 265-276, 2017. doi: [10.1515/mms-2017-0021](https://doi.org/10.1515/mms-2017-0021)
- [171] M. Gibson, B. Harris, C. Markham, J. Weston, S. Weddell, R. Jones, “Brain-computer interface for thought controlled mobility”, in *New Zealand physics and engineering in medicine conference*, 2014, Christchurch, New Zealand.
- [172] A. Sankar, J. Selvi, D. Kumar, K. Lakshmi, “Effective enhancement of classification of respiratory states using feed forward back propagation neural networks”, *Sādhanā*, vol. 38, no. 3, pp. 377-395, 2013.
- [173] R. Ramli, H. Arof, F. Ibrahim, N. Mokhtar, M. Idris, “Using finite state machine and a hybrid of EEG signal and EOG artifacts for an asynchronous wheelchair navigation”, *Expert Systems with Applications*, vol. 42, no. 5, pp. 2451-2463, 2015. doi: doi.org/10.1016/j.eswa.2014.10.052
- [174] C. Lin, M. Hsieh, “Classification of mental task from EEG data using neural networks based on particle swarm optimization”, *Neurocomputing*, vol. 72, no. 4-6, pp. 1121-1130, 2009.
- [175] M. Yücel, J. Selb, T. Huppert, M. Franceschini, D. Boas, “Functional Near Infrared Spectroscopy: Enabling routine functional brain imaging”, *Current Opinion in Biomedical Engineering*, vol. 4, pp. 78-86, 2017. doi: doi.org/10.1016/j.cobme.2017.09.011

- [176] L. Borges, F. Martins, E. Naves, T. Bastos, V. Lucena, “Multimodal System for Training at Distance in a Virtual or Augmented Reality Environment for Users of Electric-Powered Wheelchairs”, *IFAC – Papers OnLine*, vol. 49, no. 30, pp. 156-160, 2016. doi: 10.1016/j.ifacol.2016.11.146
- [177] “Index”, em *Statistical Signal Processing for Neuroscience and Neurotechnology*, 2010. Disponível em sciencedirect.com/science/article/pii/B9780123750273000120. Acessado em 18 nov. 2017.
- [178] “Index”, em *Wearable Sensors*, 2014. Disponível em sciencedirect.com/science/article/pii/B9780124186620000404. Acessado em 18 nov. 2017.
- [179] M. K. Ahirwal, A. Kumar, G. K. Singh, “Sub-band adaptive filtering method for electroencephalography/event related potential signal using nature inspired optimisation techniques”, *IET Science, Measurement & Technology*, vol. 9, no. 8, pp. 987-997, 2015. doi: 10.1049/iet-smt.2015.0048
- [180] T. Bastos-Filho, F. Cheein, S. Müller, W. Celeste, C. Cruz, D. Cavalieri, M. Sarcinelli-Filho, P. Amaral, E. Perez, C. Soria, R. Carelli, “Towards a New Modality-Independent Interface for a Robotic Wheelchair”, *IEEE Trans. Neural Systems and Rehabilitation Engineering*, vol. 22, no. 3, pp. 567-584, 2014. doi: 10.1109/TNSRE.2013.2265237
- [181] C. McCrimmon, J. Fu, M. Wang et al., “Performance Assessment of a Custom, Portable, and Low-Cost Brain-Computer Interface Platform”, *IEEE Trans. Biomedical Engineering*, vol. 64, no. 10, pp. 2313-2320, 2017. doi: 10.1109/TBME.2017.2667579
- [182] R. Zhang, Q. Wang, K. Li et al., “A BCI-Based Environmental Control System for Patients With Severe Spinal Cord Injuries”, *IEEE Trans. Biomedical Engineering*, vol. 64, no. 8, pp. 1959-1971, 2017. doi: 10.1109/TBME.2016.2628861
- [183] H. G. Jung, G. Kim, “Support vector number reduction: Survey and experimental evaluations”, *IEEE Transactions on Intelligent Transportation Systems*, vol. 15, no. 2, pp. 463-476, 2014. doi: 10.1109/TITS.2013.2282635
- [184] S. Lai, Z. Zhang, Y. Hung, Z. Niu, C. Chang, “A Chromatic Transient Visual Evoked Potential Based Encoding/Decoding Approach for Brain-Computer Interface”, *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, vol. 1, no. 4, pp. 578-589, 2011. doi: 10.1109/JETCAS.2011.2178734
- [185] A. Das, S. Sundaram, N. Sundararajan, “A self-regulated interval type-2 neuro-fuzzy inference system for handling non-stationarities in EEG signals for BCI”, *IEEE Transactions on Fuzzy Systems*, vol. PP, no.99, pp.1-1, 2016. doi: 10.1109/TFUZZ.2016.2540072

- [186] C. Lin, B. Lin, F. Lin, C. Chang, “Brain Computer Interface-Based Smart Living Environmental Auto-Adjustment Control System in UPnP Home Networking”, *IEEE Systems Journal*, vol. 8, no. 2, pp. 363-370, 2014. doi: 10.1109/JSYST.2012.2192756
- [187] K. Shyu, Y. Chiu, P. Lee, M. Lee, J. Sie, C. Wu, Y. Wu, P. Tung, “Total Design of an FPGA-Based Brain-Computer Interface Control Hospital Bed Nursing System”, *IEEE Trans. Industrial Electronics*, vol. 60, no. 7, pp. 2731-2739, 2013. doi: 10.1109/TIE.2012.2196897
- [188] Z. Chen, “A Primer on Neural Signal Processing”, *IEEE Circuits and Systems Magazine*, vol. 17, no. 1, pp. 33-50, 2017. doi: 10.1109/MCAS.2016.2642718
- [189] H. Chang, P. Lee, M. Lo, Y. Wu, K. Wang, G. Lan, “Inter-Trial Analysis of Post-Movement Beta Activities in EEG Signals Using Multivariate Empirical Mode Decomposition”, *IEEE Trans. Neural Systems and Rehabilitation Engineering*, vol. 21, no. 4, pp. 607-615, 2013. doi: 10.1109/TNSRE.2013.2258940
- [190] J. Wu, A. Ang, K. Tsui et al., “Efficient Implementation and Design of a New Single-Channel Electrooculography-Based Human-Machine Interface System”, *IEEE Transactions on Circuits and Systems II: Express Briefs*, vol. 62, no. 2, pp. 179-183, 2015. doi: 10.1109/TCSII.2014.2368617
- [191] C. Lo, T. Chien, J. Pan, B. Lin, “Novel Non-Contact Control System for Medical Healthcare of Disabled Patients”, *IEEE Access*, vol. 4, pp. 5687-5694, 2016. doi: 10.1109/ACCESS.2016.2566668
- [192] P. Georgieva, N. Bouaynaya, F. Silva, L. Mihaylova, L. Jain, “A Beamformer-Particle Filter Framework for Localization of Correlated EEG Sources”, *IEEE Journal of Biomedical and Health Informatics*, vol. 20, no. 3, pp. 880-892, 2016. doi: 10.1109/JBHI.2015.2413752
- [193] B. Pedroni, S. Das, J. Arthur, P. Merolla, B. Jackson, D. Modha, K. Kreutz-Delgado, G. Cauwenberghs, “Mapping Generative Models onto a Network of Digital Spiking Neurons”, *IEEE Transactions on Biomedical Circuits and Systems*, vol. 10, no. 4, pp. 837-854, 2016. doi: 10.1109/TBCAS.2016.2539352
- [194] H. Wöhrle, M. Tabie, S. Kim, F. Kirchner, E. Kirchner, “A Hybrid FPGA-Based System for EEG- and EMG-Based Online Movement Prediction”, *Sensors*, vol. 17, no. 7, 2017. doi: 10.3390/s17071552
- [195] Y. Qassim, T. Cutmore, D. Rowlands, “FPGA implementation of wavelet coherence for EEG and ERP signals”, *Microprocessors and Microsystems*, vol. 51, pp. 356-365, 2017. doi: 10.1016/j.micpro.2017.01.001

- [196] H. Hao, H. Wang, Q. Wei, “Theory of empirical mode decomposition and its application” em *Gaojishu Tongxin/Chinese High Technology Letters*, vol. 26, pp. 67-80, 2016. doi: 10.3772/j.issn.1002-0470.2016.01.010
- [197] T. Shi, H. Wang, C. Zhang, “Brain Computer Interface system based on indoor semi-autonomous navigation and motor imagery for Unmanned Aerial Vehicle control”, *Expert Systems with Applications*, vol. 42, no. 9, pp. 4196-4206, 2015. doi: dx.doi.org/10.1016/j.eswa.2015.01.031
- [198] H. Priyadarsini, R. Manoj, E. Dinesh, A. Kanyalakshmi, S. Jeepitha, “Intelligent control of vehicle using brain computer interface”, *International Journal of Applied Engineering Research*, vol. 10, no. 13, pp. 11282-11289, 2015.
- [199] R. Djemal, A. Bazyed, K. Belwafi, S. Gannouni, W. Kaaniche, “Three-Class EEG-Based Motor Imagery Classification Using Phase-Space Reconstruction Technique”, *Brain Sciences*, vol. 6, no. 3, 2016. doi: 10.3390/brainsci6030036
- [200] A. Évain, F. Argelaguet, G. Casiez, N. Roussel, A. Lécuyer, “Design and Evaluation of Fusion Approach for Combining Brain and Gaze Inputs for Target Selection”, *Frontiers in Neuroscience*, 2016. doi: 10.3389/fnins.2016.00454
- [201] T. Wissel, T. Pfeiffer, R. Frysch et al., “Hidden Markov Model and Support Vector Machine Based Decoding of Finger Movements using Electroencephalography”, *Journal of Neural Engineering*, vol. 10, no. 3, 2013. doi: 10.1088/1741-2560/10/5/056020
- [202] G. Sharma, D. Friedenber, N. Annetta et al., “Using an Artificial Neural Bypass to Restore Cortical Control of Rhythmic Movements in a Human with Quadriplegia”, *Scientific Reports*, vol. 6, art. no. 33807, 2016. doi: 10.1038/srep33807
- [203] R. Fukuma, T. Yanagisawa, Y. Saitoh et al., “Real-Time Control of a Neuroprosthetic Hand by Magnetoencephalographic Signals from Paralysed Patients”, vol. 6, art. no. 21781, 2016. doi: 10.1038/srep21781
- [204] J. Lin, S. Huang, “An FPGA-based brain-computer interface for wireless electric wheelchairs”, *Applied Mechanics and Materials*, vol. 284-287, pp. 1616-1621, 2013. doi: 10.4028/www.scientific.net/AMM.284-287.1616
- [205] J. Lin, M. Wang, C. Hsieh, “An SSVEP-Based BCI System with SOPC Platform for Electric Wheelchairs”, *Transactions on Computer Science and Technology*, vol. 3, no. 2, 2014.
- [206] S. Wu, Y. Liu, T. Hsieh, Y. Lin, C. Chen, C. Chuang, C. Lin, “Fuzzy Integral with Particle Swarm Optimization for a Motor-Imagery-based Brain-Computer Interface”,

- IEEE Trans. Fuzzy Systems*, vol. 25, no. 1, pp. 21-28, 2017. doi: 10.1109/TFUZZ.2016.2598362
- [207] A. Doud, J. Lucas, M. Pisansky, H. Bin, “Continuous Three-Dimensional Control of a Virtual Helicopter Using a Motor Imagery Based Brain-Computer Interface”, *Plos ONE*, vol. 6, no. 10, 2011. doi: 10.1371/journal.pone.0026322
- [208] *Xilinx DS312 Spartan-3E FPGA Family Data Sheet*, Xilinx, Inc., 2013. Disponível em xilinx.com/support/documentation/data_sheets/ds312.pdf. Acessado em 19 nov. 2017.
- [209] *EEG Hardware Platforms*, NeuroSky, 2017. Disponível em neurosky.com/biosensors/eeg-sensor/biosensors/. Acessado em 19 nov. 2017.
- [210] *SAM3X / SAM3A Series - Atmel / SMART ARM-based MCU Datasheet*, Atmel, 2015. Disponível em atmel.com/Images/Atmel-11057-32-bit-Cortex-M3-Microcontroller-SAM3X-SAM3A_Datasheet.pdf. Acessado em 19 nov. 2017.
- [211] L. Liao, S. Wu, C. Liou, S. Lu, S. Chen, S. Chen, “A Novel 16-Channel Wireless System for Electroencephalography Measurements With Dry Spring-Loaded Sensors”, *IEEE Trans. Instrument. Measure.*, vol. 63, pp. 1545-1555, 2014.
- [212] C. Lin, L. Liao, Y. Liu, I. Wang, B. Lin, J. Chang, “Novel Dry Polymer Foam Electrodes for Long-Term EEG Measurement”, *IEEE Trans. Biomed. Eng.*, vol. 58, pp. 1200-1207, 2011.
- [213] G. Schalk, D. McFarland, T. Hinterberger, N. Birbaumer, J. Wolpaw, “BCI2000: a general-purpose brain-computer interface (BCI) system”, *IEEE Trans. Biomed. Eng.*, vol. 51, pp. 1034-1043, 2004.
- [214] S. Gordleeva, M. Lukoyanov, S. Mineev, M. Khoruzhko, V. Mironov, A. Kaplan, V. Kazantsev, “Exoskeleton Control System Based on Motor-Imaginary Brain-Computer Interface”, *MODERN TECHNOLOGIES IN MEDICINE* (eng.), vol. 9, no. 3, 2017. Disponível em cyberleninka.ru/article/n/exoskeleton-control-system-based-on-motor-imaginary-brain-computer-interface. Acessado em 12 nov. 2017. doi: 10.17691/stm2017.9.3.04
- [215] M. G. N. M. Silva, “Redes neurais artificiais para o reconhecimento de padrões de EEG durante o movimento e imaginação do movimento das mãos”, Tese de Doutorado, Centro de Tecnologia e Geociências, Univ. Federal de Pernambuco, Recife, 2014.

- [216] *INA12x Precision, Low Power Instrumentation Amplifiers*, Texas Instruments, 2015. Disponível em ti.com/lit/ds/symlink/ina129.pdf. Acessado em 21 out. 2017.
- [217] R. Sallen, E. Key, “A practical method of designing RC active filters”, *IRE Transactions on Circuit Theory*, vol. 2, no. 1, pp. 74-85, 1955. doi: 10.1109/TCT.1955.6500159
- [218] “Analog filters”, em *Basic Linear Design*, H. Zumbahlen ed. Analog Devices, Inc, 2007. ISBN 0-916550-28-1. Disponível em analog.com/media/en/training-seminars/design-handbooks/Basic-Linear-Design/Basic_Linear_Design.zip. Acessado em 22 out. 2017.
- [219] *TLC272, TLC272A, TLC272B, TLC272Y, TLC277 LinCMOS PRECISION DUAL OPERATIONAL AMPLIFIERS*, Texas Instruments, 2002. Disponível em ti.com/lit/ds/symlink/tlc272a.pdf. Acessado em 21 out. 2017.
- [220] *13-Bit Differential Input, Low Power A/D Converter with SPI Serial Interface*, Microchip Technology Inc. 2008. Disponível em microchip.com/downloads/en/DeviceDoc/21697e.pdf. Acessado em 29 set. 2015.
- [221] *DE0 User Manual*, Terasic Technologies, 2011. Disponível em terasic.com.tw/cgi-bin/page/archive_download.pl?Language=English&No=364&FID=0c266381d75ef92a8291c5bbdd5b07eb. Acessado em 29 set. 2015.
- [222] Terasic Technologies Inc. Disponível em terasic.com.tw/en/. Acessado em 21 out. 2017.
- [223] A. Hasnat, T. Bhattacharyya, A. Dey, S. Halder, D. Bhattacharjee, “A fast FPGA based architecture for computation of square root and Inverse Square Root”, em *2017 Devices for Integrated Circuit (DevIC)*, Kalyani, 2017, pp. 383-387. doi: 10.1109/DEVIC.2017.8073975
- [224] M. Parker, “Hardware-Based Floating-Point Design Flow”, Altera Corporation, 2011. Disponível em https://www.altera.com/content/dam/altera-www/global/en_US/pdfs/literature/wp/designcon2011-floating-point-design-flow.pdf. Acessado em 9 nov. 2017.
- [225] K. Arun, K. Srivatsan, “A binary high speed floating point multiplier”, em *2017 Int. Conf. Nextgen Electronic Technologies: Silicon to Software (ICNETS2)*, Chennai, 2017, pp. 316-321. doi: 10.1109/ICNETS2.2017.8067953
- [226] M. Athira Menon, R. Renjith, “Implementation of 24 bit high speed floating point vedic multiplier”, em *2017 Int. Conf. Networks & Advances in Computational Technologies (NetACT)*, Thiruvanthapuram, 2017, pp. 453-457. doi: 10.1109/NETACT.2017.8076814

- [227] P. Diez, V. Mut, E. Laciari, E. Avila, “A comparison of monopolar and bipolar EEG recordings for SSVEP detection”, *Int. Conf. IEEE Engineering in Medicine and Biology*, Buenos Aires, 2010, pp. 5803-5806. doi: 10.1109/IEMBS.2010.5627451
- [228] H. M. de Oliveira, *Análise de Fourier e Wavelets: Sinais Estacionários e não Estacionários*. Editora Universitária – UFPE, 2007.
- [229] D. Maraun, J. Kurths, M. Holschneider, “Nonstationary Gaussian processes in wavelet domain: Synthesis, estimation, and significance testing”, *Physical Review E*, vol 75, ed. 1, 2007. doi: 10.1103/PhysRevE.75.016707
- [230] C. Chiann, P. A. Morettin, “A wavelet analysis for time series”, *Journal of Nonparametric Statistics*, vol. 10, no. 1, pp. 1-46, 1998. doi: zurl10.1080/10485259808832752
- [231] P. S. Addison, “Wavelet transforms and the ECG: a review”, *Physiological Measurement*, vol. 26, pp. R155-R199, 2005.
- [232] J. T. Bialasiewicz, “Application of Wavelet Scalogram and Coscalogram for Analysis of Biomedical Signals”, *Proc. World Congress on Electrical Engineering and Computer Systems and Science (EECSS 2015)*, Barcelona, Spain, 2015.
- [233] M. Clerc, S. Mallat, “The Texture Gradient Equation for Recovering Shape from Texture”, *IEEE Trans. Pattern Analysis Machine Intelligence*, vol. 24, no. 4, 2002.
- [234] Z. Peng, F. Chu, Y. He, “Vibration Signal Analysis And Feature Extraction Based On Reassigned Wavelet Scalogram”, *Journal of Sound and Vibration*, vol. 253, no. 5, pp. 1087-1100, 2002. doi: doi.org/10.1006/jsvi.2001.4085
- [235] P. S. Addison, J. N. Watson, T. Feng, “Low-Oscillation Complex Wavelets”, *Journal Of Sound And Vibration*, vol. 254, no. 4, pp. 733-762, 2002. doi: dx.doi.org/10.1006/jsvi.2001.4119
- [236] V. Bostanov, “BCI Competition 2003 – Data Sets Ib and IIb: Feature Extraction From Event-Related Brain Potentials With the Continuous Wavelet Transform and the t-Value Scalogram”, *IEEE Trans. Biomedical Engineering*, vol. 51, no. 6, 2004. doi: 10.1109/TBME.2004.826702
- [237] R. Anderson, M. Sandsten, “Stochastic Modelling and Optimal Spectral Estimation of EEG signals”, em *EMBECE & NBC 2017 – IFMBE Proceedings*, H. Eskola, O. Väisänen, J. Viik, J. Hyttinen eds., vol. 65. Springer, Singapore. doi: doi.org/10.1007/978-981-10-5122-7_227
- [238] D. M. Cestari, J. Rosa, “Stochastic and deterministic stationarity analysis of EEG data”, em *2017 Int. J. Conf. Neural Networks (IJCNN)*, Anchorage, AK, 2017, pp. 63-70. doi: 10.1109/IJCNN.2017.7965837

- [239] M. Paluš, “Nonlinearity in normal human EEG: cycles, temporal asymmetry, nonstationarity and randomness, not chaos”, *Biological Cybernetics*, vol. 75, no. 5, pp 389-396, 1996. doi: doi.org/10.1007/s004220050304D0
- [240] P. Sovilj, S. Milovancev, V. Vujcic, “Digital Stochastic Measurement of a Nonstationary Signal With an Example of EEG Signal Measurement”, *IEEE Trans. Instrumentation and Measurement*, vol. 60, no. 9, pp. 3230-3232, 2011. doi: [10.1109/TIM.2011.2128670](https://doi.org/10.1109/TIM.2011.2128670)
- [241] M. A. Ariño, P. A. Morettin, B. Vidakovic, “Wavelet scalograms and their applications in economic time series”, *Brazilian Journal of Probability and Statistics*, vol. 18, pp. 37-51, 2004.
- [242] C. Torrence, G. P. Compo, “A Practical Guide to Wavelet Analysis”, *Bulletin of the American Meteorological Society*, vol. 79, no. 1, pp. 61-78, 1998. doi: [10.1175/1520-0477\(1998\)079<0061:APGTWA>2.0.CO;2](https://doi.org/10.1175/1520-0477(1998)079<0061:APGTWA>2.0.CO;2)
- [243] P. Abry, P. Gonçalvès, P. Flandrin, “Wavelets, spectrum analysis and 1/f processes”, in *Wavelets and Statistics*, A. Antoniadis e G. Oppenheim, Eds. Springer, 1995, pp. 15-29. doi: doi.org/10.1007/978-1-4612-2544-7_2
- [244] A. Hossen, “Power spectral density estimation via wavelet decomposition”, *Electronics Letters*, vol. 40, no. 17, 2004.
- [245] D. B. Percival, “On estimation of the wavelet variance”, *Biometrika*, vol. 82, no. 3, pp. 619-631, 1995. doi: doi.org/10.1093/biomet/82.3.619
- [246] Y. Liu, X. Liang, R. Weisberg, “Rectification of the Bias in the Wavelet Power Spectrum”, *Journal of Atmospheric and Oceanic Technology*, vol. 24, pp. 2093-2101, 2007. doi: [10.1175/2007JTECH0511.1](https://doi.org/10.1175/2007JTECH0511.1)
- [247] B. Rebsamen, E. Burdet, C. Guan, C. L. Teo, Q. Zeng, M. Ang, C. Laugier, “Controlling a wheelchair using a BCI with low information transfer rate”, *2007 IEEE 10th Int. Conf. Rehabilitation Robotics*, Noordwijk, 2007, pp. 1003-1008. doi: [10.1109/ICORR.2007.4428546](https://doi.org/10.1109/ICORR.2007.4428546)
- [248] G. Pfurtscheller, G. R. Muller-Putz, J. Pfurtscheller, R. Rupp, “EEG-Based Asynchronous BCI Controls Functional Electrical Stimulation in a Tetraplegic Patient”, *EURASIP Journal on Applied Signal Processing*, vol. 19, pp. 3152-3155, 2005.
- [249] Z. Tang, C. Li, S. Sun, “Single-trial EEG classification of motor imagery using deep convolutional neural networks”, *Optik – International Journal for Light and Electron Optics*, vol. 130, pp. 11-18, 2017.

- [250] L. Gao, J. Wang, L. Chen, “Event-related desynchronization and synchronization quantification in motor-related EEG by Kolmogorov entropy”, *Journal of Neural Engineering*, vol. 10, 2013. doi: 10.1088/1741-2560/10/3/036023
- [251] B. Graimann, G. Pfurtscheller, “Quantification and visualization of event-related changes in oscillatory brain activity in the time-frequency domain”, em *Progress in Brain Research*, Neuper e Klimesch, Eds. Elsevier B.V., 2006, pp. 79-97. ISSN 0079-6123
- [252] G. Pfurtscheller and A. Aranibar, “Event-related Cortical Desynchronization Detected by Power Measurements of Scalp EEG”, *Electroencephalography and Clinical Neurophysiology*, vol. 42, pp. 817-826, 1977. doi: doi.org/10.1016/0013-4694(77)90235-8
- [253] G. Pfurtscheller, A. Aranibar, “Evaluation of event-related desynchronization (ERD) preceding and following voluntary self-paced movement”, *Electroencephalography and Clinical Neurophysiology*, vol. 46, no. 2, pp. 138-146, 1979. doi: doi.org/10.1016/0013-4694(79)90063-4
- [254] J. Kalcher, G. Pfurtscheller, “Discrimination between phase-locked and non-phase-locked event-related EEG activity”, *Electroencephalography and Clinical Neurophysiology*, vol. 94, no. 5, pp. 381-384, 1995. doi: doi.org/10.1016/0013-4694(95)00040-6
- [255] R. Leeb, F. Lee, C. Keinrath, R. Scherer, H. Bischof, G. Pfurtscheller. “Brain-computer communication: motivation, aim, and impact of exploring a virtual apartment”, *IEEE Trans. Neural Systems and Rehabilitation Engineering*, vol. 15, pp. 473-482, 2007. doi: 10.1109/TNSRE.2007.906956
- [256] G. Pfurtscheller, C. Brunner, A. Schlögl, F. H. L. da Silva, “Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks”, *NeuroImage*, vol. 31, pp. 153-159, 2006. doi: 10.1016/j.neuroimage.2005.12.003
- [257] G. Pfurtscheller, C. Neuper, D. Flotzinger, M. Pregenzer, “EEG-based discrimination between imagination of right and left hand movement”, *Electroencephalography and clinical Neurophysiology*, vol. 103, pp. 642-651, 1997. doi: 10.1016/S0013-4694(97)00080-1
- [258] W. Yi, S. Qiu, H. Qi, L. Zhang, B. Wan, D. Ming, “EEG feature comparison and classification of simple and compound limb motor imagery”, *Journal of NeuroEngineering and Rehabilitation*, vol. 10. 2013. doi: doi.org/10.1186/1743-0003-10-106

- [259] C. Neuper, G. Pfurtscheller, “Event-related dynamics of cortical rhythms: frequency-specific features and functional correlates”, *Int. Journal of Psychophysiology*, vol. 43, pp. 41-58, 2001. doi: [doi.org/10.1016/S0167-8760\(01\)00178-7](https://doi.org/10.1016/S0167-8760(01)00178-7)
- [260] G. Pfurtscheller, C. Neuper, C. Guger, W. Harkam, H. Ramoser, A. Schlögl, B. Obermaier, M. Pregenzer, “Current trends in Graz Brain-Computer Interface (BCI) research”, *IEEE Trans. Rehabilitation Engineering*, vol. 8, no. 2, pp. 216-219, 2000. doi: [10.1109/86.847821](https://doi.org/10.1109/86.847821)
- [261] M. Bascil, A. Tesneli, F. Temurtas, “Multi-channel EEG signal feature extraction and pattern recognition on horizontal mental imagination task of 1-D cursor movement for brain computer interface”, *Australasian Physical and Engineering Sciences in Medicine*, vol. 38, no. 2, pp. 229-239, 2015. doi: [10.1007/s13246-015-0345-6](https://doi.org/10.1007/s13246-015-0345-6)
- [262] J. Sleight, P. Pillai, S. Mohan, “Classification of Executed and Imagined Motor Movement EEG Signals”, 2009. Disponível em web.eecs.umich.edu/~cscott/past_courses/eecs545f09/projects/MohanPillaiSleight.pdf. Acessado em 5 nov. 2017.
- [263] *Low Power, 3.3 V, RS-232 Line Drivers/Receivers*, Analog Devices Inc. 2011. Disponível em analog.com/media/en/technical-documentation/data-sheets/ADM3202_3222_1385.pdf. Acessado em 29 set. 2015.
- [264] *HC-05 Bluetooth Module User's Manual v1.0*. Disponível em <https://www.gme.cz/data/attachments/dsh.772-148.1.pdf>. Acessado em 21 nov. 2017.
- [265] *The On-line Encyclopedia of Integer Sequences*. Disponível em oeis.org/A033484. Acessado em 14 jun. 2016.
- [266] M. Sai Kumar, D. A. Kumar and P. Samundiswary, “Design and performance analysis of Multiply-Accumulate (MAC) unit”, *Int. Conf. on Circuits, Power and Computing Technologies (ICCPCT-2014)*, 2014, pp. 1084-1089. doi:[10.1109/ICCPCT.2014.7054782](https://doi.org/10.1109/ICCPCT.2014.7054782)
- [267] M. Cieplucha, “High performance FPGA-based implementation of a parallel multiplier-accumulator”, *20th Proc. Int. Conf. Mixed Design of Integrated Circuits and Systems – MIXDES 2013*, Gdynia, 2013, pp. 485-489. ISBN 978-83-63578-02-2
- [268] BNCI Horizon 2020. Disponível em bnci-horizon-2020.eu/database/data-sets. *Data set “A”* disponível em bnci-horizon-2020.eu/database/data-sets/004-2015/A.mat. *Data set “C”* disponível em bnci-horizon-2020.eu/database/data-sets/004-2015/C.mat. Acessados em 11 nov. 2016.

- [269] M. Abramowitz, I. Stegun, *Handbook of Mathematical Functions with Formulas, Graphs, and Mathematical Tables*, 9^a ed. NBS, 1972, pp. 14.
- [270] R. E. Warpole, R. H. Myers, S. L. Myers, K. Ye, *Probability & Statistics for Engineers & Scientists*, 9^a ed. Prentice Hall, 2012.
- [271] BNCI Horizon 2020. Disponível em bnci-horizon-2020.eu/database/data-sets. *Data set* “B01T” disponível em bnci-horizon-2020.eu/database/data-sets/004-2014/B01T.mat. *Data set* “B02T” disponível em bnci-horizon-2020.eu/database/data-sets/004-2014/B02T.mat. *Data set* “B03T” disponível em bnci-horizon-2020.eu/database/data-sets/004-2014/B03T.mat. Acessados em 21 abr. 2017.
- [272] “BCI Competition 2008 – Graz data set B”. Disponível em bnci-horizon-2020.eu/database/data-sets/005-2014/description.pdf. Acessado em 21 abr. 2017.
- [273] *SHAP Southampton Hand Assessment Procedure*, SHAP Business Enterprise – University of Southampton. Disponível em shap.ecs.soton.ac.uk/files/protocol.pdf. Acessado em 21 nov. 2017.

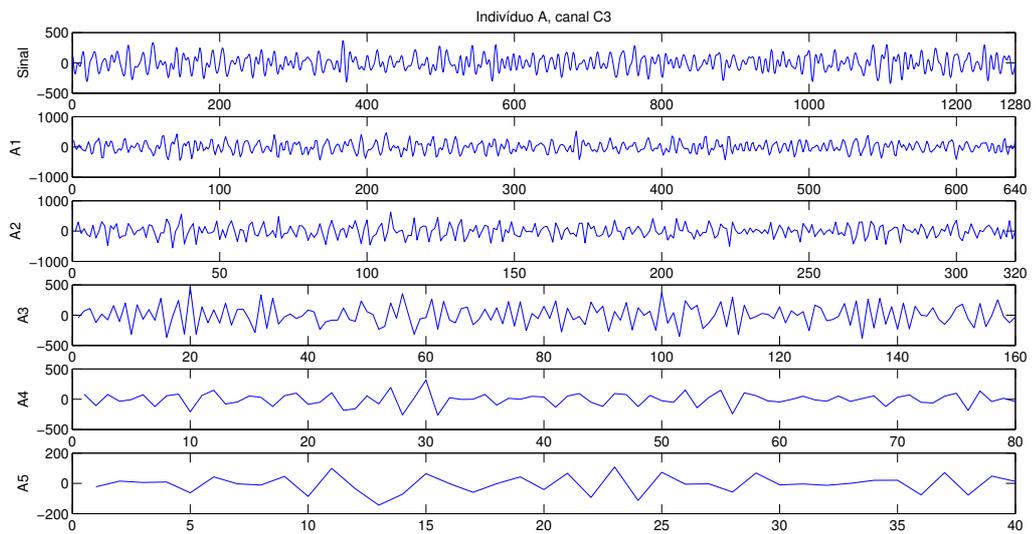
APÊNDICE A -TABELAS COMPARATIVAS ENTRE OS CÁLCULOS DO ALGORITMO DO FPGA E DO MATLAB

Neste apêndice são detalhadas as decomposições em *wavelets* executadas pelo algoritmo no FPGA e comparadas com os cálculos do Matlab. Foram processadas duas amostras do canal C3 de dois indivíduos da base de dados BNCI Horizon 2020 [268], chamados “A” e “C”, totalizando quatro sinais. Neste primeiro momento foram comparados os coeficientes da decomposição em *wavelets* Daubechies-4. Posteriormente, no decorrer desta pesquisa, serão comparados a capacidade de reconhecer movimento da mão com esta e outras bases de dados. Os resultados são ilustrados nas Fig. .1 até .5.

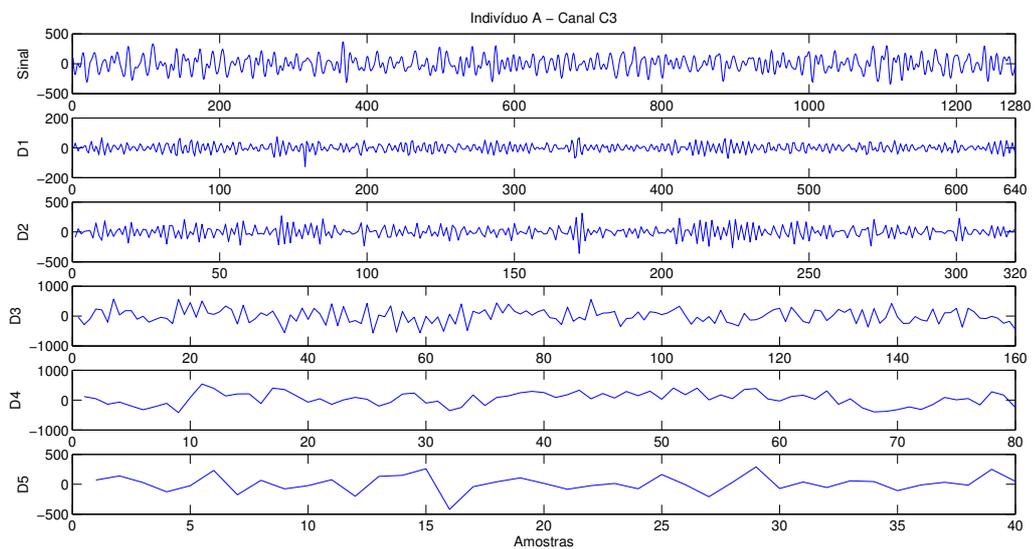
Para avaliar o funcionamento do sistema protótipo foi adquirido o canal O2 de um voluntário chamado “D”, utilizando a placa analógica desenvolvida e o processamento no FPGA. Os resultados são exibidos na Fig. .5.

A comparação ponto a ponto dos coeficientes do FPGA com o Matlab está na Tabela .1 até .5, incluindo os erros absolutos, para as ondas de interesse β , α , θ e δ .

Figura .1 – Canal C3 do indivíduo A decomposto em *wavelets*, amostra 1: coeficientes de (a) aproximação e (b) detalhe.



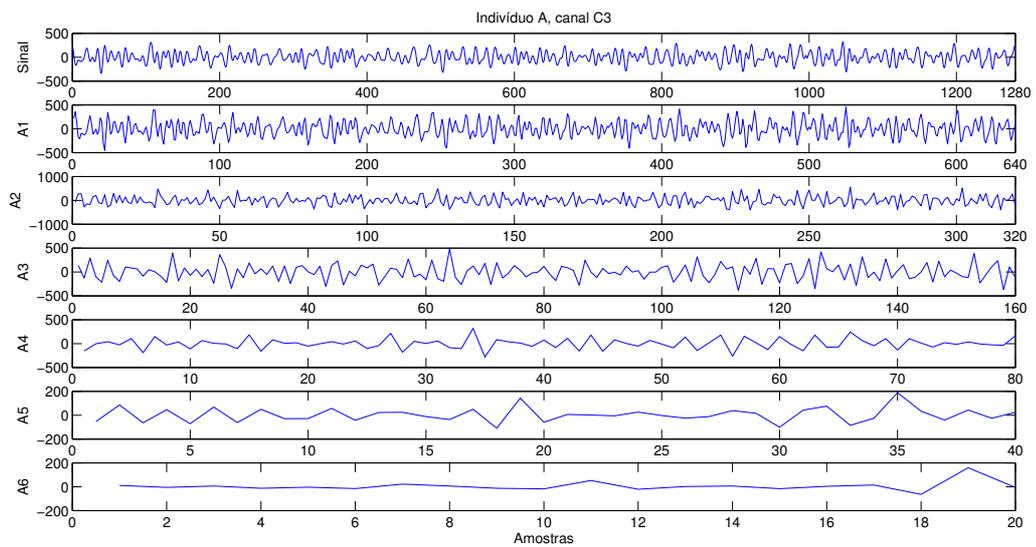
(a)



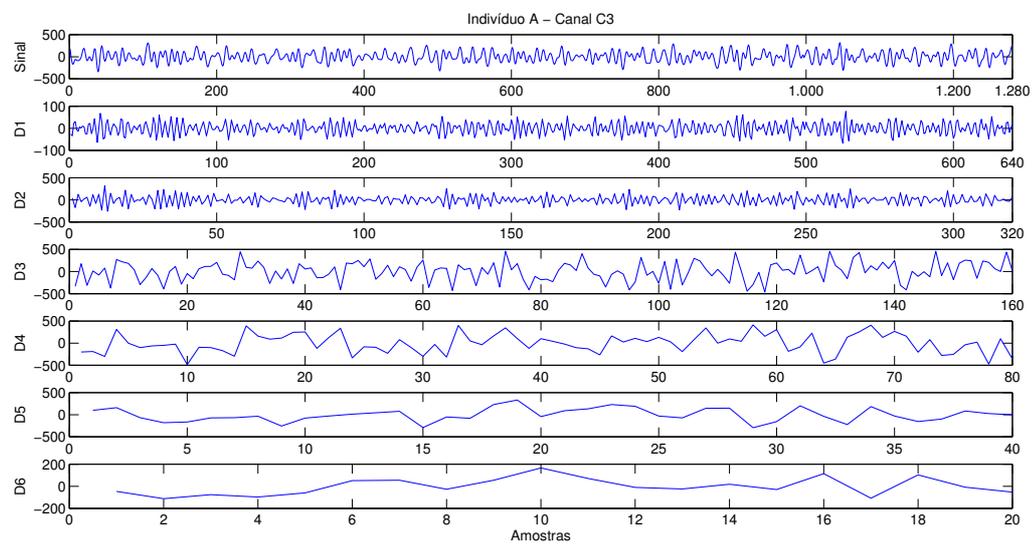
(b)

Fonte: autor.

Figura .2 – Canal C3 do indivíduo A decomposto em *wavelets*, amostra 2: coeficientes de (a) aproximação e (b) detalhe.



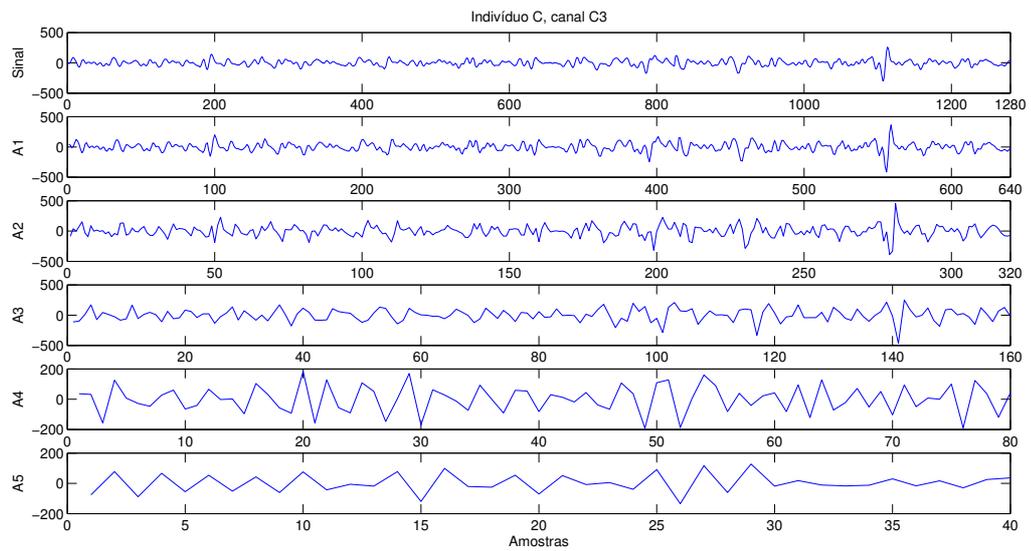
(a)



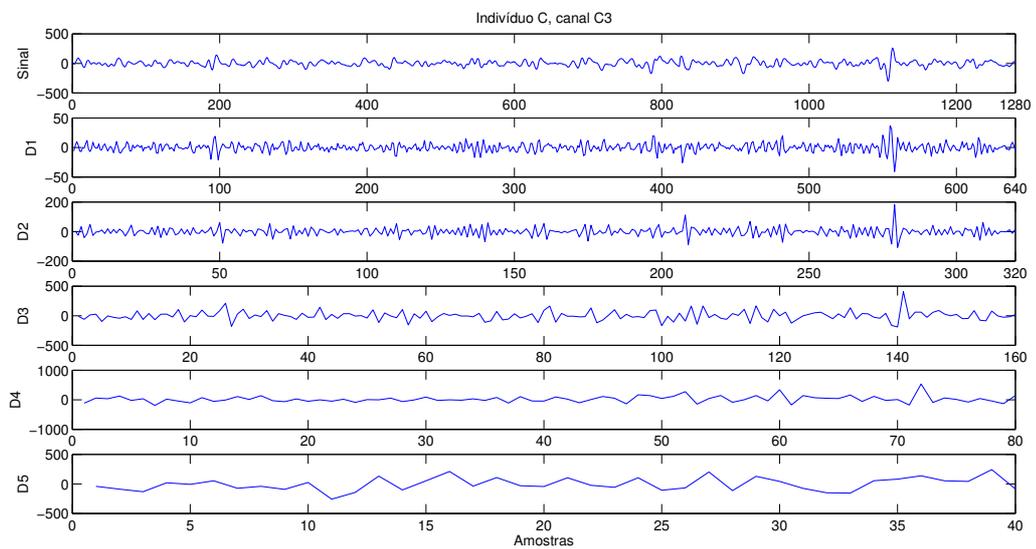
(b)

Fonte: autor.

Figura .3 – Canal C3 do indivíduo C decomposto em *wavelets*, amostra 1: coeficientes de (a) aproximação e (b) detalhe.



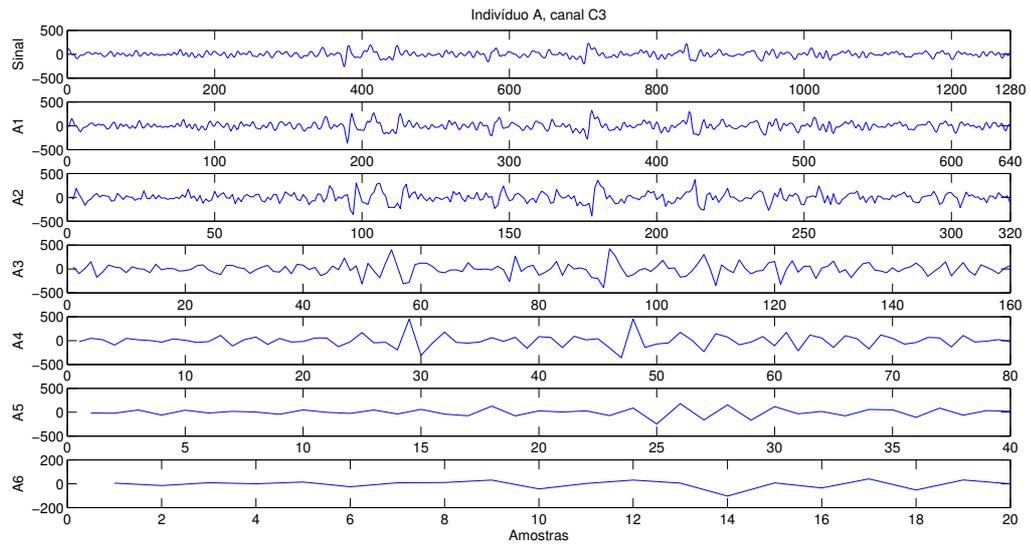
(a)



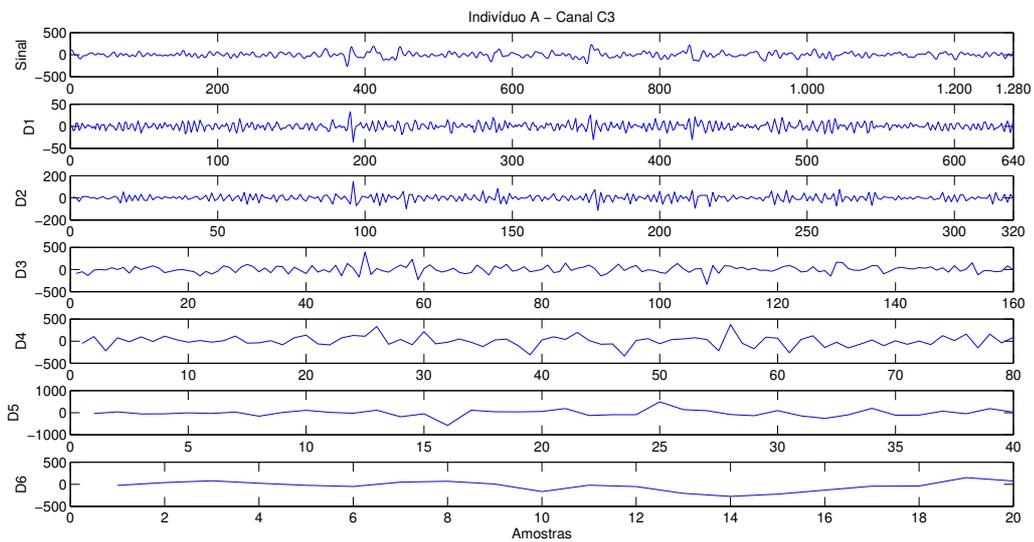
(b)

Fonte: autor.

Figura .4 – Canal C3 do indivíduo C decomposto em *wavelets*, amostra 2: coeficientes de (a) aproximação e (b) detalhe.



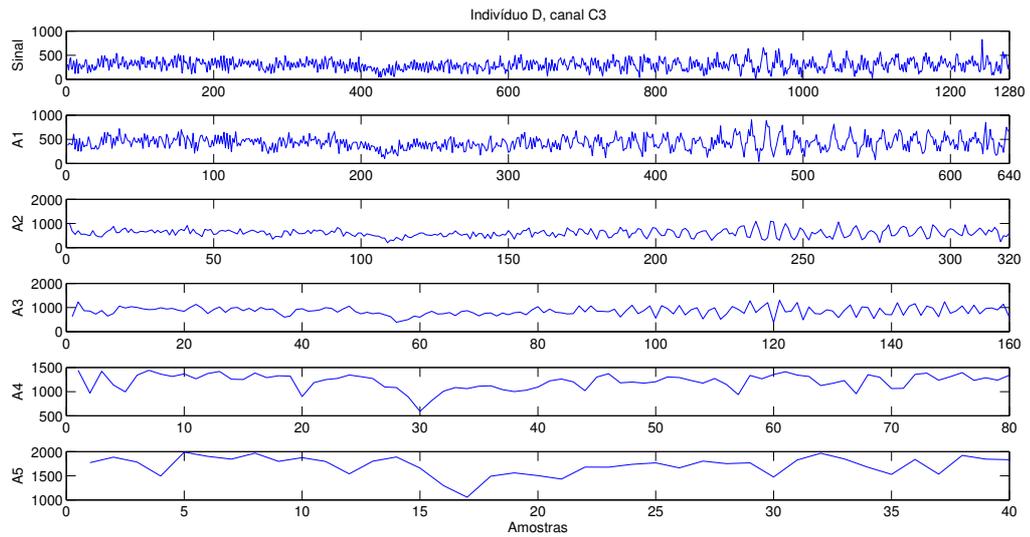
(a)



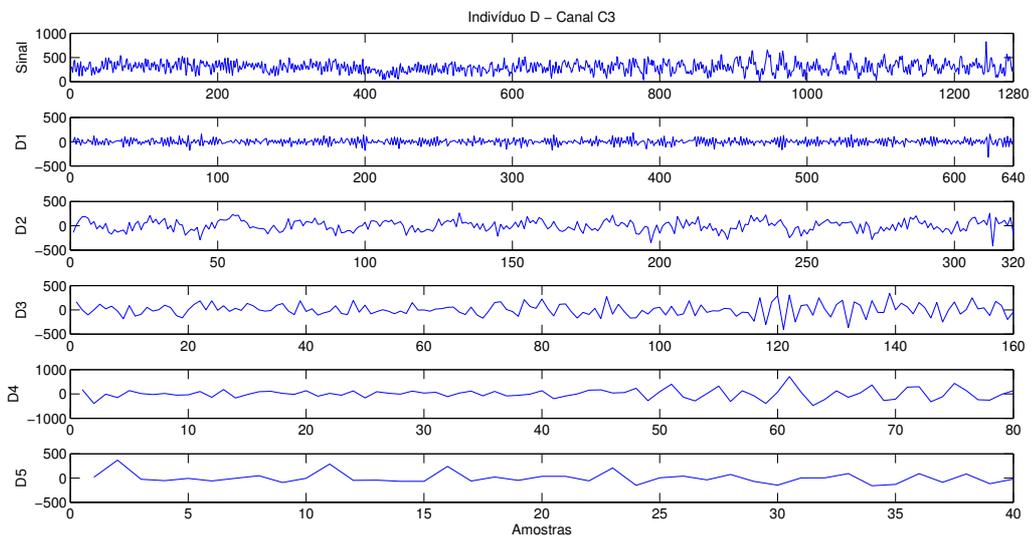
(b)

Fonte: autor.

Figura .5 – Canal O2 do indivíduo D decomposto em *wavelets*: coeficientes de (a) aproximação e (b) detalhe.



(a)



(b)

Fonte: autor.

Tabela .1 – Comparação ponto a ponto dos coeficientes β , α , θ e δ do indivíduo A, amostra 1.

β			α			θ			δ		
D4	cD4	$\Delta D4$	D5	cD5	$\Delta D5$	D6	cD6	$\Delta D6$	A6	cA6	$\Delta A6$
-198	-199	1	-24	-25	1	36	37	-1	9	10	-1
-323	-323	0	231	231	0	129	129	0	1	1	0
-221	-222	1	-176	-176	0	-28	-29	1	52	52	0
-110	-110	0	66	66	0	55	55	0	-162	-162	0
-416	-416	0	-77	-78	1	-22	-22	0	26	26	0
87	88	-1	-23	-23	0	8	9	-1	-57	-57	0
537	538	-1	76	76	0	76	76	0	17	17	0
394	395	-1	-200	-200	0	139	140	-1	1	2	-1
137	137	0	131	132	-1	142	142	0	10	11	-1
208	209	-1	150	151	-1	4	4	0	6	6	0
211	212	-1	260	260	0	80	80	0	-27	-28	1
-115	-115	0	-421	-421	0	15	15	0	28	29	-1
400	401	-1	-41	-42	1	8	9	-1	-11	-12	1
356	357	-1	41	42	-1	-8	-8	0	-4	-5	1
143	144	-1	106	107	-1	105	106	-1	1	1	0
-68	-69	1	14	14	0	94	95	-1	0	-1	1
45	45	0	-84	-84	0						
-142	-143	1	-23	-23	0						
6	7	-1	13	13	0						
93	93	0	-75	-75	0						
28	29	-1	162	163	-1						
-199	-200	1	-6	-6	0						
-77	-78	1	-209	-210	1						
202	203	-1	33	34	-1						
237	237	0	290	291	-1						
-97	-97	0	-71	-71	0						
-35	-35	0	37	37	0						
-350	-351	1	-55	-55	0						
-245	-246	1	57	57	0						
170	171	-1	44	44	0						
-180	-180	0	-106	-107	1						
89	89	0	-12	-13	1						
140	141	-1	33	33	0						
245	246	-1	-14	-14	0						

Tabela .2 – Comparação ponto a ponto dos coeficientes β , α , θ e δ do indivíduo A, amostra 2.

β			α			θ			δ		
D4	cD4	$\Delta D4$	D5	cD5	$\Delta D5$	D6	cD6	$\Delta D6$	A6	cA6	$\Delta A6$
-2	-3	1	-166	-167	1	-60	-61	1	-4	-4	0
-101	-101	0	-72	-73	1	51	51	0	-15	-15	0
-63	-63	0	-67	-68	1	55	56	-1	22	22	0
-49	-50	1	-34	-34	0	-27	-27	0	6	6	0
-23	-23	0	-256	-256	0	55	56	-1	-13	-14	1
-485	-486	1	-76	-76	0	166	167	-1	-18	-19	1
-95	-96	1	-29	-29	0	71	71	0	52	53	-1
-100	-101	1	13	14	-1	-10	-11	1	-21	-22	1
-171	-172	1	44	44	0	-24	-25	1	2	3	-1
-296	-296	0	76	77	-1	18	18	0	6	6	0
389	389	0	-290	-291	1	-30	-30	0	-16	-16	0
160	160	0	-52	-52	0	114	115	-1	4	4	0
89	90	-1	-80	-81	1	-108	-109	1	14	15	-1
114	114	0	230	230	0	103	103	0	-64	-65	1
246	247	-1	333	334	-1	-8	-9	1	159	159	0
252	253	-1	-43	-43	0	-53	-54	1	-5	-5	0
-118	-118	0	90	90	0						
123	123	0	132	132	0						
336	337	-1	230	230	0						
-334	-334	0	191	192	-1						
-83	-84	1	-30	-31	1						
-94	-95	1	-72	-72	0						
-231	-232	1	146	147	-1						
80	81	-1	148	148	0						
-101	-101	0	-295	-296	1						
-299	-299	0	-156	-157	1						
-31	-31	0	201	202	-1						
-316	-317	1	-36	-37	1						
398	398	0	-223	-223	0						
51	52	-1	184	184	0						
-37	-37	0	-30	-30	0						
164	164	0	-154	-154	0						
346	347	-1	-98	-98	0						
103	104	-1	84	85	-1						

Tabela .3 – Comparação ponto a ponto dos coeficientes β , α , θ e δ do indivíduo C, amostra 1.

β			α			θ			δ		
D4	cD4	$\Delta D4$	D5	cD5	$\Delta D5$	D6	cD6	$\Delta D6$	A6	cA6	$\Delta A6$
-20	-21	1	-8	-8	0	-69	-70	1	1	1	0
36	36	0	52	53	-1	-92	-93	1	-6	-7	1
-191	-191	0	-74	-74	0	-3	-4	1	1	1	0
20	20	0	-40	-41	1	-128	-128	0	14	14	0
-46	-47	1	-92	-93	1	-109	-110	1	-37	-37	0
-105	-106	1	24	25	-1	55	56	-1	17	17	0
73	73	0	-258	-258	0	92	93	-1	10	10	0
-56	-57	1	-144	-145	1	12	13	-1	6	7	-1
-7	-8	1	132	132	0	76	77	-1	-20	-20	0
108	108	0	-102	-103	1	184	185	-1	11	12	-1
13	13	0	52	53	-1	121	122	-1	3	3	0
137	138	-1	210	211	-1	45	46	-1	71	72	-1
-31	-32	1	-37	-38	1	2	2	0	6	6	0
-66	-67	1	107	107	0	19	20	-1	-26	-27	1
29	29	0	-31	-32	1	27	28	-1	13	14	-1
-50	-50	0	-44	-45	1	38	39	-1	-3	-4	1
-1	-2	1	103	104	-1						
-49	-50	1	-24	-24	0						
19	19	0	-58	-58	0						
-89	-90	1	104	104	0						
6	7	-1	-107	-108	1						
-3	-3	0	-67	-68	1						
54	54	0	202	203	-1						
-60	-61	1	-113	-113	0						
-5	-6	1	129	129	0						
90	90	0	43	43	0						
-21	-21	0	-75	-76	1						
-2	-3	1	-150	-150	0						
-15	-15	0	-156	-157	1						
33	33	0	54	55	-1						
-20	-21	1	81	81	0						
78	78	0	137	137	0						
-111	-111	0	53	53	0						
106	107	-1	43	44	-1						

Tabela .4 – Comparação ponto a ponto dos coeficientes β , α , θ e δ do indivíduo C, amostra 2.

β			α			θ			δ		
D4	cD4	$\Delta D4$	D5	cD5	$\Delta D5$	D6	cD6	$\Delta D6$	A6	cA6	$\Delta A6$
-14	-15	1	-8	-8	0	-23	-24	1	14	14	0
96	97	-1	-33	-34	1	-51	-52	1	-25	-25	0
-7	-8	1	30	30	0	48	49	-1	8	9	-1
112	113	-1	-156	-156	0	67	68	-1	10	10	0
33	33	0	9	9	0	5	5	0	31	31	0
-25	-26	1	110	110	0	-165	-166	1	-43	-44	1
14	15	-1	16	16	0	-22	-22	0	2	3	-1
-23	-23	0	-26	-27	1	-52	-53	1	31	31	0
10	11	-1	115	116	-1	-205	-205	0	5	6	-1
115	116	-1	-185	-186	1	-274	-275	1	-103	-103	0
-46	-46	0	-52	-53	1	-223	-223	0	7	7	0
-38	-38	0	-576	-576	0	-132	-132	0	-35	-36	1
11	12	-1	112	112	0	-43	-44	1	41	42	-1
-84	-85	1	41	41	0	-38	-39	1	-52	-52	0
77	78	-1	36	36	0	151	151	0	32	33	-1
135	135	0	57	57	0	74	74	0	0	1	-1
-64	-64	0	188	189	-1						
-86	-87	1	-127	-128	1						
73	74	-1	-93	-93	0						
128	128	0	-93	-93	0						
111	112	-1	493	493	0						
329	330	-1	141	141	0						
-73	-74	1	91	91	0						
38	39	-1	-84	-84	0						
-82	-82	0	-134	-135	1						
215	216	-1	94	94	0						
-60	-61	1	-143	-143	0						
-26	-27	1	-261	-261	0						
48	49	-1	-97	-98	1						
-26	-26	0	198	198	0						
-124	-124	0	-112	-112	0						
26	26	0	-110	-110	0						
45	46	-1	67	68	-1						
-103	-104	1	-46	-47	1						

Tabela .5 – Comparação ponto a ponto dos coeficientes β , α , θ e δ do indivíduo D.

β			α			θ			δ		
D4	cD4	$\Delta D4$	D5	cD5	$\Delta D5$	D6	cD6	$\Delta D6$	A6	cA6	$\Delta A6$
-148	-148	0	-54	-55	1	-60	-60	0	2573	2574	-1
139	139	0	-8	-9	1	-119	-120	1	2670	2670	0
15	15	0	-60	-60	0	-44	-44	0	2644	2644	0
-24	-24	0	-5	-5	0	226	226	0	2520	2520	0
22	22	0	48	49	-1	-175	-176	1	2459	2460	-1
-50	-51	1	-92	-93	1	41	42	-1	2455	2455	0
-37	-38	1	-5	-6	1	-88	-88	0	1641	1641	0
99	100	-1	289	289	0	-23	-23	0	2177	2177	0
-139	-140	1	-47	-47	0	-79	-80	1	2083	2084	-1
180	181	-1	-44	-44	0	-5	-6	1	2374	2375	-1
-165	-166	1	-67	-67	0	99	99	0	2456	2457	-1
-23	-24	1	-67	-67	0	7	8	-1	2476	2477	-1
92	93	-1	239	239	0	271	272	-1	2419	2419	0
111	111	0	-62	-62	0	-152	-152	0	2440	2441	-1
24	25	-1	21	21	0	6	6	0	2673	2674	-1
-17	-18	1	-47	-47	0	-237	-238	1	2301	2302	-1
132	132	0	36	37	-1	-134	-135	1	2362	2363	-1
-93	-94	1	35	36	-1						
25	25	0	-58	-59	1						
-54	-54	0	208	208	0						
127	127	0	-151	-152	1						
-160	-161	1	6	7	-1						
94	94	0	39	40	-1						
29	29	0	-37	-37	0						
-10	-10	0	73	73	0						
118	118	0	-70	-70	0						
38	38	0	-147	-148	1						
69	69	0	4	4	0						
-111	-111	0	3	4	-1						
35	36	-1	93	93	0						
119	119	0	-158	-159	1						
-76	-77	1	-130	-131	1						
105	106	-1	90	91	-1						
-80	-81	1	-89	-90	1						

