

**UFRRJ**

**INSTITUTO DE CIÊNCIAS EXATAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
MODELAGEM MATEMÁTICA E  
COMPUTACIONAL**

**DISSERTAÇÃO**

**Um Estudo dos Sinais de Eletroencefalograma e  
Eletrodermal no Aprendizado por Reforço de uma  
Interface Cérebro-Máquina**

**Werley de Oliveira Gonçalves**

**2017**



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO**  
**INSTITUTO DE CIÊNCIAS EXATAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM**  
**MATEMÁTICA E COMPUTACIONAL**

**ESTUDO DOS SINAIS DE ELETROENCEFALOGRAMA E**  
**ELETRODERMAL NO APRENDIZADO POR REFORÇO DE UMA**  
**INTERFACE CÉREBRO-MÁQUINA**

**WERLEY DE OLIVEIRA GONÇALVES**

Sob a Orientação da Professora  
**Gizelle Kupac Vianna**

e Co-orientação do Professor  
**Luiz Maltar Castello Branco**

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Ciências**, no Curso de Pós-Graduação em Modelagem Matemática e Computacional, Área Concentração em Modelagem Matemática e Computacional

Seropédica, RJ  
Março de 2017

Universidade Federal Rural do Rio de Janeiro  
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada  
com os dados fornecidos pelo(a) autor(a)

G635e      Gonçalves, Werley de Oliveira, 1982-  
Um Estudo dos Sinais de Eletroencefalograma e  
Eletrodermal no Aprendizado por Reforço de uma  
Interface Cérebro-Máquina / Werley de Oliveira  
Gonçalves. - 2017.  
59 f.: il.

Orientadora: Gizelle Kupac Vianna.  
Coorientador: Luiz Maltar Castello Branco.  
Dissertação (Mestrado). -- Universidade Federal  
Rural do Rio de Janeiro, PROGRAMA DE PÓS-GRADUAÇÃO EM  
MODELAGEM MATEMÁTICA E COMPUTACIONAL, 2017.

1. Interface Cérebro Máquina. 2. Sistemas de  
Controle Inteligentes. 3. Redes Neurais Artificiais.  
4. EEG. 5. Sinal Eletrodermal. I. Vianna, Gizelle  
Kupac, -, orient. II. Branco, Luiz Maltar Castello,  
-, coorient. III Universidade Federal Rural do Rio de  
Janeiro. PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM  
MATEMÁTICA E COMPUTACIONAL. IV. Título.

UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
INSTITUTO DE CIÊNCIAS EXATAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA  
E COMPUTACIONAL

WERLEY DE OLIVEIRA GONÇALVES

Dissertação submetida como requisito parcial para obtenção do grau de Mestre em Ciências,  
no Curso de Pós-Graduação em Modelagem Matemática e Computacional, área de  
Concentração em Modelagem Matemática e Computacional.

DISSERTAÇÃO APROVADA EM 12/07/17 (Data da defesa)



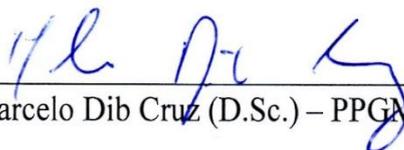
---

Prof<sup>a</sup>. Gizelle Kupac Vianna (D.Sc.) – PPGMMC - UFRRJ  
(Orientador)



---

Prof<sup>a</sup> Rosa Maria Esteves Costa (D.Sc.) – UERJ



---

Marcelo Dib Cruz (D.Sc.) – PPGMMC - UFRRJ

## **Agradecimento**

Agradeço a Deus pela oportunidade de aprendizado que foi este trabalho, a minha família pelo apoio e incentivo por aceitar a minha ausência tanto física quanto de espírito no decorrer dessa jornada em especial ao meu tio Nicacio Sardella.

A orientadora, professora Gizelle Kupac Vianna, e ao co-orientador, professor Luiz Maltar Castello Branco, pelo apoio e por me botar no caminho certo em todo tempo em que estive sob a orientação deles. Também agradeço aos professores Rosa Maria Esteves Costa e Marcelo Dib Cruz pela participação na banca examinadora.

Por fim agradeço a todos os voluntários que dedicaram um pouco do seu tempo para tornar esse trabalho possível.

## RESUMO

GONÇALVES, Werley de Oliveira. **Utilização dos Sinais de Eletroencefalograma e Eletrodermal no Aprendizado por Reforço de uma Interface Cérebro Máquina.** 2017. 59p. Dissertação (Mestre em Ciência em Modelagem Matemática e Computacional). Instituto de Ciências Exatas, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2017.

O objetivo deste trabalho é a construção de um sistema de controle inteligente para uma interface cérebro-máquina, usando o paradigma das Redes Neurais Artificiais. A interface construída traduz sinais cerebrais para movimentar um cursor em uma tela digital. O sistema de controle utiliza um sinal de feedback vindo do próprio usuário para realizar a sua calibração, fazendo com que o mesmo ajuste o movimento do cursor, de forma personalizada, de acordo com os sinais que o usuário envia. Com o uso de redes neurais artificiais conseguimos reduzir o tempo de treinamento que, em sistemas de controle tradicionais pode levar de dois a três meses, para a ordem de cinco minutos. O projeto visa facilitar a acessibilidade de indivíduos que possuam limitações de sua capacidade físico-motora, sejam elas temporárias ou permanentes. A construção do sistema tradutor dos sinais límbicos em respostas digitais, possibilita o desenvolvimento de uma gama de novas aplicações para o aumento da autonomia em pessoas com limitações motoras. Como continuação desse trabalho, muitos aplicativos poderão ser desenvolvidos visando a automação doméstica de tarefas básicas, como acender uma luz ou um eletrodoméstico, ou ainda para utilização similar em hospitais. Por se utilizar de plataformas de baixo custo, o mesmo possui grande potencial de produção e distribuição. Em algumas pesquisas, o sistema de Interface Cérebro Máquina se mostrou uma ferramenta promissora em aplicações que auxiliam pessoas com graves limitações motoras e na programação de dispositivos de assistência médica, remotas ou não [1].

**Palavras-chave:** interface cérebro máquina, sistemas de controle inteligentes, redes neurais artificiais, EEG, sinal eletrodermal, inteligência computacional.

## ABSTRACT

GONÇALVES, Werley de Oliveira. **Use of the Electroencefalogram and Electrodermal Signals in Learning by Reinforcement in a Brain Machine Interface**. 2017. 59p. Dissertation (Master Science in Mathematical and Computational Modeling) Instituto de Ciências Exatas, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2017.

The objective of this work is to construct an intelligent control system for a brain-machine interface using the Artificial Neural Networks paradigm. The built-in interface translates brain signals to move a cursor on a digital screen. The control system uses a feedback signal from the user to adjust the cursor movement in a personalized way according to the signals that the user sends. With the use of artificial neural networks we have been able to reduce the training time from up to 45 days, in traditional control systems, to less than 10 minutes. The project aims to facilitate the accessibility of individuals who have limitations of their physical and motor capacity, whether temporary or permanent. The construction of the limbic signal translator system in digital responses allows the development of a range of new applications to increase the autonomy of people with motor limitations. As a continuation of this work, many automation applications may be developed, for home or hospital use. By using low cost platforms, it has great potential for production and distribution. . In some researches, the Brain Computer Interface (BCI) system has proven to be a promising tool in applications that assist people with severe motor limitations and in health care devices, remote or otherwise.[1]

**Keywords:** Brain computer interface, intelligent control systems, artificial neural networks, fuzzy logic, EEG, electrodermal signal, computational intelligence.

## LISTA DE FIGURAS

FIGURA 1 – (A) MOSTRA O MODELO RESISTIVO DA PELE COMPLETO E (B) O MODELO REDUZIDO SUBSTITUINDO AS COMPONENTES $R_N$ POR UMA RESISTÊNCIA VARIÁVEL .....	7
FIGURA 2 – POSICIONAMENTO DOS ELETRODOS MODELO 10/20 FIGURA EXTRAÍDA DE [13].....	8
FIGURA 3 – CURVAS CARACTERÍSTICAS DE GANHO E ÂNGULO DE FASE DO FILTRO PASSA-BAIXA .....	12
FIGURA 4 – CURVAS CARACTERÍSTICAS DE GANHO E ÂNGULO DE FASE DO FILTRO PASSA-ALTA .....	13
FIGURA 5 – ESQUEMA TÍPICO DE UM AMPLIFICADOR.....	14
FIGURA 6 – CONFIGURAÇÃO TÍPICA DE UM FILTRO PASSIVO PASSA BAIXA.....	14
FIGURA 7 – CIRCUITO GSR CONECTADO AO ARDUINO .....	18
FIGURA 8 – PLACA GSR O CONECTOR MENOR É LIGADO AOS DEDOS DO USUÁRIO E O CONECTOR MAIOR COM QUATRO PINOS É CONECTADO AO ARDUINO@.....	19
FIGURA 9 – TOPOGRAFIA DO CIRCUITO GSR FONTE: <a href="https://www.seeedstudio.com/Grove-GSR-Sensor-P-1614.html">HTTPS://WWW.SEEEDSTUDIO.COM/GROVE-GSR-SENSOR-P-1614.HTML</a> .....	20
FIGURA 10 – ESQUEMA ELÉTRICO DO SENSOR GSR .....	21
FIGURA 11 – SINAL ELETRODERMAL ATÉ 0,5S UM COMPORTAMENTO NEUTRO DE 0,5S A 2,17S SINAL DE FRUSTRAÇÃO E EM 2,17S O COMPORTAMENTO DO SINAL A UMA REAÇÃO DE SURPRESA .....	24
FIGURA 12 – COM O EQUIPAMENTO USADO, TEMOS O ESPECTRO DA FREQUÊNCIA COM VALORES DE PERTURBAÇÃO PEQUENOS.....	24
FIGURA 13 – ELETRODOS UTILIZADOS .....	25
FIGURA 14 – OSCILOSCÓPIO PARA PC JÁ COM A BLINDAGEM .....	26
FIGURA 15 – AMPLIFICADORES OPERACIONAIS.....	26
FIGURA 16 – VALORES TÍPICOS DE EEG – COLETADOS EM 12 DE DEZEMBRO DE 2016.....	27
FIGURA 17 – EM AZUL OS PENSAMENTOS DE SUBIDA E EM VERMELHO PENSAMENTOS DE DESCIDA – DADOS COLETADOS EM 12 DE DEZEMBRO DE 2016 .....	28
FIGURA 18 – ALÉM DA REGIÃO DA ONDA MU CONSTATOU-SE QUE OS SINAIS ATÉ 20HZ PODEM AJUDAR NA IDENTIFICAÇÃO DO SINAL.....	29
FIGURA 20 – APRENDIZADO SUPERVISIONADO .....	32
FIGURA 21 – APRENDIZADO NÃO SUPERVISIONADO .....	32
FIGURA 22 – BOA GENERALIZAÇÃO: DADOS AJUSTADOS ADEQUADAMENTE.....	33
FIGURA 23 – GENERALIZAÇÃO POBRE: DADOS AJUSTADOS EM EXCESSO.....	33
FIGURA 24 – EXEMPLO DE UMA REDE MULTILAYER PERCEPTRON COM DUAS CAMADAS OCULTAS.....	34
FIGURA 25 – AS CURVAS DE COMPORTAMENTO DO SINAL ELETRODERMAL, AMPLITUDE EM VOLTS .....	37
FIGURA 26: VOLUNTARIO 1 – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	43

FIGURA 27: VOLUNTARIO 2 – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	44
FIGURA 28: VOLUNTARIO – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	45
FIGURA 29: VOLUNTARIO 4 – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	46
FIGURA 30: VOLUNTARIO 5 – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	47
FIGURA 31: VOLUNTARIO 6 – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	48
FIGURA 32: VOLUNTARIO 7 – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	49
FIGURA 26: VOLUNTARIO 8 – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	50
FIGURA 34: VOLUNTARIO 9 – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	51
FIGURA 35: VOLUNTARIO 10 – DISTRIBUIÇÃO DOS SINAIS CORRESPONDENTES AOS PENSAMENTOS DE SUBIDA E DESCIDA NO DECORRER DO EXPERIMENTO.....	52
FIGURA 37 – COMPORTAMENTO DO SINAL GSR DOS 10 VOLUNTÁRIOS DURANTE AS DUAS ÚLTIMAS FASES FINAIS DO EXPERIMENTO.....	55

## LISTA DE TABELAS

TABELA 1: VARIEDADE DE PARÂMETROS DE TREINAMENTOS TESTADOS, ONDE TODAS AS COMBINAÇÕES FORAM AVALIADAS. ....	36
TABELA 2: DESEMPENHO DAS DEZ MELHORES CONFIGURAÇÕES DE REDE NEURAL, IDENTIFICADAS NA PRIMEIRA FASE DE TREINAMENTO (A TABELA ESTÁ ORDENADA, DE FORMA DECRESCENTE, POR MÉDIA DE ACERTO). ....	36
TABELA 3 – ESTATÍSTICA DE ACERTO NO TREINO DA REDE NEURAL E NA PRÁTICA. TESTE 2.# DIRETAMENTE DO AMPLIFICADOR INICIAL; TESTE 1.# APÓS O FILTRO PASSA BAIXA E TESTE 3.# APÓS O SEGUNDO AMPLIFICADOR E FILTROS ELETRÔNICOS FINAIS. ....	38
TABELA 4 – ESTATÍSTICAS EXTRAÍDAS DA ETAPA DE TREINAMENTO DA REDE.....	39

## LISTA DE ABREVIACOES E SMBOLOS

BCI – Brain Computer Interface;

EDA – Eletrodermal Active;

GSR – Galvanic Skin Response;

SSEP – Potenciais Evocados Sustentados (*Steady-State Visual Evoked Potentials*);

NIRS –*Near-infrared Spectroscopy* (Espectroscopia de infravermelho prximo);

PIM – Potencial de Imagens Motoras;

SR – Skin Resistance;

$R_{TOT}$  – Resistncia equivalente total observada na pele;

$R_1$  – Resistncia equivalente em srie de pele;

$R_2$  – Resistncia equivalente do estrato crneo da pele;

$r_1 \dots r_n$  – Resistncia individuais de cada glndula sudorpara;

$R$  – Resistncia varivel equivalente  $r_1 \dots r_n$  em paralelo;

$dR_2$  – Variao da resistncia equivalente total observada na pele;

$dR$  – Variao da resistncia varivel equivalente das glndulas sudorparas;

$Fp_{\#}$  – Regio Frontal polar;

$F_{\#}$  – Regio Frontal;

$T_{\#}$  – Regio Temporal;

$C_{\#}$  – Regio Parietal;

$O_{\#}$  – Regio Occipital;

PNE – Portadores de Necessidades Especiais;

SSVEP – Steady-State Visual Evoked;

VEP – Visual Evoked;

$x$  – Variável no domínio do tempo;

$u$  – Variável no domínio da frequência;

$f(x)$  – Função contínua no tempo;

$F(u)$  – Transformada para o domínio da frequência;

$R(u)$  – Parte real da Transformada;

$I(u)$  – Parte imaginária da Transformada;

$\phi(u)$  - Ângulo de fase da componente  $u$

$N$  – Número de amostras igualmente espaçadas de um  $\Delta t$ , no domínio do tempo, e de  $\Delta u$ , no domínio da frequência;

MTBF – Mean-Time Between-Failure;

MTTR – Mean-Time-to Repair;

UOD – Universe of Discourse (Região de Discussão);

$D_{min}$  – Valor mínimo do UOD;

$D_{max}$  – Valor máximo do UOD;

$V_e$  – Sinal de entrada;

$V_s$  – Sinal de saída;

$R$  – Resistência do filtro;

$C$  – Capacitância do filtro;

$X_c$  – Impedância do capacitor  $(\omega C)^{-1}$ ;

$\omega$  – Frequência angular do sinal  $\omega = 2\pi f$ ;

$\alpha$  – Ângulo de defasagem em relação ao sinal de entrada;

$G$  – Ganho do sinal;

$\omega_c$  – Frequência de corte em radianos por segundo;

$f_c$  – Frequência de corte em Hertz;

$G_{dB}$  – Ganho em decibéis;

DFT – Discrete Fourier Transform (Transformada Discreta de Fourier);

GRD – Ground, referência elétrica do sistema eletrônico – elétrico;

$\mu_s$  – Valor médio do sinal GSR quando o usuário está surpreso;

$\mu_n$  – Valor médio do sinal GSR quando o usuário está em estado neutro;

$\mu_f$  – Valor médio do sinal GSR quando o usuário está frustrado;

$\sigma$  – Valor do desvio padrão do sinal GSR quando o usuário está em estado neutro;

$F_n(x)$  – Função normalizada do sinal GSR quando o usuário está em estado neutro;

$F_s(x)$  – Função normalizada do sinal GSR quando o usuário está surpreso;

$F_f(x)$  – Função normalizada do sinal GSR quando o usuário está frustrado;

$w_{kj}$ , – Elo Sináptico;

$b_k$  – Bias;

$a_k$  – Função de ativação  $a_k$ ;

$\varphi(a_k)$  – Função de Propagação;

$y_k$  – Saída do neurônio;

# SUMÁRIO

I	INTRODUÇÃO .....	1
I.1	Motivação .....	1
I.2	Objetivos.....	2
II	REVISÃO DE LITERATURA .....	4
II.1	SSVEP – <i>Steady-State Visual Evoked</i> .....	4
II.2	Autoindução de emoções.....	4
II.3	Onda $\mu$ .....	4
III	MODELAGEM DO SISTEMA DE CONTROLE .....	5
III.1	Atividade Eletrodermal .....	5
III.2	Eletroencefalograma.....	8
III.3	Filtrando os sinais .....	9
IV	ESPECIFICAÇÃO DO SISTEMA DE COLETA E AMPLIFICAÇÃO DO SINAL EEG.....	11
IV.1	Filtro Passa-Baixa RC.....	11
IV.2	Filtro Passa-Baixa RC.....	12
IV.3	Filtros com elementos Ativos .....	14
IV.4	Interferências Eletromagnéticas e Soluções.....	15
V	MATERIAL E MÉTODOS .....	16
V.1	Criando o sistema .....	17
V.2	Coleta do Sinal Eletrodermal .....	17
V.3	A programação do sistema GRS .....	22
V.4	Coleta do Sinal EEG.....	24
V.5	Teste Piloto – Definindo as variáveis da Rede Neural .....	26
VI	REDES NEURAIS ARTIFICIAIS.....	30
VI.1.1	Tipos de treinamento das redes neurais artificiais.....	31
VI.1.2	Riscos da generalização .....	32
VI.1.3	Multilayer Perceptron (MLP).....	34

VII	Modelagem do Sistema de Reconhecimento.....	35
VII.1.1	O sistema de reconhecimento neural.....	35
VII.1.2	Modelando o sinal eletrodermal .....	36
VIII	CONCLUSÕES.....	38
VIII.1	RESULTADOS E DISCUSSÃO .....	38
VIII.2	TRABALHOS FUTUROS.....	55
IX	REFERÊNCIAS BIBLIOGRÁFICAS .....	56
X	ANEXOS.....	59

# I INTRODUÇÃO

## I.1 Motivação

O Sistema Límbico tem papel importante no desenvolvimento do ser humano, uma vez que é ele quem cria e modula funções mais específicas, as quais permitem a uma pessoa distinguir entre o que lhe agrada ou desagradar [2]. A sua principal função é a integração de informações sensoriais do ambiente com o estado psíquico interno, onde é atribuído um conteúdo afetivo a esses estímulos, como medo ou prazer. Um sinal de feedback positivo é enviado para cada ação, ou pensamento sobre uma intenção de ação, realizada corretamente, reforçando determinadas sinapses enquanto outras são desestimuladas [3]. Em outras palavras, o sistema límbico gera um sinal de aprovação ou rejeição para cada ação que realizamos.

Como o lobo límbico se encontra na parte mais interna do cérebro, não é possível coletar os seus sinais diretamente através de um eletroencefalograma. Felizmente, esse sistema também controla a resposta eletrodermal, que é o sinal elétrico presente na pele e suas glândulas [4]. Em 1904, o engenheiro Müller e o neurologista suíço Veraguth constataram que a atividade eletrodermal (EDA) é estimulada por fenômenos psicofisiológicos. O fenômeno eletrodermal é espontâneo e resultado de alterações induzidas por um sistema complexo de elementos com diferentes propriedades eletrofísicas da pele e, por essa razão, a pele pode ser modelada por um conjunto de resistências e capacitores variáveis. Como exemplo, podemos citar as glândulas sudoríparas, que podem ser representadas por uma fonte de tensão ou capacitores carregados [4].

Por outro lado, apesar da possibilidade de coletar sinais límbicos através da pele, as respostas do Eletroencefalograma (EEG) são de natureza estacionária e variam a cada sessão de registro. Mesmo assim, pesquisadores que trabalham em EEG baseado em interfaces cérebro-máquina (em inglês, *Brain Computer interface* (BCI) têm obtido sucesso na discriminação entre os sinais de imagem motor esquerda-direita, utilizando técnicas de classificação de padrões como o Vetor de Suporte de Máquina, a Análise de Discriminantes Lineares, o Algoritmo de Classificação Bayesiana e o k-Vizinhos Mais Próximos. Porém esses métodos são incapazes de fornecer uma solução estável a longo prazo e os classificadores precisam frequentemente recalculá-lo seu modelo de distribuição, isto é, precisam ser recalibrados. É na busca pela superação desse problema que propomos um modelo neural, capaz de reduzir o tempo de treinamento do sistema e a frequência de calibrações [5][6].

A coleta de sinais através da utilização de um sistema de EEG utilizando eletrodos externos é um procedimento seguro, barato, não invasivo e com uma resolução temporal satisfatória para a maioria dos estudos e aplicações BCI [7][8]. Os sinais captados são compostos pela interação de diversos sinais elétricos emitidos pelo corpo humano. Durante o procedimento, pode haver captura de alguns sinais indesejados, mas estes podem ser eliminados através de filtros específicos para tal [8].

O BCI atualmente utiliza com maior frequência três metodologias que são elas:

- Potenciais evocados sustentados (SSVEP): (do inglês *Steady-State Visual Evoked Potentials*), este sinal aparece quando o indivíduo percebe um estímulo

periódico, tal como uma imagem piscando ou um som modulado em amplitude. A resposta SSVEP é identificada pelo aumento da potência do sinal do EEG na frequência de oscilação da excitação e nas suas harmônicas, ou sub-harmônicas. A principal vantagem desse tipo de sinal é poder ser utilizado sem necessidade de treinamento prévio [10][11].

- Espectroscopia de infravermelho próximo (NIRS): (do inglês *Near-infrared Spectroscopy*) é um método não invasivo que se baseia nas oscilações da absorção de luz em regiões ativas, maior concentração de hemoglobinas oxigenadas e regiões inativas do cérebro. A coleta de dados se limita a região cortical, camada mais externa do cérebro.
- Potenciais de imagens motoras (PIM): também conhecidos como ritmos mu (8-13Hz) / beta (13-30hz), são induzidos pelo córtex motor através da imaginação espontânea de movimentos corporais, como imaginar movimentos dos próprios membros, por exemplo, pés e mãos [12]. O sinal produzido pela imaginação do movimento possui características temporais, espaciais e de frequência bem determinadas, de modo que podem ser corretamente identificadas pela máquina. O usuário aprende a modular voluntariamente a amplitude dos seus ritmos sensório-motores através de um longo treinamento denominado condicionamento operante [11].

## I.2 Objetivos

O trabalho visa facilitar a acessibilidade de indivíduos que possuam limitações de sua capacidade físico-motora, sejam elas temporárias ou permanentes. A construção do sistema tradutor dos sinais límbicos em respostas digitais é capaz de propiciar uma gama de aplicações que podem se beneficiar dessa construção. Como continuação desse trabalho, muitos aplicativos poderão ser desenvolvidos visando a automação doméstica de tarefas básicas, como acender uma luz ou um eletrodoméstico, ou ainda para utilização similar em hospitais. Por se utilizar de plataformas de baixo custo, o mesmo possui grande potencial de produção e distribuição. Em algumas pesquisas, o sistema BCI já se mostrou uma ferramenta promissora em aplicações que auxiliam pessoas com graves limitações motoras a completar várias ações e em programação de dispositivos de assistência médica, remotas ou não [1].

O sistema de controle proposto está dividido em:

- Dois circuitos de coleta de dados, EEG e eletrodermal, que foram desenvolvidos com componentes eletrônicos de fácil aquisição e de baixo custo;
- Sistema de captura de sinais por uma interface Arduino®;
- Sistema de tratamento e reconhecimento de sinais, utilizando o software MATLAB®.

Durante o desenvolvimento desse trabalho, procurou-se atender a um conjunto de objetivos específicos, a saber:

- Implementar circuito de aquisição e amplificação do sinal eletroencefalograma (EEG)
- Propor alternativas que eliminem os ruídos tais como a construção do filtro Chebychev e blindagem do circuito e filtros Passa-Alta para eliminação dos sinais externos indesejados.
- Implementar o circuito de aquisição de sinal eletrodermal.
- Modelar um sistema automatizado de aprendizado e controle, em tempo real, de movimentos de um cursor na tela.
- Calibrar o sistema de aprendizado, identificando vulnerabilidades e aumentando sua robustez.

## II REVISÃO DE LITERATURA

Nesta sessão apresentamos o uso de interfaces cérebro-máquina, ou BCI, em trabalhos correlatos mostrando que existem diversas maneiras de se trabalhar BCI, algumas das quais descrevemos aqui. Depois do estudo bibliográfico, definiu-se que o presente trabalho iria usar como base o trabalho de Wolpaw, que detalharemos posteriormente.

### II.1 SSVEP – *Steady-State Visual Evoked*

No trabalho de Luísa Fernanda Suarez [10] foi adotado o SSVEP, metodologia que consiste em identificar onde o usuário está mantendo o seu foco de atenção. O foco, neste caso visual, faz com que propriedades específicas do objeto observado, como contraste de iluminação e sua frequência, alterem a atividade neuronal e modulem uma resposta ao estímulo visual. Essa resposta, denominada potencial visual evocado (VEP, do inglês *visual evoked potencial*), pode ser observada em frequências superiores a 6hz, criando oscilações quase senoidais, proporcionais à frequência e à fase do estímulo visual.

O mesmo trabalho relata que os sinais gravados por EEG correspondem à contribuição das fontes cerebrais e quaisquer outras fontes de corrente no corpo. Todos os sinais diferentes de fontes cerebrais são artefatos biológicos que podem não ser completamente eliminados por amplificadores e filtros [10]. Esse problema é comumente relatado nos trabalhos envolvendo BCI.

### II.2 Autoindução de emoções

Os sinais de emoção são gerados no lado direito do cérebro na frequência gama, como mostra Iacoviello [8] em seu artigo que usa as ondas alfa para a confirmação dos resultados. Para a identificação dos sinais como desgosto, medo, fome entre outros deve-se considerar os sinais provenientes do lado esquerdo do cérebro e também deve ser levado em consideração todo o espectro de frequência, a fim de reduzir o erro de classificação. Geralmente o reconhecimento e classificação das emoções é feito através de uma apresentação multimídia, método que é utilizado tanto para o treino quanto para a validação do modelo. Para se ter um sistema de BCI eficiente é necessário classificar uma grande gama de emoções, como “desgosto”, felicidade, medo e fome, entre outros[8].

O ponto negativo do processo de autoindução de emoções é que os sinais gerados por esse método são em magnitude 15% do valor dos sinais gerados com as emoções originais [8].

### II.3 Onda $\mu$

Trabalhos anteriores mostraram que um indivíduo pode ser treinado para utilizar as ondas cerebrais para acionamento de um cursor unidimensional usando ondas cerebrais 8-12hz (por sensor). A amplitude do sinal faz o cursor subir ou descer proporcionalmente a sua intensidade. Este treinamento pode durar até três semanas [17].

A onda  $\mu$ , 8-12hz tem um grande potencial nas aplicações de BCI por estar diretamente vinculada às regiões motoras do córtex cerebral, principalmente aos movimentos imaginados. Além disso, nota-se que existe facilidade do usuário em controlar a sua amplitude através de treinamento. Outra vantagem na utilização das ondas  $\mu$  ativadas no córtex “senso-motor” é não sofrer interferências dos olhos quando estes estão abertos ou não, nem pela contração da mandíbula, contração do pescoço ou qualquer outra atividade motora, exceto pelo movimento da mão contralateral. A localização dos sensores 10/20, C3 e C4, é a região do cérebro na qual o sinal  $\mu$  é identificado com melhor eficiência.

No trabalho de Jun Jiang ondas  $\mu$  são abordadas como sinais binários vindos dos dois hemisférios. Depois do tratamento com filtros, os sinais são trabalhados como combinação dois a dois, um sinal é coletado temporalmente depois do outro, permitindo uma sequência de dois sinais vindas do mesmo hemisfério, totalizando 6 combinações que são identificadas cada uma como um comando específico para o acionamento de um braço mecânico [19].

No trabalho de Wolpaw [17] foi desenvolvido um sistema em que o usuário move um cursor verticalmente. Nele, o usuário tem por objetivo acertar um alvo que se encontra hora na parte superior da tela e hora na parte inferior. Cinco voluntários participaram, no período de dois meses, em seções semanais de 45 minutos cada. Os sinais foram coletados em intervalos de 333ms, ou seja, a frequência de coleta é de 3hz. A amplitude dos sinais foi subdividida em 5 níveis 0-1  $\mu$ V, 1-2  $\mu$ V, 2-3  $\mu$ V, 3-4  $\mu$ V e  $>4$   $\mu$ V, com o intuito de facilitar o acerto do alvo. Quando o alvo se encontrava na parte superior da tela constatou-se uma facilidade maior em obter sucesso, mas quando o alvo se encontra na parte inferior da tela o erro era maior. A performance do modelo foi medida pela combinação da acurácia, entre 95 a 80% de acertos e pela velocidade, entre 29 a 10 acertos/min [17].

## **II.4 Sinal Eletrodermal**

O sinal eletrodermal será abordado com mais detalhes em III.1 , neste momento é necessário saber que esse sinal é gerado pela pele. Ele vem a ser uma das variáveis observadas nos polígrafos, sendo ainda uma alternativa barata para implementações em BCI [18].

Tsukahara e Aoki [26] elaboraram um protótipo baseado no fenômeno eletrodermal onde conseguiram acertar a letra que o voluntário estava pensando com 47% de precisão. Stefanie Blain e Tom Chau [18] mostraram que, com treinamento realizado através de exercícios mentais e uma catalogação adequada do sinal eletrodermal, é possível ajudar pessoas com limitações de comunicação a responderem perguntas do tipo Sim ou Não com acurácia de  $84 \pm 11,6\%$ . Para se chegar a esses valores, foram coletados e estudados o comportamento eletrodermal para diferentes tipos de respiração, meditação e contas mentais.

## **III MODELAGEM DO SISTEMA DE CONTROLE**

### **III.1 Atividade Eletrodermal**

O estudo da atividade eletrodermal iniciou-se em 1880 quando se constatou a grande correlação entre este sinal com estados psicológicos, o que fez com que esse se tornasse um

dos bioassinais mais utilizados pela psicologia da época. Comparando-o com outros sinais, o eletrodermal pode ser monitorado com equipamentos baratos e não há necessidade de o procedimento ser feito em condições controladas em laboratório [4].

O termo *atividade eletrodermal* (EDA, do inglês *electrodermal activity*), foi primeiramente introduzido na literatura por Johnson e Lubin (1966) para descrever todo fenômeno elétrico, incluindo fenômenos ativos e passivos, observados na pele e em seus anexos. Também é conhecido como *resposta galvânica da pele* (GSR, do inglês *galvanic skin response*) [4][13].

As primeiras correlações feitas entre o EDA e os fatores psicológicos são atribuídas a Vigouroux (1879), um eletroterapeuta francês que mediu as mudanças da resistência da pele (SR, do inglês *skin resistance*) em função da quantidade de anestesia que era administrado aos pacientes histéricos. Em sua teoria, ambos os fenômenos eram dependentes de processos centrais, entretanto, ele não creditava as mudanças bruscas da SR observadas por ele a processos locais na própria pele, atribuindo-as a atividades vasculares. Em 1904 o engenheiro Müller e o neurologista suíço Veraguth concluíram que o EDA é estimulado por fenômenos psicofisiológicos gerando grande interesse entre os psicólogos e psiquiatras [4].

Com o advento de melhores equipamentos como osciloscópio, polígrafo e o computador, o estudo da EDA se expandiu para diversas áreas, muito além do estudo científico do fenômeno e o uso em diligências policiais [4].

O fenômeno eletrodermal é espontâneo, assim como as alterações induzidas, e resultado de um sistema complexo de elementos com diferentes propriedades eletrofísicas. Podemos considerar a pele com o um conjunto de resistências e capacitores variáveis, enquanto glândulas que a compõe, como as sudoríparas, podem ser representadas por uma fonte de tensão ou capacitores carregados.

Do ponto de vista teórico, podemos dividir a medição eletrodermal em três categorias distintas:

- **Registro endossomáticos** – Neste método apenas as mudanças das partes ativas são levadas em conta, ou seja, apenas a energia elétrica originária das membranas polarizadas é levada em consideração.
- **Registro endossomático com corrente contínua** – Neste método o sistema elétrico é alimentado por uma fonte contínua de tensão ou corrente. Os sistemas ativos tornam-se fatores de menor relevância, sendo os componentes resistivos os de maior peso para o modelo.
- **Registro endossomático usando corrente alternada** – além das características resistivas descritas a cima, os fenômenos oscilatórios são estudados, ou seja, os componentes ativos também influenciam o resultado final. Não é um método comumente utilizado [4].

O diagrama da Figura 1 mostra o modelo proposto por Montazu e Coles (1966), que propõe um elemento capacitivo C, um resistor R1 representando a resistência equivalente em série, localizada na derme e no núcleo do corpo. R2 modela a resistência do estrato córneo, ou seja, a camada mais externa da pele, formada por células mortas e achatadas constituída predominantemente de queratina e óleos. Os  $r_1, \dots, r_n$  são os valores de resistência individuais

equivalentes das glândulas sudoríparas, onde os valores  $r_i$  podem entrar ou sair do modelo dependendo da atividade de cada glândula [20].

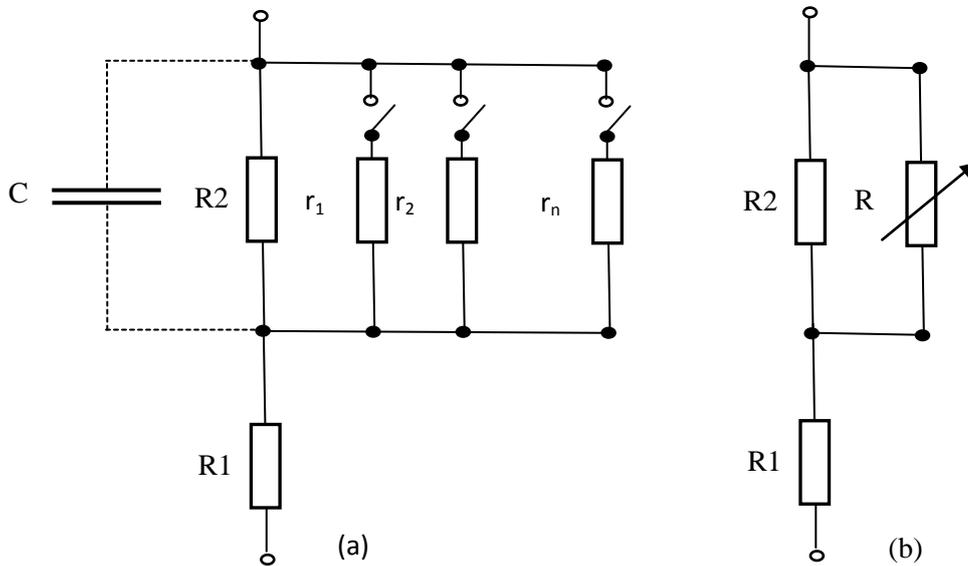


Figura 1 – (a) mostra o modelo resistivo da pele completo e (b) o modelo reduzido substituindo as componentes  $r_n$  por uma resistência variável

Pode-se considerar  $r_1, \dots, r_n$  como somente uma resistência variável  $R$ , equivalente ao valor em paralelo de todos os  $r_i$  facilitando a escrita do modelo como:

$$R_{tot} = R_1 + \frac{R_2 * R}{R_2 + R} \quad (1)$$

$R_{tot}$  – Resistência equivalente total observada na pele;

$R_1$  – Resistência equivalente em série de pele;

$R_2$  – Resistência equivalente do estrato córneo da pele;

$R$  – Resistência variável equivalente  $r_1 \dots r_n$  em paralelo;

Como o valor medido só depende do valor de  $R$  podemos trabalhar com a equação diferencial

$$dR_{tot} = \frac{R_2^2}{(R_2 + R)^2} dR \quad (2)$$

Estudos comprovam que dependendo do tipo de lesão causada a coluna espinhal pode constatar a presença do sinal eletrodermal. Em indivíduos com lesão abaixo da T8 é constatado a presença desse fenômeno tanto nas mãos quanto nos pés, para lesões entre a T4 e T8 o fenômeno só está presente nas mãos.

### III.2 Eletroencefalograma

O sistema de EEG com eletrodos externos é um procedimento seguro, barato, não invasivo e com uma resolução temporal satisfatória para a maioria dos estudos e aplicações de BCI.

A coleta de sinais realizada nesse trabalho baseia-se no sistema internacional 10-20, que divide o crânio em 21 pontos (Figura 2). A nomenclatura dos pontos é dada de acordo com a região em que estão localizados: F<sub>p</sub> = frontal polar, F = frontal, T = temporal, C = central, P = parietal e O = occipital. Os pontos localizados sobre a linha média são indexados pela letra “z”, de “zero”, os pontos localizados do lado esquerdo da linha média por índices ímpares e à direita por índices pares. Na determinação das posições dos pontos são usados dois pontos de referência no plano medial: o *nasion*, localizado no topo do nariz entre as sobrancelhas, e o *inion*, que fica na base do crânio atrás da cabeça. Além desses, usam-se também os pontos pré-auriculares no plano perpendicular ao crânio. A distância entre os pontos *inion* e *nasion* é medida e a partir deles são marcados os pontos sobre a linha mediana do crânio, F<sub>pz</sub> e O<sub>z</sub>, localizados a 10% da distância entre o *nasion* e o *inion*, e os pontos F<sub>z</sub>, C<sub>z</sub> e P<sub>z</sub>, localizados a 20% desta distância [13] [22].

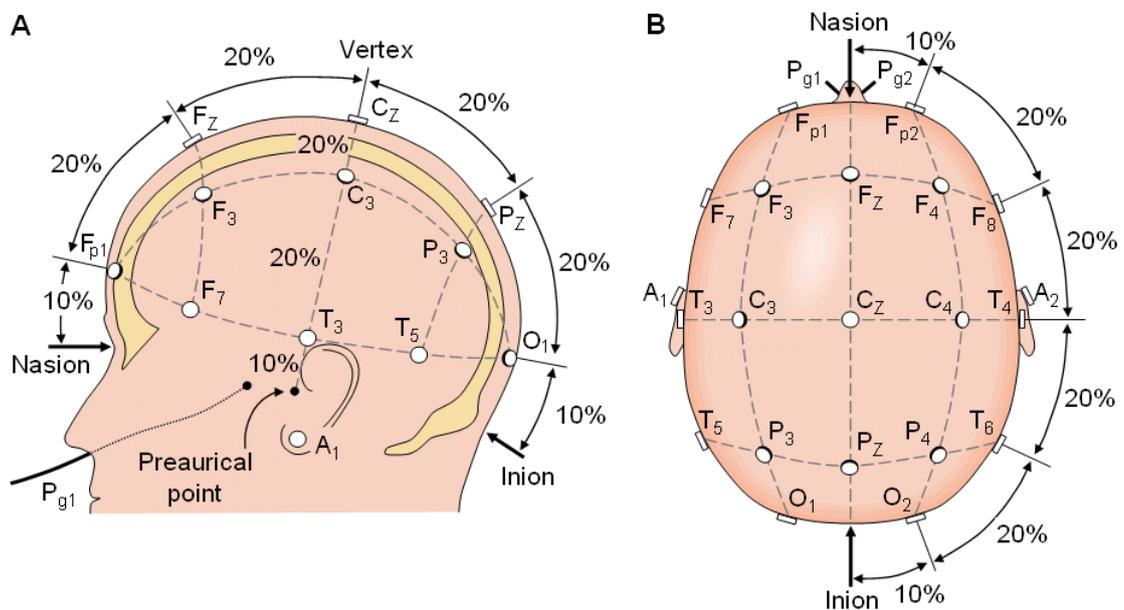


Figura 2 – posicionamento dos eletrodos modelo 10/20 figura extraída de [13]

A coleta também pode ser feita através de eletrodos bipolares e unipolares. No primeiro método, mede-se a diferença de potencial elétrico entre um par de eletrodos,

enquanto no segundo todos os eletrodos medem o seu potencial elétrico em comparação a um eletrodo de referência [13] [14].

Todo sistema elétrico sempre trabalha comparando um valor de tensão com uma referência, geralmente a terra. Na medição de eletroencefalograma, o mais comum é ligar a referência aos os lóbulos da orelha ou à ponta do nariz. Por outro lado, alguns pesquisadores afirmam que as referências localizadas fora do couro cabeludo (lóbulos da orelha, nariz) introduzem mais ruído do que uma referência de canal no couro cabeludo [13] [14] [22].

Os sinais captados são compostos não só pelos sinais cerebrais, mas pela combinação desses com diversos outros sinais elétricos emitidos pelo corpo humano. Tais sinais indesejados, como a eletromiografia, composta por sinais emitidos pelos músculos, e o sinal eletrodermal, emitidos pela pele, podem ser eliminados através de filtros. No presente trabalho, definimos o sinal de interesse como todo sinal que reflete as intenções do usuário, desta forma, os demais serão considerados ruído.

Diferentes áreas de conhecimento podem se beneficiar da aquisição de dados via EEG, desde a indústria de videogames, a indústria militar até o mercado de portadores de necessidades especiais (PNE). As aplicações voltadas para as PNE permitem uma maior interação com o ambiente e pessoas que o cercam através da tradução de “movimentos imaginários” em sinais elétricos capazes, por exemplo, de mover um terminal robótico usando uma interface adaptativa.

### III.3 Filtrando os sinais

Para o processo de filtragem de sinais, foi escolhida a Transformada Discreta de Fourier pela sua simplicidade. A transformada  $F(u)$  de uma função contínua  $f(x)$  sendo  $x$  uma variável real e  $u$  a variável no domínio da frequência é dada por:

$$F(u) = \int_{-\infty}^{\infty} f(x) \exp[-j2\pi ux] dx \quad (3)$$

$x$  – Variável no domínio do tempo;

$u$  – Variável no domínio da frequência;

$f(x)$  – Função contínua no tempo;

$F(u)$  – Transformada para o domínio da frequência;

$F(u)$  é uma função complexa isto é, têm uma parte real e imaginária:

$$F(u) = R(u) + j I(u) \quad (4)$$

$R(u)$  – Parte real da Transformada;

$I(u)$  – Parte imaginária da Transformada;

Para a nossa análise de dados devemos trabalhar a amplitude do espectro de Fourier desconsiderando o ângulo de fase.

$$|F(u)| = [R^2(u) + I^2(u)]^{1/2} \quad (5)$$

$$\phi(u) = \tan^{-1}[I(u) / R(u)] \quad (6)$$

$\phi(u)$  – Ângulo de fase da componente  $u$

Assim, para sinais discretos com  $N$  amostras uniformemente espaçadas:

$$\{f(0), f(1), f(2), \dots, f(N-1)\} \quad (7)$$

Segundo Najarian [14] é definido o par de transformadas discretas de Fourier como sendo a soma infinita de exponenciais complexas, também o domínio da frequência é discreto representados por:

$$u = (0, \Delta u, 2\Delta u, \dots, (N-1)\Delta u), \text{ onde } \Delta u = 1/N\Delta x \quad (8)$$

Onde:

$\Delta x$  é a discretização da função no domínio do tempo

$\Delta u$  é a discretização da função no domínio da frequência

$N$  – Número de amostras igualmente espaçadas de um  $\Delta t$ , no domínio do tempo, e de  $\Delta u$ , no domínio da frequência;

A transformada discreta de Fourier é obtida através da equação abaixo:

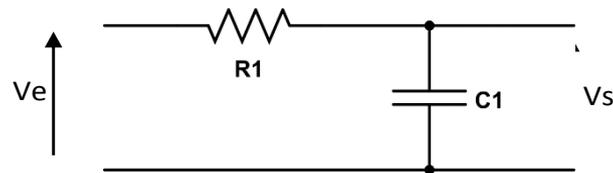
$$F(u) = \sum_{x=0}^{N-1} f(x) \exp[-j2\pi ux/N] \quad (9)$$

## IV ESPECIFICAÇÃO DO SISTEMA DE COLETA E AMPLIFICAÇÃO DO SINAL EEG

Antes de descrever o circuito de coleta de sinais iremos descrever os filtros de sinais e sua interface com os amplificadores operacionais, pois estes são partes essenciais do circuito. Os filtros eletrônicos consistem em componentes introduzidos no circuito a fim de limitar as frequências a jusante do circuito. Dependendo de suas configurações, os filtros são considerados Passa-Baixa, Passa-Alta, Passa-Faixa e Rejeita-Faixa. Para o andamento desse trabalho serão abordados somente alguns desses filtros.

### IV.1 Filtro Passa-Baixa RC

É composto de uma resistência em série com um capacitor onde a tensão obtida neste último é o sinal de saída,  $V_s$ . Para um mesmo valor de frequência, quanto maior a frequência, menor será o valor da impedância do capacitor,  $X_c$ , assim diminuindo o valor da tensão de saída.



$$V_s = \frac{-jX_c}{R-jX_c} * V_e \quad (10)$$

$$G = \frac{V_s}{V_e} = \frac{1}{1+j(\omega RC)} \quad (11)$$

$$|G| = \frac{1}{\sqrt{1+(\omega RC)^2}} \quad (12)$$

$$\alpha = -Tg^{-1}(\omega RC) \quad (13)$$

$V_e$  – Sinal de entrada

$V_s$  – Sinal de saída

$R$  – Resistência do filtro

$C$  – Capacitância do filtro

$X_c$  – Impedância do capacitor  $(\omega C)^{-1}$

$\omega$  – Frequência angular do sinal  $\omega = 2\pi f$

$\alpha$  – Ângulo de defasagem em relação ao sinal de entrada

$G$  – Ganho do sinal

O ganho em dB,  $G_{dB}$ , é definido como  $G_{dB} = 20 * \log G$  e a frequência de corte ocorre quando  $G_{dB} = -3$  é neste ponto que a potência de corte cai pela metade.

$$|G| = \frac{1}{\sqrt{2}} = \frac{1}{\sqrt{1+(\omega_c RC)^2}} \quad (14)$$

Resolvendo a equação acima temos:

$$\omega_c = \frac{1}{RC} \quad (15)$$

Ou,

$$f_c = \frac{1}{2\pi RC} \quad (16)$$

$$\alpha = -45^\circ$$

$\omega_c$  – Frequência de corte em radianos por segundo

$f_c$  – Frequência de corte em Hertz

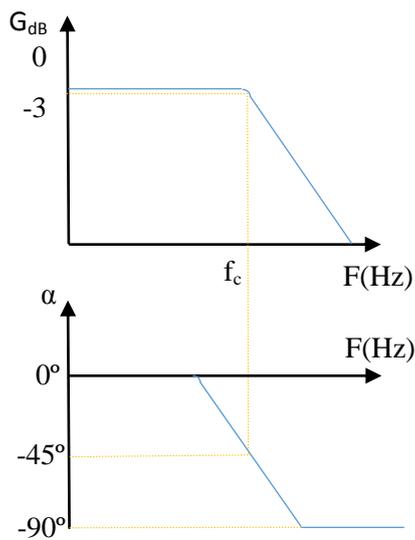
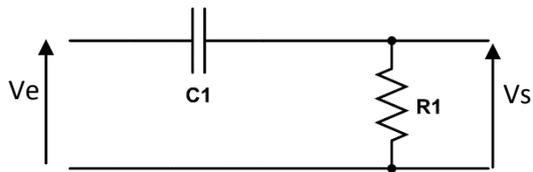


Figura 3 – curvas características de ganho e ângulo de fase do Filtro Passa-baixa

## IV.2 Filtro Passa-Baixa RC

Ao contrário do filtro Passa-Alta, a tensão de saída  $V_s$  é medida no componente resistivo ao invés do componente capacitivo.



Temos o ganho como:

$$G = \frac{V_s}{V_e} = \frac{R}{R + \frac{1}{j\omega C}} \quad (17)$$

$$|G| = \frac{\omega RC}{\sqrt{1 + (\omega RC)^2}} \quad (18)$$

$$\alpha = 90^\circ - \text{Tg}^{-1}(\omega RC) \quad (19)$$

Para o cálculo da frequência de corte, analogamente ao filtro passa-baixa, temos:

$$\omega_c = \frac{1}{RC} \quad (20)$$

Ou,

$$f_c = \frac{1}{2\pi RC} \quad (21)$$

$$\alpha = -45^\circ$$

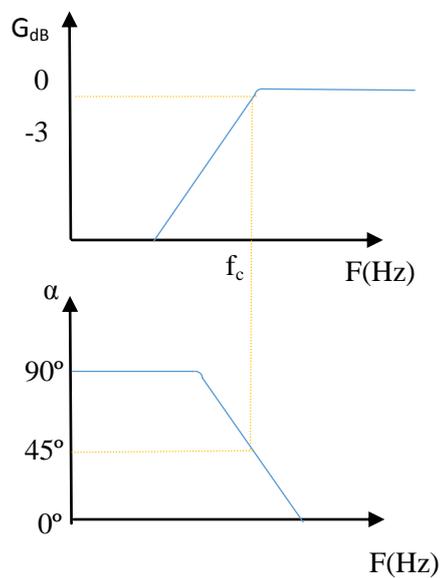


Figura 4 – curvas características de ganho e ângulo de fase do Filtro Passa-alta

### IV.3 Filtros com elementos Ativos

Também podemos obter um filtro passa-baixa com componentes ativos, os amplificadores operacionais. Como podemos ver abaixo, a inclusão de circuitos ativos é extremamente simples e ainda temos a vantagem de eliminar os componentes indutores do circuito, que são volumosos em baixas frequências, pesados e caros. Buscamos nesse trabalho a simplicidade e flexibilização dos projetos, fazendo-se associação em cascata de estágios de filtragens, e também a possibilidade de ganhos altos na amplificação do sinal de entrada.

Como desvantagens do uso de filtros ativos temos a necessidade de usar uma fonte de alimentação para a alimentação do mesmo, resposta à frequência limitada pelo circuito ativo e difícil utilização em sistemas de média e alta potência. Felizmente, para o desenvolvimento do presente trabalho, essas limitações não se tornaram um empecilho.

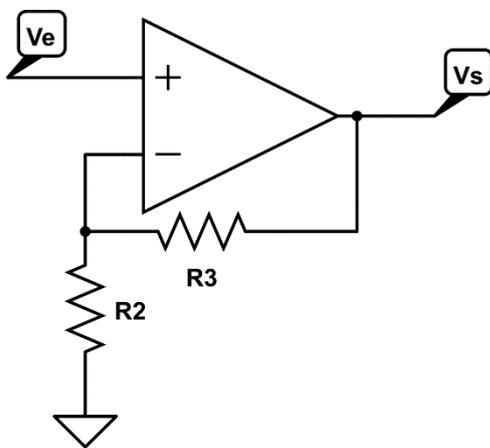


Figura 5 - esquema típico de um amplificador

Temos com a configuração acima um ganho na ordem de:

$$G_o = 1 + \frac{R_3}{R_2} \quad (22)$$

Acrescentando o circuito acima ao filtro passa baixa temos o circuito da Figura 6 -

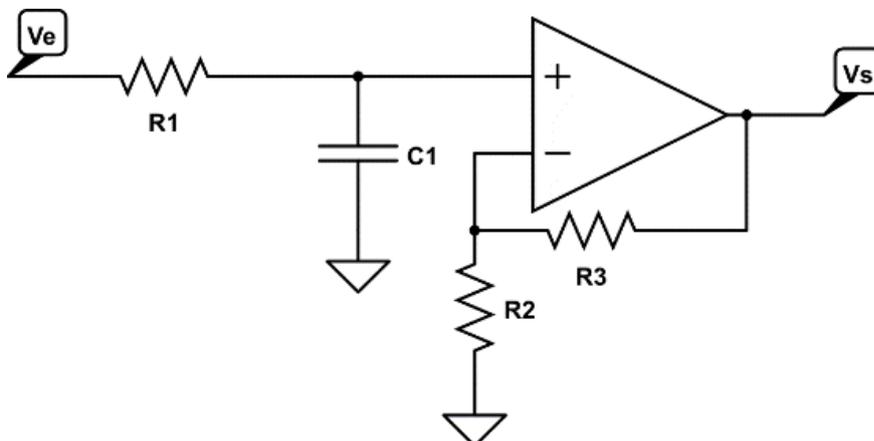


Figura 6 - configuração típica de um filtro passivo Passa Baixa

configuração típica de um filtro passivo Passa Baixa:

Temos assim para o filtro Passa-baixa acima o ganho e seu respectivo ângulo de fase:

$$|G| = \frac{G_0}{\sqrt{1+(\omega R_1 C)^2}} \quad (23)$$

$$\alpha = -Tg^{-1}(\omega R_1 C) \quad (24)$$

#### IV.4 Interferências Eletromagnéticas e Soluções

Apesar do intuito principal desse trabalho ser o uso do BCI e não a aquisição eletrônica do sinal, constamos nos experimentos iniciais que a interferência do sinal de 60Hz gerado pelas instalações elétricas locais, dependendo do nível de amplificação ou configuração do circuito de amplificação, acarretava em uma saturação dos componentes que, em muitos casos, inviabilizou a visualização dos sinais de interesse.

A interferência eletromagnética está presente tanto na coleta do sinal, antes da amplificação, quanto durante e depois da amplificação. Para minimizar esse problema, o cabo de coleta do sinal foi blindado, depois da amplificação, mas para melhorar a atenuação do sinal, tanto a blindagem quanto o corpo humano foram ligados à referência do circuito. Nos locais onde não foi possível fazer a blindagem eletromagnética, foram colocados filtros passa-baixa para minimizar a ocorrências desses sinais indesejados.

## V MATERIAL E MÉTODOS

O sistema proposto é composto por dois sistemas de coleta. O primeiro deles, o sinal de feedback, será coletado através da pele ou, mais precisamente, a partir da pele dos dedos da mão. O segundo conjunto de sinais, correspondente ao sistema motriz, será proveniente dos sinais de eletroencefalograma.

Neste trabalho de pesquisa a aquisição será feita por eletrodos tradicionais de EEG encontrados em qualquer loja de produtos médicos. De acordo com o sistema internacional 10-20 de mapeamento de posições os eletrodos serão fixados nas posições C3 ou C4, regiões localizadas a 20% da distância dos pontos pré-auriculares, passando pela parte mais alta do crânio [13][14].

Durante a condução dos primeiros experimentos, foi verificada a necessidade de amplificação dos sinais e, para tal, foi escolhido o amplificador de instrumentação AD620 por ser indicado para os níveis de tensão coletados pelos eletrodos [15]. Também foi necessário a inclusão de filtros passa-baixa e passa-alta, colocados em pontos estratégicos do circuito, a fim de evitar os ruídos indesejáveis que saturavam o amplificador limitando a amplificação do sinal.

Depois de coletado pelo computador, o sinal EEG passa por um filtro Chebychev de quarta ordem que mantém somente as frequências no intervalo entre 3,5 e 40hz. Esse filtro foi escolhido por sua grande atenuação do sinal na sua banda de corte e seus componentes foram dimensionados para que a ondulação na região de banda passante fosse a mínima possível. Também foi constatado a necessidade de blindagem do circuito para eliminar ruídos externos, principalmente em 60hz gerados pelas instalações elétricas.

O sinal coletado, apesar de ser analógico na sua origem, é trabalhado digitalmente como discreto, pois consiste de um agrupamento de valores coletados a um intervalo de tempo constante. Sendo assim, para se estudar esse sinal no domínio da frequência, será adotado a Transformada Discreta de Fourier (DFT) (do inglês *Discrete Fourier Transform*). Também é importante que a amostra atenda ao critério de Nyquist que especifica que um sinal precisa ser amostrado pelo menos duas vezes em cada ciclo de variação, ou seja, a frequência de amostragem tem que ser de no mínimo o dobro da maior frequência presente no sinal. É importante ressaltar que, quando esse critério não é atendido, os sinais de alta frequência são erroneamente registrados como baixa frequência, ocasionando o fenômeno chamado de *alias*. Um exemplo desse erro é o que ocorre quando observamos a imagem de uma roda girando na televisão e temos a impressão de que a mesma gira no sentido inverso [16].

A aplicação de BCI abordada nesse trabalho utilizará a onda  $\mu$ , compreendida entre 8-12hz, que está diretamente vinculada às regiões motoras do córtex cerebral, principalmente aos movimentos imaginados. Outra vantagem na utilização dessa onda é facilidade com que uma pessoa consegue controlar a sua amplitude através de treinamento. Diferentemente das demais ondas cerebrais, essas ondas não sofrem interferências visuais ou motoras da face, não sofrendo alterações se os olhos estiverem abertos ou fechados, nem de nenhuma outra atividade motora, como a contração da mandíbula ou do pescoço [17][19].

A onda  $\mu$  pode ser tratada como um sinal binário, oriundo dos dois hemisférios cerebrais. Esses sinais são coletados sequencialmente, de um mesmo hemisfério e combinados dois a dois, gerando uma codificação. Ao longo do tempo, podemos construir então uma sequência de pares de sinais vindas das regiões motoras, direita-direita, esquerda-direita, nulo-direita, etc. Sabe-se que só existem 6 combinações possíveis desses sinais e essas combinações serão usadas, nesta pesquisa, para representar um comando motor específico sobre um cursor [19].

Usaremos como ponto de partida o trabalho de Wolpaw que subdivide a amplitude da onda  $\mu$  em 5 níveis, a saber: 0-1  $\mu\text{V}$ , 1-2  $\mu\text{V}$ , 2-3  $\mu\text{V}$ , 3-4  $\mu\text{V}$  e  $>4 \mu\text{V}$ . No trabalho, essa divisão foi usada tanto para definir o sentido de um cursor na tela (por exemplo: para cima ou para baixo), quanto para definir a velocidade do cursor. Sendo a amplitude do sinal utilizada para o cursor subir ou descer proporcionalmente a sua intensidade. Em [17] esse treinamento pode durar até três meses.

Na pesquisa realizada no presente trabalho, além dos sinais descritos anteriormente e coletados via (EEG), utilizaremos também o sinal eletrodermal para modelar informações oriundas do sistema límbico sobre reforço ou penalização, conforme explicado anteriormente. A combinação desses sinais e sua tradução em um movimento de cursor será realizada através da utilização do paradigma das redes neurais artificiais. A expectativa é que o sistema de controle construído segundo o modelo neural possa acelerar o processo de calibração do sistema, reduzindo o tempo de treinamento de um usuário.

## **V.1 Criando o sistema**

No sistema proposto, já com os circuitos de coleta de dados calibrados e testados, os sinais são capturados por uma interface Arduino® e manipulados pelo MATLAB® versão R2015b, o computador utilizado é um Notebook com processador Intel® Core™ i5-4200U 64 bits 8Gb de memória RAM.

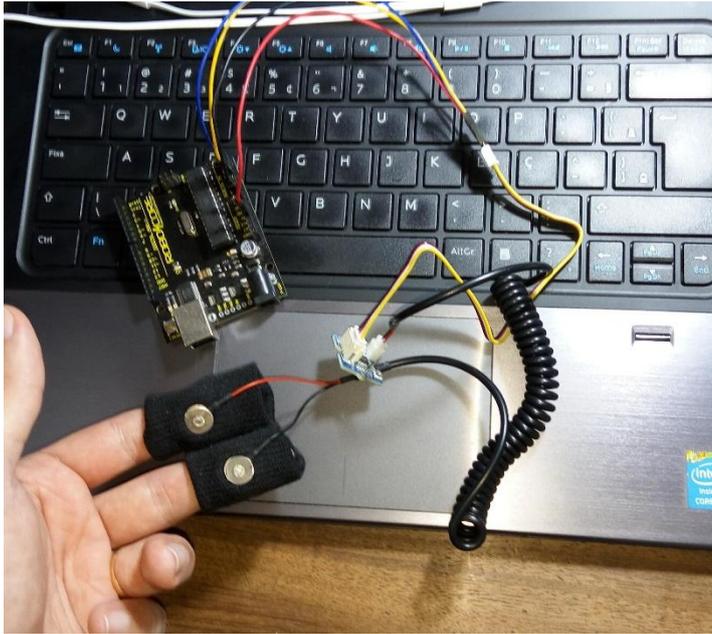
No primeiro momento foram estudados de forma independente os sinais eletrodermal e EEG afim de estudar as particularidades de cada sinal distinto para poder propor a solução final para o problema na forma do sistema de controle nebuloso. Neste tópico é abordado o trabalho realizado ao coletar os dados de entrada, eletrodermal e EEG, abordando as dificuldades e soluções propostas durante o período de coleta inicial dos dados.

## **V.2 Coleta do Sinal Eletrodermal**

Conforme levantado anteriormente, os sinais eletrodermais, também chamados de respostas galvânicas da pele, são o resultado do comportamento elétrico de todas as glândulas e células da derme e epiderme e refletem o entendimento que o sistema límbico tem do mundo exterior. No experimento final desse trabalho, este sinal será usado para determinar se o computador interpretou corretamente o sinal vindo do EEG.

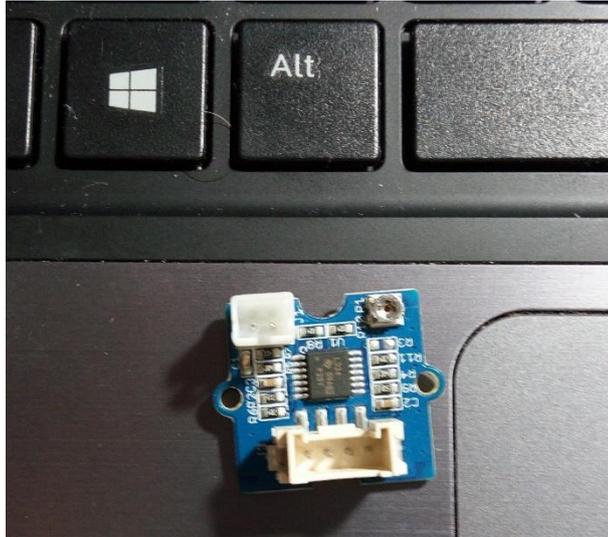
O aparelho escolhido para a coleta do sinal é fabricado pela <https://www.seeedstudio.com/>, por ser uma ferramenta barata e por ser baseada na plataforma Arduino®. As vantagens dessa escolha são diversas entre as quais citamos:

- É uma plataforma livre e, portanto, qualquer pessoa poderá reproduzir e melhorar os seus circuitos sem a prévia autorização do fabricante;
- É facilmente programável, diretamente no MATLAB®;
- Possui baixo custo, quando comparado com soluções de outros fornecedores.



*Figura 7 – Circuito GSR conectado ao Arduino*

A Figura 8 mostra um circuito GSR conectado ao Arduino® através de uma configuração típica de ligação entre eles, quando não se tem a placa base shield, que é fornecida separadamente e que permite conectar até quatro sinais analógicos, A0 a A3, e até 12 equipamentos digitais através do protocolo I2C.



*Figura 8 – Placa GSR o conector menor é ligado aos dedos do usuário e o conector maior com quatro pinos é conectado ao ARDUINO®*

Nos nossos experimentos, suprimimos a placa shield e o circuito GSR foi conectado diretamente ao Arduino®. Analisando a o circuito da base shield podemos propor, caso o usuário final só tenha a placa do Arduino e o sensor GSR, uma conexão alternativa para o usuário final que liga diretamente o sensor na placa Arduino, usando jumpers com a seguinte configuração:

- Cabo amarelo na entrada analógica A2
- Cabo branco na entrada analógica A3
- Cabo vermelho na fonte de corrente contínua 3V3
- Cabo preto no GRD da placa Arduino

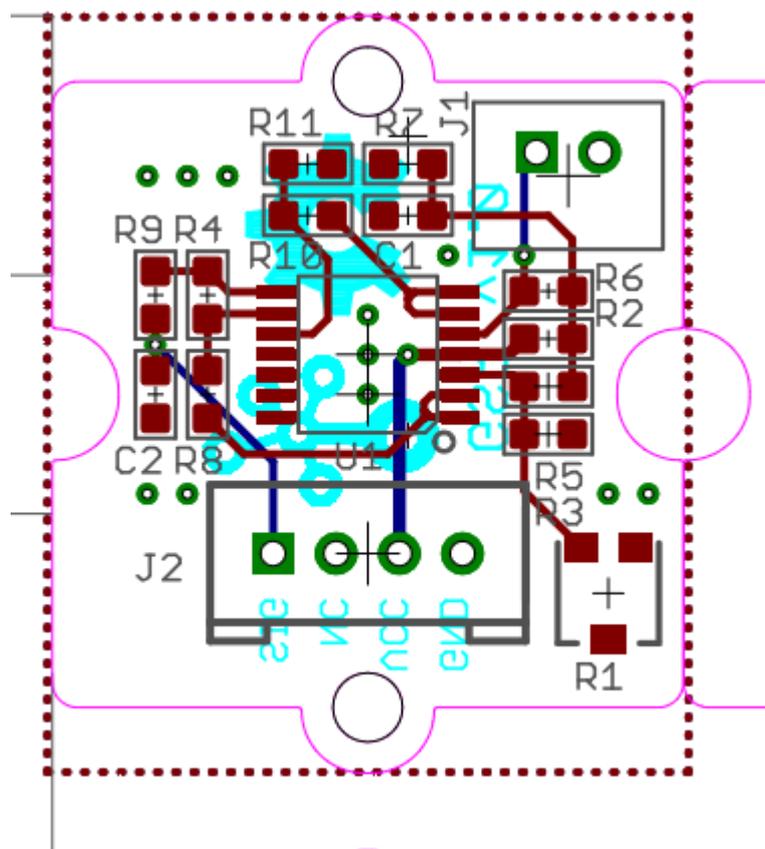
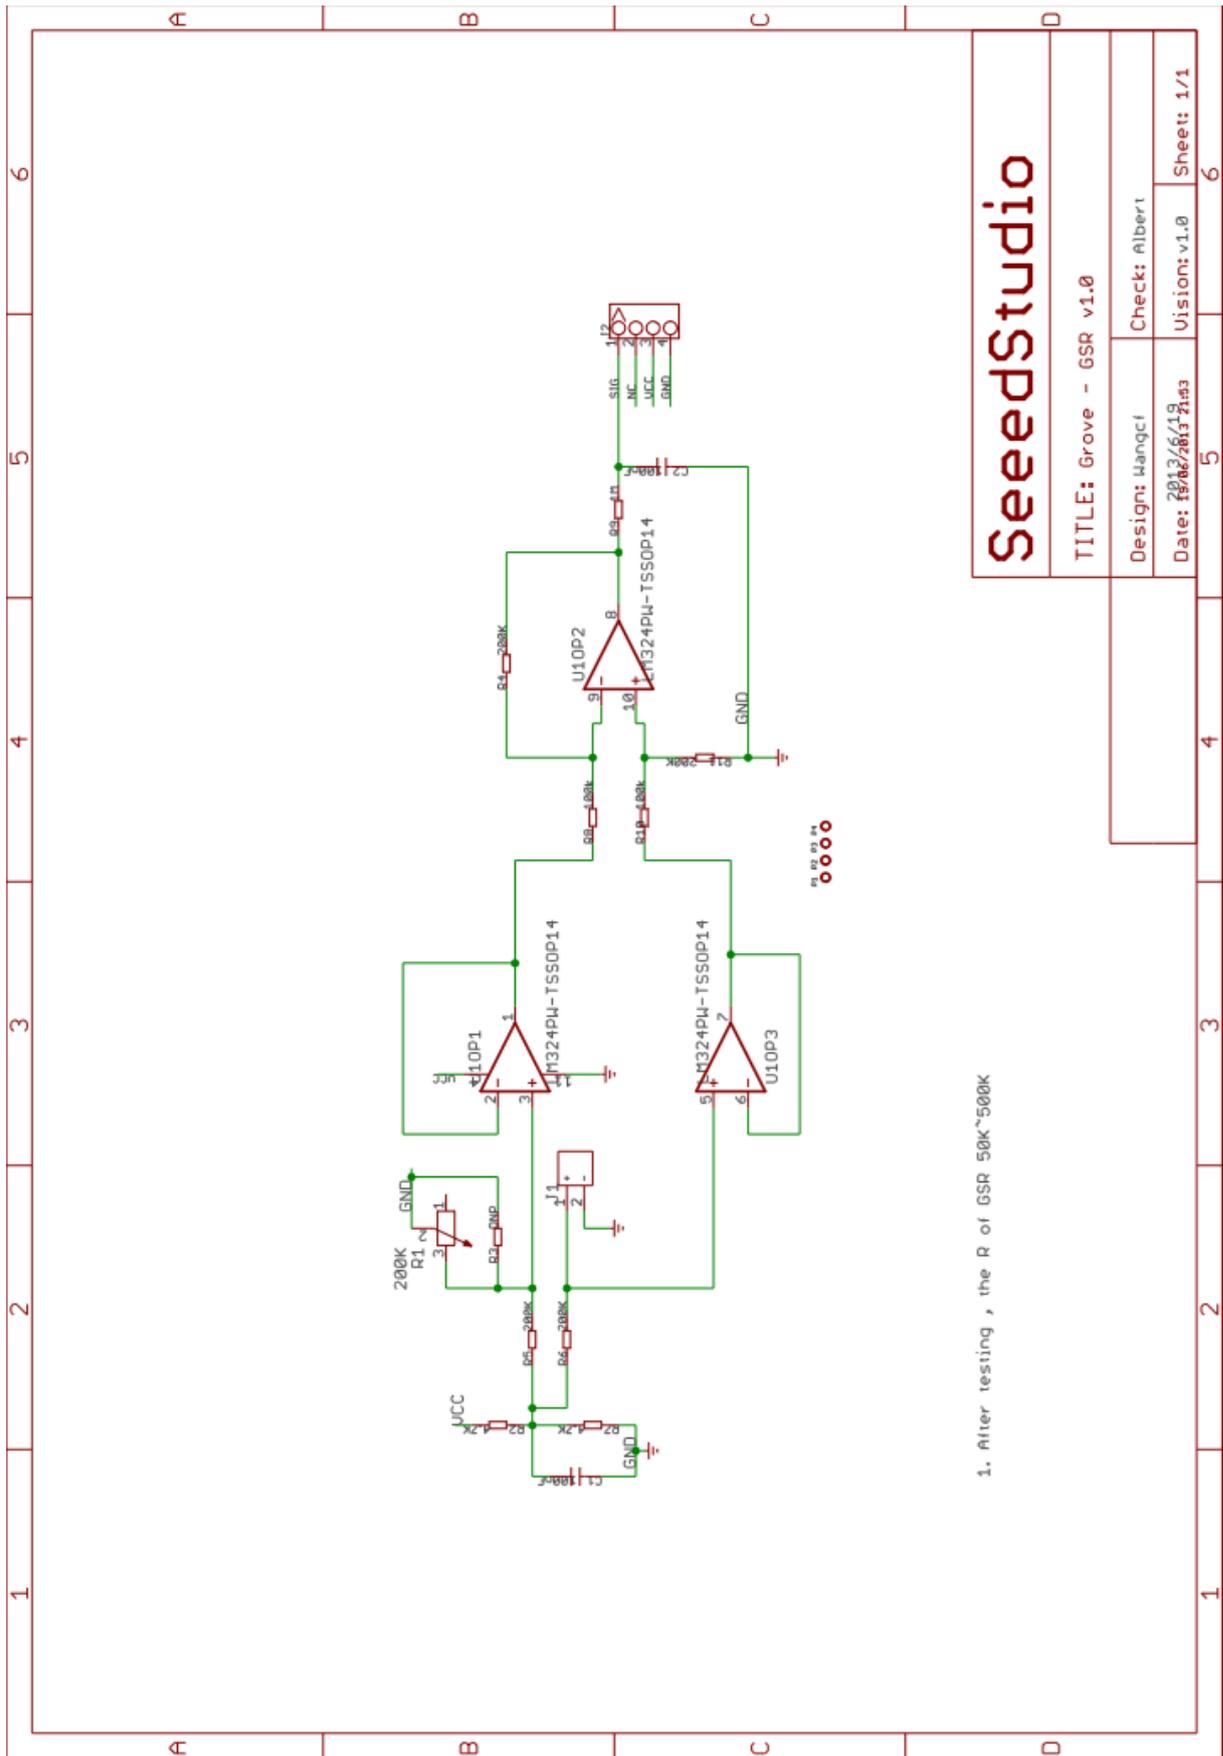


Figura 9 – Topografia do circuito GSR fonte: <https://www.seeedstudio.com/Grove-GSR-sensor-p-1614.html>



<h1>SeedStudio</h1>	
TITLE: Grove - GSR v1.0	
Design: Wangcl	Check: Albert
Date: 2013/6/19	Uision: v1.0
Sheet: 1/1	

Figura 10 – esquema elétrico do sensor GSR

### V.3 A programação do sistema GRS

Tendo em mente as considerações acima sobre o circuito do sensor GSR, abordaremos as rotinas de coletas de dados através do MATLAB®. De início, partimos do script em Arduino usado como exemplo pelo fornecedor [21] no qual a rotina registra dados a cada 5µs e calcula a média a cada 500 amostras coletadas. Quando a diferença do valor medido e a média ultrapassar a diferença de 50 unidades por duas medições seguidas, uma buzina é acionada e, caso o usuário tenha conectado o equipamento na porta digital 3, a mensagem “YES!” será exibida no monitor.

Para adaptar os comandos do Arduino para o MATLAB®, precisamos primeiro entender o que representa o valor de 50 unidades. O sinal analógico é comparado com a tensão de referência 5V, enquanto todos os valores inferiores a esse são separados a um intervalo de 5v/1024. O Arduino retorna valores entre 0 e 1023, porém no MATLAB® os valores de saída são fornecidos em volts. Para realizar a conversão desses valores, precisamos conhecer em volts o valor correspondente a 50 unidades e uma regra de três simples nos fornece o valor de 0,2441V.

Tendo definido o  $\Delta V$ , elaboramos uma rotina de observação em tempo real do sinal eletrodermal. Constatou-se que sentimentos de frustração, ansiedade e nervosismo diminuem a amplitude do sinal, enquanto sentimentos de espanto e surpresa aumentam sua amplitude, mas em ambos os casos, a variação é quase instantânea. Depois da ocorrência do comportamento ou sentimento gerador do impulso, o sinal lentamente converge para o valor original. Em uma coleta, iremos categorizar os sinais pelo seu comportamento em neutro, frustração e surpresa.

Entrando mais a fundo no script utilizado o sinal é previamente coletado, para ser usado como referência, e feito uma média ( $\mu$ ) e desvio padrão ( $\sigma$ ) que são usados em uma curva gaussiana em seguida é coletado o sinal em que deve ser percebido o comportamento citado acima.

$$F_n(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu_n)^2}{2\sigma^2}} \quad (25)$$

$F_n(x)$  – Função normalizada do sinal GSR quando o usuário está em estado neutro;

$\mu_n$  – Valor médio do sinal GSR quando o usuário está em estado neutro;

$\sigma$  – Valor do desvio padrão do sinal GSR quando o usuário está em estado neutro;

$x$  – Variável no domínio do tempo;

Analisando a equação acima quando o valor da medição  $x$  for igual a  $\mu$  temos a amplitude máxima que será,  $\frac{1}{\sigma\sqrt{2\pi}}$ , para o foco do trabalho é interessante trabalhar com valores de 0 a 1 para isso devemos dividir o valor obtido pelo valor máximo, sendo assim foi adotado

somente a parte  $e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ . Analogamente será feito funções similares para a frustração

$$F_f(x) = e^{-\frac{(x-\mu_f)^2}{2\sigma^2}}$$

Sendo

$$\mu_f = \mu_n - 0,2441. \quad (26)$$

E, analogamente, para os sinais de surpresa

$$F_s(x) = e^{-\frac{(x-\mu_s)^2}{2\sigma^2}} \quad (27)$$

Sendo,

$$\mu_s = \mu_n + 0,2441. \quad (28)$$

Ao final da varredura, determinamos os máximos das funções (25), (27) e (28) valores de  $[F_n(x)]_{max}$ ,  $[F_s(x)]_{max}$  e  $[F_f(x)]_{max}$  essas três variáveis determinarão se a interpretação do EEG foi bem-sucedida ou não.

No experimento final, o sinal de surpresa sempre acontecerá no início na medição, momento de mais fácil percepção, pois nessa hora o usuário perceberá se o programa atendeu a sua expectativa ou não. Na Figura 11 – Sinal eletrodermal até 0,5s um comportamento neutro de 0,5s a 2,17s sinal de frustração e em 2,17s o comportamento do sinal a uma reação de surpresa. Esse é um exemplo típico do comportamento do sinal eletrodermal que contém os três fenômenos possíveis: neutro, frustração e surpresa. No experimento que deu origem à figura, aos exatos 2,17 segundos ocorreu uma falta de luz que causou o pico de surpresa.

É importante deixar registrado que há ruídos no sinal eletrodermal coletado, independente do comportamento do sinal. Sempre haverá um sinal de ruído cujo valor encontra-se entre 50hz e 60hz, conforme mostrado na Figura 12 correspondendo a cerca de 10% da amplitude principal, não afetando significativamente as medições, o que garante a integridade do sinal coletado.

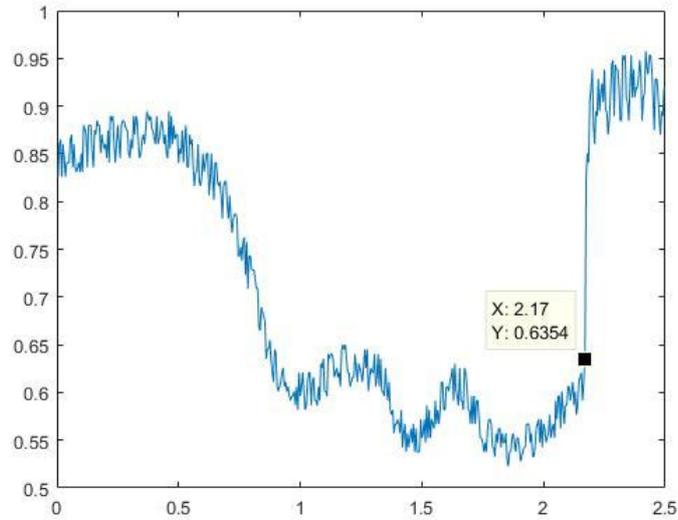


Figura 11 – Sinal eletrodermal até 0,5s um comportamento neutro de 0,5s a 2,17s sinal de frustração e em 2,17s o comportamento do sinal a uma reação de surpresa

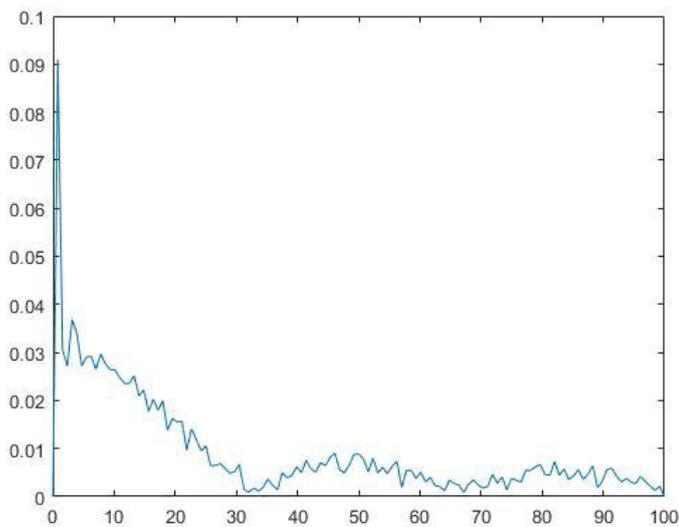


Figura 12 – Com o equipamento usado, temos o espectro da frequência com valores de perturbação pequenos.

## V.4 Coleta do Sinal EEG

Foram escolhidos eletrodos comumente usados para EEG<sup>1</sup>, mostrados na Figura 13. A coleta do sinal, após a amplificação, foi realizada através de um osciloscópio para PC<sup>2</sup>. O aparelho consiste em transformar a tensão de entrada para valores compatíveis com a entrada

<sup>1</sup> Modelo MaxxiGold, fabricado pela MF. Equipamentos Médicos LTDA, Indústria Brasileira – [www.neurovirtual.com.br](http://www.neurovirtual.com.br).

<sup>2</sup> Osciloscópio para PC, Laboratório de Som, fabricado pela Sensores-Microhard, <http://www.sensores-microhard.com.br/>

de áudio do computador. Escolhemos esse método pela facilidade com que se pode trabalhar sinais de áudio no MATLAB®.



Figura 13 – Eletrodos utilizados

Para suprir a necessidade de se criar uma blindagem do osciloscópio, que consiste em um cabo de 1m de comprimento (Figura 14) que, por sua vez, também sofre interferência de sinais externos.

Existem diversos tipos de hardwares dedicados a coleta dos sinais EEG, muitos deles bem especializados e, por consequência, extremamente caros. Produtos mais em conta, em contrapartida, não envolvem a metodologia da onda  $\mu$ , mas trabalham a atenção do usuário pelas ondas  $\beta$ . Por esse motivo foi elaborado também um circuito dedicado a coleta desses sinais.

Na amplificação de sinal, usamos um amplificador operacional AD620 (Figura 15) e, depois de diversas tentativas, constatou-se que o ruído em 60hz atrapalhava os resultados, saturando o amplificador. Uma solução apresentada no próprio manual do amplificador, e que se mostrou a melhor forma de coletar os sinais EEG, foi a inclusão de filtros passa-baixa na entrada do amplificador, reduzindo os sinais indesejados e melhorando o resultado final. Como consequência, conseguimos usar o amplificador com o ganho máximo de  $G \approx 10000$  ou seja, cada  $1\mu V$  na entrada do amplificador se tornará 10mV na saída do amplificador, um valor ótimo para aquisição pelo computador.



Figura 14 – Osciloscópio para PC já com a blindagem

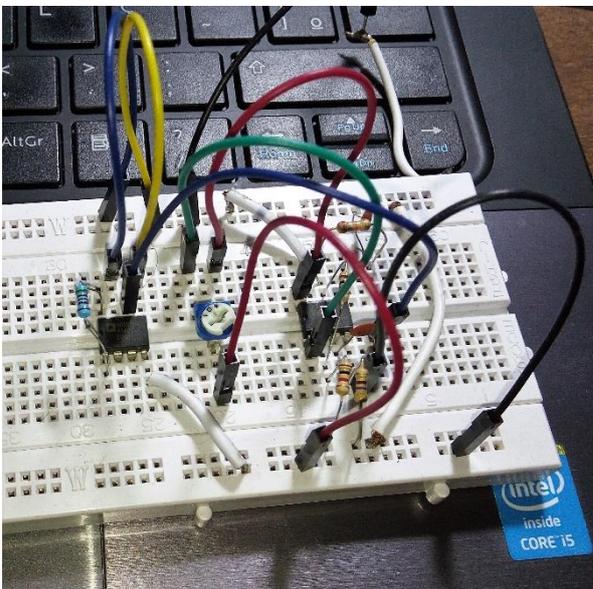


Figura 15 – amplificadores operacionais

Vale a pena deixar registrado que o motivo pelo qual não se atingiu o ganho de 10000 se deve a imprecisões construtivas dos componentes eletrônicos, resistores e capacitores usados, o que é natural em projetos de eletrônica.

## V.5 Teste Piloto – Definindo as variáveis do Sistemas Neural

Depois de feita a engenharia dos circuitos coletores dos sinais EEG, definimos as variáveis de entrada do sistema neural. Inicialmente, o sinal é coletado no domínio do tempo e transportado para o domínio da frequência e, a seguir, analisamos a amplitude das frequências que formam este sinal. Como visto anteriormente, a onda  $\mu$ , que está na faixa de 8 a 12hz deve se destacar na catalogação do sinal, e também a onda  $\beta$ , 18 a 25Hz pode ser usada como uma variável de classificação [19]. Como será visto a seguir, essas duas faixas de frequências

mostraram empiricamente comportamentos distintos para pensamentos de subida e de descida, comprovando assim que o circuito de coleta é eficiente para aplicações de BCI.

Conforme já explicado, a coleta de dados EEG se dá através de sinais de áudio e, nesse primeiro momento, utilizou-se o filtro Chebyshev do próprio MATLAB® para verificar e corrigir algumas incompatibilidades apresentadas no circuito amplificador, até que se chegasse na configuração final do circuito. Após a filtragem do sinal, utilizamos a transformada rápida de Fourier para obter a amplitude do sinal em função da frequência e o ângulo de fase deste sinal. Esses valores de amplitude e ângulo de fase são usados, posteriormente, pelo módulo neural, para reconhecer o tipo de sinal emitido e mover o cursor (Figura 16).

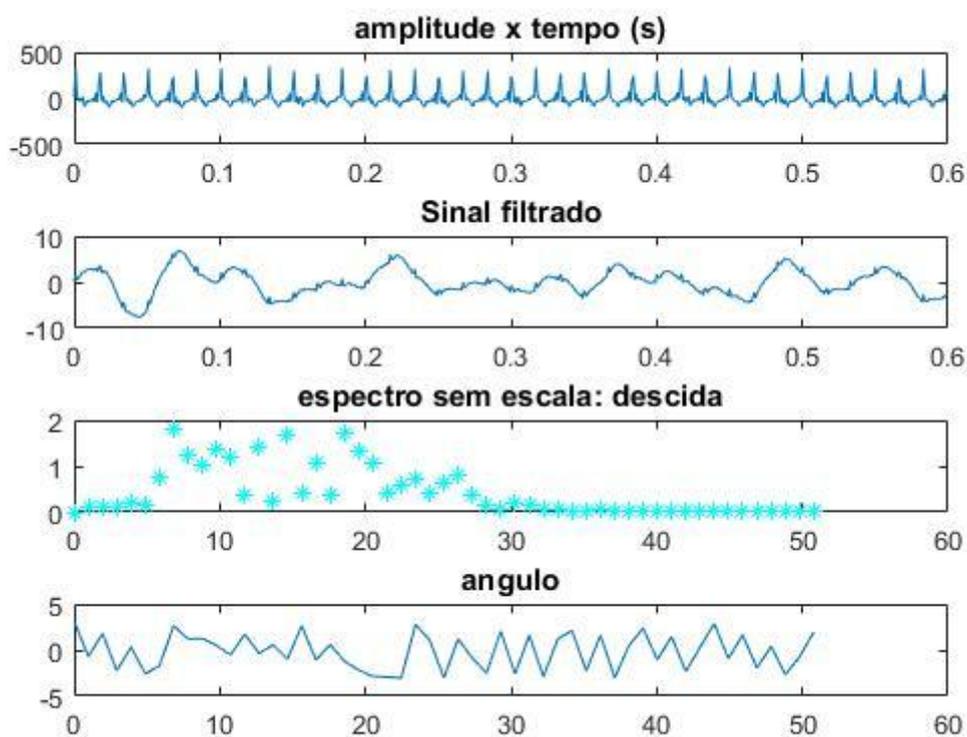


Figura 16 – Valores típicos de EEG – coletados em 12 de dezembro de 2016

Nos primeiros experimentos, testamos uma coleta contínua dos sinais, isto é, sem intervalos entre uma amostra e outra, o que acabou não se mostrando eficiente. O procedimento de coleta foi então alterado, através da inclusão de intervalos de descanso entre as amostras e da exibição de textos explicativos indicando qual pensamento devia ser executado (subir ou descer o cursor). Essas alterações melhoraram bastante a qualidade do material coletado. As coletas são feitas em conjuntos de 25 amostras de sinal de mesmo tipo, onde o tipo de cada conjunto é sempre o mesmo e escolhido aleatoriamente, podendo ser de movimentos de subida ou de descida. Antes de se iniciar as coletas, os voluntários foram orientados a imaginar o movimento pedido, criando imagens mentais diferentes para cada tipo. Por exemplo, um voluntário imaginava que estava subindo ou descendo uma ladeira de bicicleta, quando queria subir ou descer o cursor, respectivamente (Figura 17).

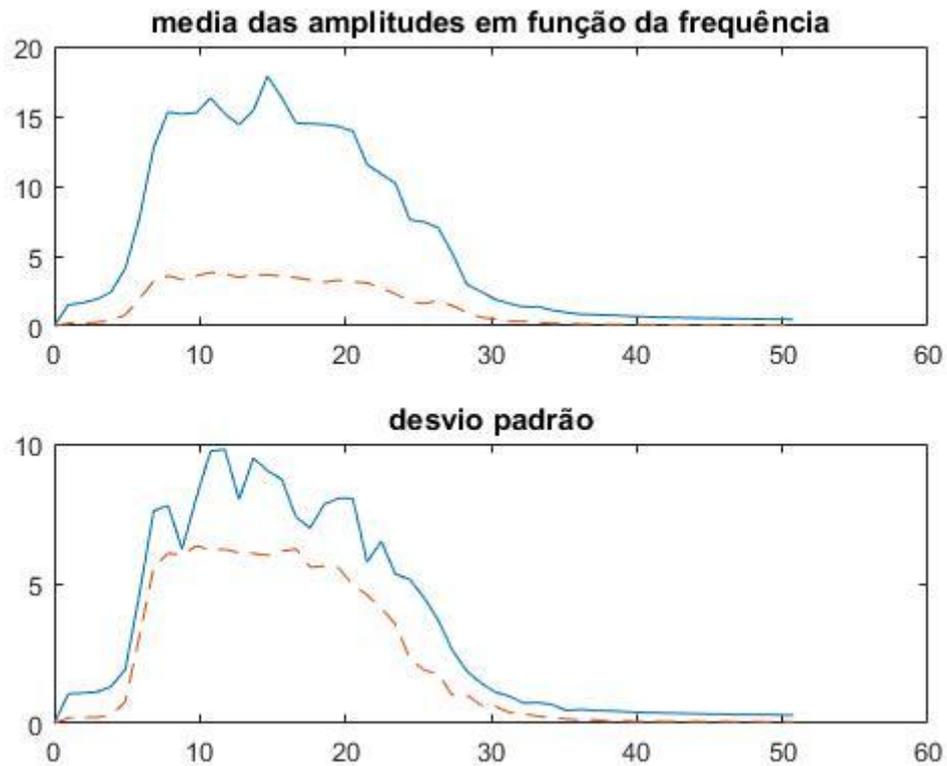


Figura 17 – em azul os pensamentos de subida e em vermelho pensamentos de descida – dados coletados em 12 de dezembro de 2016

Para definir quais seriam as frequências utilizadas como variáveis no experimento analisamos um conjunto de 100 amostras, igualmente distribuídas entre sinais de subida e de descida, dos sinais coletados pelo nosso sistema. Desses sinais, selecionou-se as 6 frequências em que a média para subida e descida se mostravam bem definidas, ou seja, distintas estatisticamente. Após a análise dos momentos estatísticos das amostras, selecionamos as frequências de 8, 10, 12, 16, 18 e 20Hz. Como era de se esperar, as frequências de 10 e 12hz se destacam das demais por estarem no espectro da onda  $\mu$ .

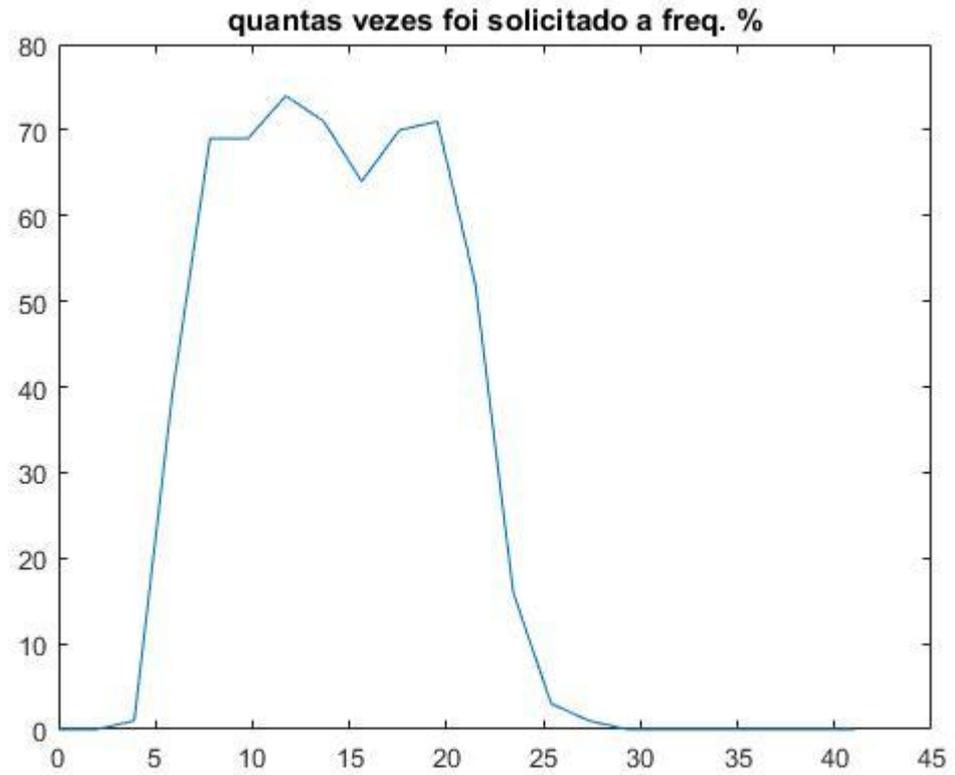


Figura 18 – além da região da onda mu constatou-se que os sinais até 20hz podem ajudar na identificação do sinal

Em seguida, já definido as variáveis de entrada da rede neural e adotando as variáveis de saída como 0 (descida) e 1 (subida), é necessário definir os parâmetros de inicialização da rede neural, assunto que será posteriormente abordado em VII.1.1.

## VI REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA's) estão entre as técnicas mais difundidas no campo da inteligência artificial. Sua operação emula o funcionamento do cérebro humano, mas suas aplicações vão muito além de seu papel como modelo biológico. As RNA's podem memorizar e raciocinar, aprendendo sobre problemas antes desconhecidos, a partir do zero. A natureza dos problemas que podem ser resolvidos pelas RNA's é muito vasta, eles podem ser financeiros (por exemplo, prever a direção do mercado de ações nos próximos meses), pode ser psicológicos (que fatores tornam um rosto atraente?) ou médicos (a imagem de um raio-X indica que um osso está quebrado?), dentre outros [24].

As redes neurais possuem a capacidade de armazenar informações e disponibilizá-las para uso posterior. Assim como o cérebro, o conhecimento é adquirido através no meio externo e consolidado por um processo de aprendizado, ou treinamento. No treinamento das redes neurais, as informações acerca do ambiente ou fenômeno em que se deseja atuar são representadas através de vetores de informações coletados nesse ambiente. Esses vetores representam as amostras de dados disponíveis e são a entrada das redes neurais, podendo ser rotuladas ou não, caso a classificação das amostras seja conhecida ou não, respectivamente.

Nas redes neurais, o conhecimento é armazenado nas conexões entre os neurônios, ou pesos, correspondendo às sinapses entre neurônios. O algoritmo de aprendizado modifica a intensidade dessas conexões, de forma a alcançar o objetivo desejado. Uma das características principais das redes neurais é sua capacidade de generalizar, produzindo saídas corretas para entradas nunca antes vistas. As RNA's realizam o mapeamento entrada-saída, onde as fronteiras de separação das classes são estimadas durante a fase de treinamento. Uma rede com mais de uma camada é capaz de aprender qualquer mapeamento contínuo. Elas podem ser facilmente re-treinadas, em casos de pequenas alterações no ambiente, são tolerantes a falhas por possuírem processamento distribuído. (FAUSETT, 1994; HAYKIN, 2001)

Um neurônio  $k$  de uma RNA é representado por um conjunto de elos sinápticos lineares,  $w_{kj}$ , um bias aplicado externamente e um elo de ativação possivelmente não-linear. O bias é representado por um elo sináptico conectado a uma entrada em +1. Os elos sinápticos de um neurônio ponderam os seus respectivos sinais de entrada. Sobre a soma ponderada dos sinais de entrada de um neurônio  $k$  corresponde à função de ativação  $a_k$  e, na sua saída, a função de propagação  $\varphi(a_k)$ , como as funções linear, degrau, hiperbólica ou sigmóide, dentre outras, induzindo o neurônio a produzir uma saída  $y_k$  (Figura 19). [24]

$$a_k = \sum_{j=0}^m w_{kj} \cdot x_j$$

$$y_k = \varphi(a_k)$$

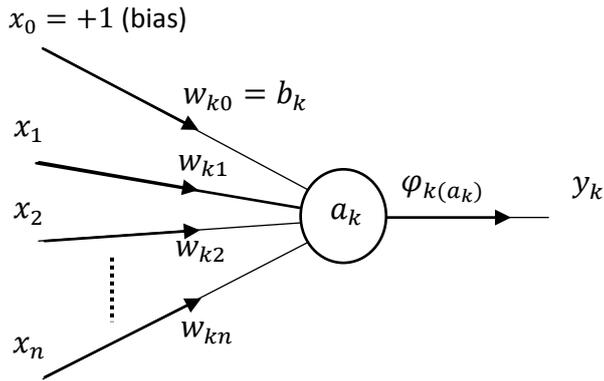


Figura 19 – Representação matemática de um neurônio

$w_{kj}$ , – Elo Sináptico;

$b_k$  – Bias;

$a_k$  – Função de ativação  $a_k$ ;

$\varphi(a_k)$  – Função de Propagação;

$y_k$  – Saída do neurônio;

A arquitetura da rede neural está intimamente ligada ao algoritmo de treinamento utilizado, à forma como os neurônios estão distribuídos pelas camadas e ao padrão de conexão entre eles. As redes Feedforward geralmente têm uma (Single-layer feedforward) ou mais camadas ocultas de neurônios (Multilayer feedforward) seguidas por uma camada de saída de neurônios lineares. Várias camadas de neurônios com funções de transferência não-lineares permitem que a rede aprenda relações não-lineares entre os vetores de entrada e saída. A camada de saída linear é mais frequentemente usada para problemas de ajuste de função (ou regressão não linear) [5][24]. Porém, se for necessário restringir as saídas de uma rede (como entre 0 e 1), então a camada de saída deve usar uma função de transferência sigmoide. No sistema construído, constatamos que os melhores resultados ocorreram quando usamos a função sigmoide na última camada da rede, em acordo com a literatura consultada [23].

### VI.1.1 Tipos de treinamento das redes neurais artificiais

A utilização de uma RNA na solução de uma tarefa passa por uma fase de aprendizagem, onde a rede extrai informações relevantes de padrões criando assim uma representação particular do problema [25].

O treinamento ou aprendizagem se baseia em um processo iterativo de ajustes dos parâmetros da rede que pode ser dividida em dois tipos de aprendizagem:

- **Supervisionado:** O objetivo é usar os dados externos de entrada e saída conhecidos (professor) para ajustar os parâmetros de rede de forma a encontrar a ligação entre os pares de entrada e de saída. A distância entre a resposta da rede e a esperada serve como medida do erro e é utilizada no ajuste dos pesos da rede. Esse tipo de treinamento necessita de um conjunto de treinamento rotulado (Figura 20).

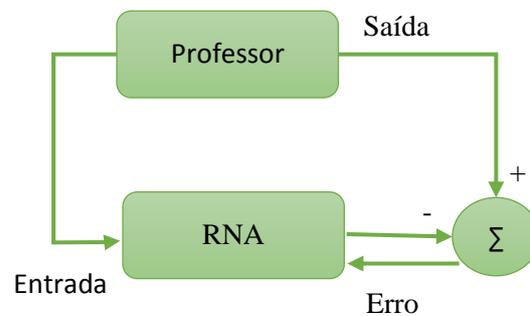


Figura 20 – Aprendizado Supervisionado

- **Não-supervisionado:** Análogo ao processo biológico do estado inicial dos sistemas de visão e audição, a resposta esperada é desconhecida. A rede se harmoniza, criando codificações internas para cada grupo de dados, definidos dinamicamente através da identificação das regularidades estatísticas das amostras de dados. Em outras palavras, a rede modifica seus pesos de forma a agrupar vetores de entrada mais semelhantes. Esse método pode ser utilizado para encontrar fronteiras de separação entre classes e em problemas de clusterização (Figura 21).



Figura 21 – Aprendizado Não Supervisionado

## VI.1.2 Riscos da generalização

Com o treinamento, espera-se que uma rede neural adquira uma boa capacidade de generalização do problema. Uma boa generalização se dá quando o sistema fornece valores corretos, ou aceitáveis, para os dados de entrada que não foram utilizados no treinamento. Quando a rede, durante o seu treinamento, passa a memorizar os resultados perde-se o seu poder de generalização e isso se deve geralmente a amostras de treinamento muito grandes.

Também pode se chegar a esse problema quando se usa mais neurônios escondidos que o necessário fazendo com que os ruídos presentes nos dados fiquem armazenados na rede neural. Este fenômeno é denominado *overfitting* ou *overtraining*. Depois de se separar o conjunto de dados disponíveis em subconjuntos de treinamento e de validação, a cada epoch (ciclo de treinamento) é avaliado se o valor erro se mantém em decréscimo. O momento em que a taxa de erro começa a aumentar indica que a rede está começando a memorizar os resultados e o treinamento deve ser encerrado (Figura 22 e Figura 23) [24].

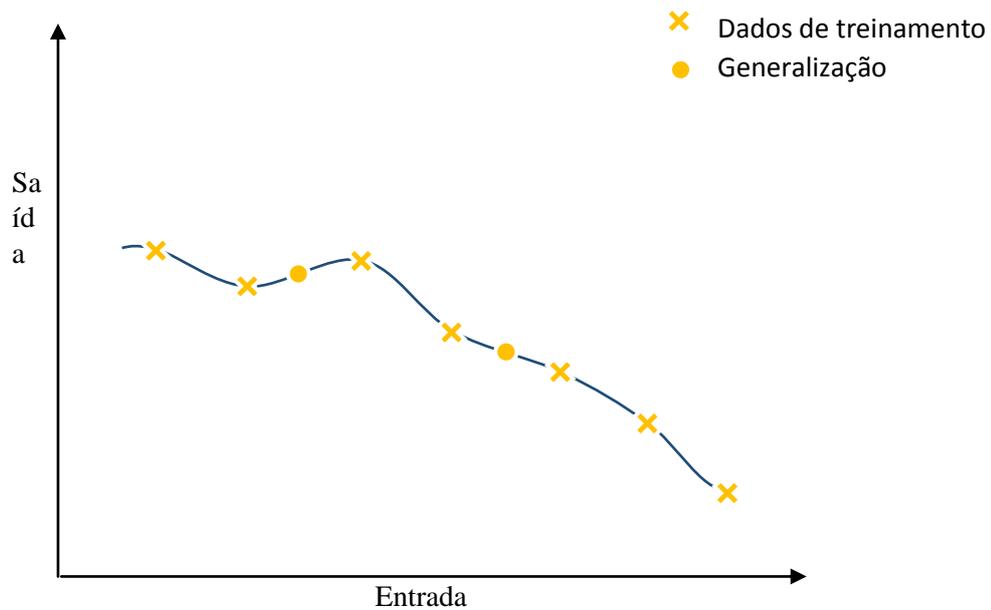


Figura 22 – Boa Generalização: Dados ajustados adequadamente

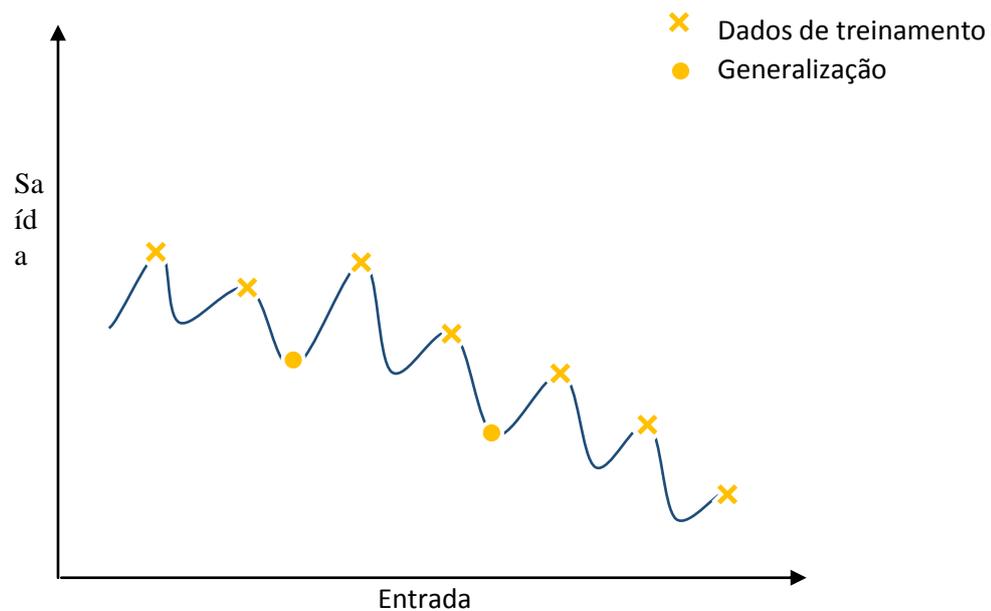


Figura 23 – Generalização Pobre: Dados ajustados em excesso

### VI.1.3 Multilayer Perceptron (MLP)

A MLP consiste de uma arquitetura de rede neural com uma ou mais camadas ocultas de neurônios, além da camada de neurônios de saída. O sinal de entrada se propaga para frente, camada por camada, e a cada *epoch* o sinal de erro é usado para corrigir os pesos, no sentido da camada de saída para a camada de entrada (Figura 24). Esse processo de correção de erros de trás para a frente baseia-se na retropropagação de erro, que gerou o nome de treinamento do tipo *backpropagation*. O treinamento dessa rede é supervisionado [24][25].

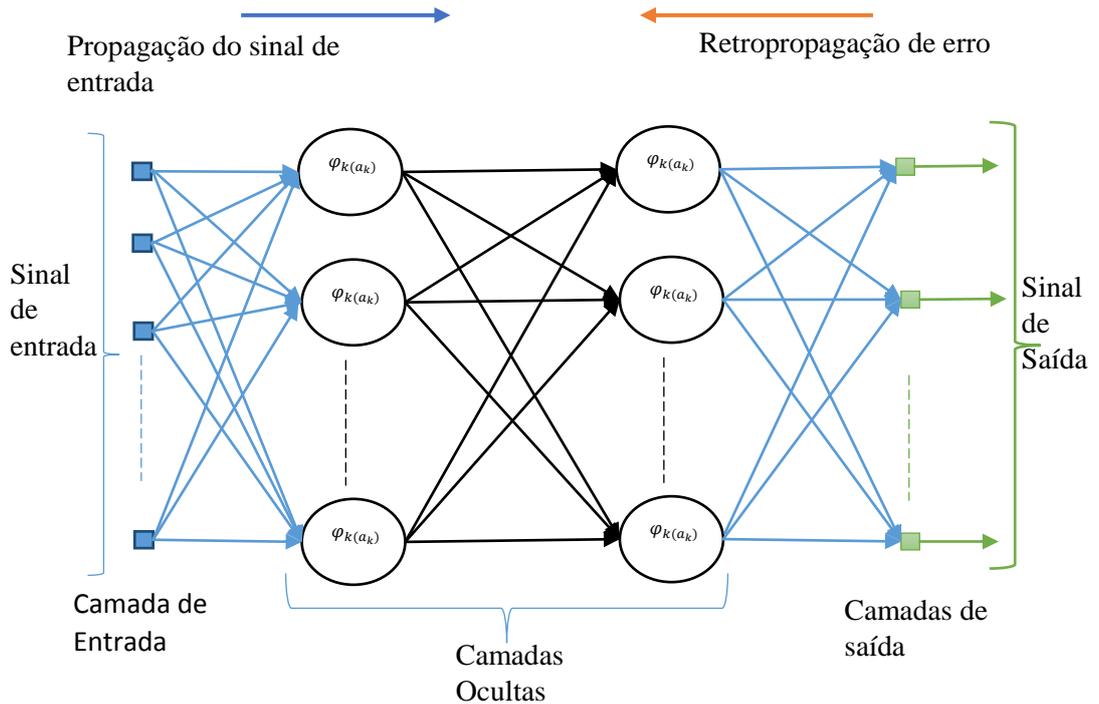


Figura 24 – Exemplo de uma rede multilayer Perceptron com duas camadas ocultas

As MLP apresentam um poder computacional muito maior do que o das redes que não contêm camadas intermediárias. Outra vantagem é que esse modelo pode trabalhar com dados que não são linearmente separáveis, na teoria uma rede com duas camadas intermediárias podem implementar qualquer função, seja linearmente separável ou não, dependendo apenas do número de nodos (neurônios) utilizados nas camadas intermediárias [25].

## VII Modelagem do Sistema de Reconhecimento

A primeira tentativa de modelar o sistema de reconhecimento dos sinais EEG foi realizada através de um sistema nebuloso, porém depois de várias análises e testes de diferentes modelos, acabamos por desistir desse modelo, pois os resultados eram muito fracos. Após essa decisão, adotou-se um sistema neural para executar a tarefa de reconhecimentos dos sinais.

O usuário segue as orientações que são transmitidas na tela do computador, que consistem em pensar em subir ou descer o cursor. Para tal é explicado ao usuário que ele tem que imaginar um movimento correspondente da mão [17].

Observou-se que a forma de pensar no movimento é um fator importante para o sucesso do reconhecimento dos sinais emitidos. Ao aplicar uma força imaginária durante o pensamento de movimentar o cursor podemos gerar amplitudes maiores nesse tipo de sinal. Em algumas amostras foi observado que se o usuário pensa com mais força em uma determinada direção essa direção terá amplitudes maiores, algo que pode ser levado em consideração de acordo com a escolha do usuário.

### VII.1.1 O sistema de reconhecimento neural

Escolhemos o modelo de rede neural MLP (*multilayer perceptron*), utilizando o algoritmo de treinamento de *backpropagation*, por ser esse um modelo conhecidamente eficiente para solução de problemas de reconhecimento de padrões. Para escolher a melhor arquitetura e definir os parâmetros de treinamento mais adequados, realizamos uma triagem inicial de cerca de 4000 modelos diferentes, onde cada modelo, definido através de diferentes combinações dos parâmetros da rede, foi treinado por 20 vezes, por 1000 *epochs* em cada treino (Tabela 1).

Os dados de entrada são coletados em conjuntos de 20 amostras, onde é solicitado ao usuário que pense em um movimento, subida ou descida. Após essa coleta inicial, realiza-se outro conjunto de coleta complementar ao anterior. Ao final da coleta se tem arquivado conjuntos de tamanho igual, compostos por amostras de pensamentos devidamente catalogados em subida (saída = 1) ou descida (saída = 0).

Após a identificação das dez arquiteturas que apresentaram o melhor desempenho (Tabela 2), retreinamos esses modelos por 50 vezes, a fim de decidir o melhor modelo para a solução do nosso problema. Finalmente, depois de executadas os 50 treinamentos de cada rede, escolhemos a que apresentou o melhor desempenho entre todas, que alcançou uma taxa de acertos médio de 72% e utilizou os seguintes parâmetros: S1=4, S2=2, f1=tangente hiperbólica, f2=sigmóide, f3= sigmoide, lr= 0.60 e mc= 0.90.

Todas as redes foram testadas utilizando uma função de treinamento que atualiza os valores de peso e de *bias* de acordo com o método BFGS quasi-Newton.

Conforme explicado na sessão anterior, todas as redes foram treinadas tendo como entrada as frequências de 8, 10, 12,16,18 e 20Hz e, como saída, elas deveriam classificar o sinal com Descida (saída = 0) ou Subida (saída = 1). Para cada modelo de rede testado, em cada novo treinamento, as amostras rotuladas disponíveis foram separadas em uma razão de 80% de amostras para treino e 20% para teste da rede.

Tabela 1: Variedade de parâmetros de treinamentos testados, onde todas as combinações foram avaliadas.

Parâmetro	Descrição	Valores testados
S1	Quantidade de neurônios da primeira camada escondida	2, 4, 8 e 16
S2	Quantidade de neurônios da segunda camada escondida	0, 2, 4 e 8
Lr	Taxa de aprendizado	0.2, 0.4, 0.6 e 0.8
Mc	Constante de <i>momentum</i>	0.3, 0.5, 0.7 e 0.9
f1	Função de propagação da primeira camada escondida	Tangente hiperbólica, sigmoide e linear
f2	Função de propagação da segunda camada escondida	Tangente hiperbólica, sigmoide e linear
f3	Função de propagação da camada de saída	Tangente hiperbólica, sigmoide e linear

Tabela 2: Desempenho das dez melhores configurações de rede neural, identificadas na primeira fase de treinamento (a tabela está ordenada, de forma decrescente, por média de acerto).

S1	S2	f1	f2	f3	lr	mc	mdAcerto
4	2	tansig	logsig	logsig	0,6	0,9	55,13
4	2	tansig	tansig	logsig	0,4	0,3	54,62
16	4	tansig	logsig	logsig	0,6	0,9	54,49
16	8	tansig	logsig	logsig	0,8	0,9	54,23
16	8	tansig	logsig	logsig	0,4	0,9	54,1
16	8	logsig	logsig	logsig	0,8	0,7	53,85
16	2	tansig	logsig	logsig	0,4	0,3	53,72
16	8	tansig	tansig	logsig	0,8	0,5	53,72
16	0	logsig	logsig	logsig	0,8	0,5	53,59
16	2	logsig	logsig	logsig	0,6	0,3	53,59

## VII.1.2 Modelando o sinal eletrodermal

Logo após a coleta do sinal EEG o sistema neural irá classificar o mesmo, traduzindo-o como um pensamento de subida ou descida e movendo o cursor de acordo com essa classificação. Logo após a movimentação é realizada a coleta do sinal eletrodermal  $x$ . De cada uma dessas coletas  $x$ , serão determinados os valores de  $F_n(x)$ ,  $F_s(x)$  e  $F_f(x)$  e determinado o valor máximo entre elas. Conforme citado anteriormente, em uma mesma amostra pode-se observar mais de um comportamento, uma vez que existe alguma interseção entre suas curvas de distribuição (Figura 25), cujos valores são fornecidos pelo fabricante do dispositivo de coleta.

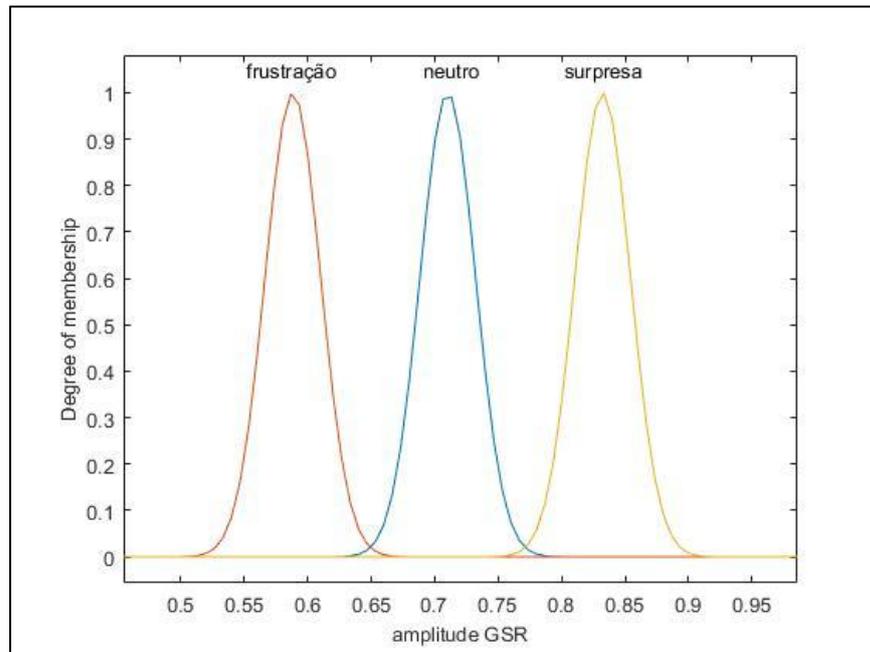


Figura 25 – as curvas de comportamento do sinal eletrodermal, amplitude em Volts

Os valores de cada função são armazenados para observação futura, mas no momento da coleta foi definido que:

- Se  $[F_n(x)]_{max} > [F_f(x)]_{max}$ . => a direção do cursor não é alterada.
- Se  $[F_n(x)]_{max} < [F_f(x)]_{max}$ . => a direção do cursor é invertida.
- O valor de  $[F_s(x)]_{max}$  não será usado nesse trabalho.

## VIII CONCLUSÕES

### VIII.1 RESULTADOS E DISCUSSÃO

Depois de um conjunto exaustivo de testes, decidimos adotar um sistema eletrônico simples, contendo apenas um amplificador. Como pode ser observado na Tabela 3, conforme incrementamos componentes no protótipo acabamos diminuindo a qualidade do sinal e, por consequência, a qualidade da modelagem. Isso ocorre por ser o protoboard suscetível à captação de ruídos e interferências e, tendo em vista que o objetivo desse trabalho é a modelagem matemática do sinal, optou-se por trabalhar apenas com um estágio de amplificação e apenas a filtragem a jusante do amplificador conforme, exposto em V.4 .

*Tabela 3 – Estatística de acerto no treino da Rede Neural e na prática. Teste 2.# diretamente do amplificador inicial; Teste 1.# após o filtro passa baixa e Teste 3.# após o segundo amplificador e filtros eletrônicos finais.*

Treino		
Teste 2.1	63,16%	80,70%
Teste 2.2	100%	
Teste 2.3	78,95%	
Teste 1.1	73,68%	77,19%
Teste 1.2	73,68%	
Teste 1.3	84,20%	
Teste 3.1	63,16%	70,18%
Teste 3.2	63,16%	
Teste 3.3	84,21%	

Para realizar os testes de desempenho final do sistema construídos, elaboramos um protocolo para organizar todas as etapas necessárias, desde a coleta dos sinais até a movimentação final do cursor na tela. O sistema foi exposto à dez voluntários e, para todos, os passos executados foram:

1. Fase de treinamento do sistema, onde é feita uma coleta inicial de sinais EEG e, cada um deles é armazenado com sua classificação, de subida ou descida. Nesta fase, o cursor não se move e serve apenas para criar padrões iniciais de sinal personalizados para o usuário.
2. Treinamento de uma rede neural inicial,  $RNA_0$ , utilizando agora as amostras rotuladas de sinal, geradas na fase 1, e arquitetura e parâmetros fixos (conforme explicado na sessão VI.1), de forma a prover uma rede personalizada ao usuário. São realizados 50 treinamentos completos na rede neural  $RNA_0$  para selecionar a que apresentou o melhor desempenho, utilizando limiar de separação de classes igual a 0,5.
3. Ocorre uma nova coleta de sinais EEG e agora cada um deles será classificado pela  $RNA_0$  como sendo um sinal de subida ou descida. O cursor será movido de forma a corresponder à classificação realizada.

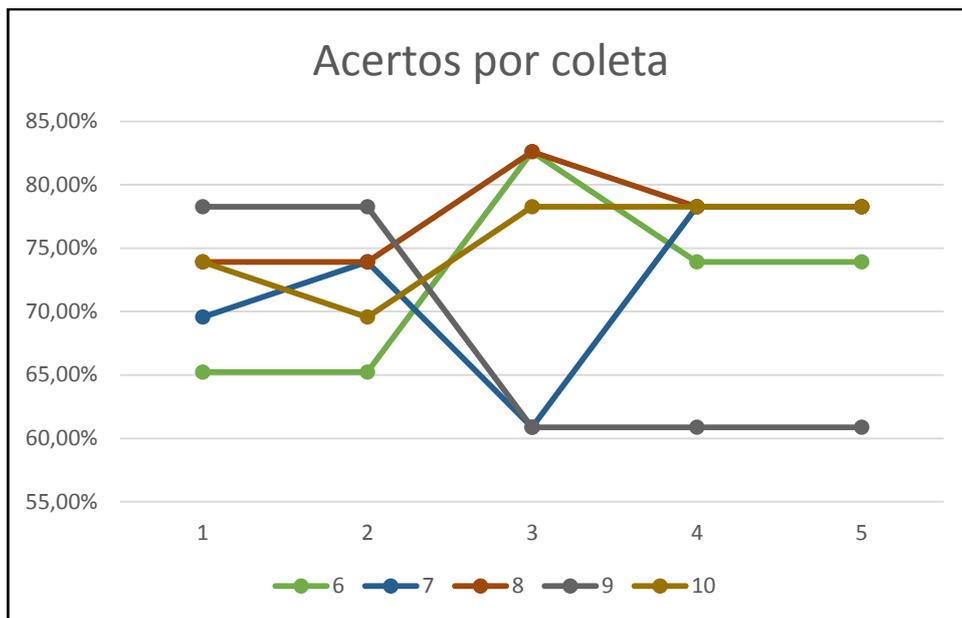
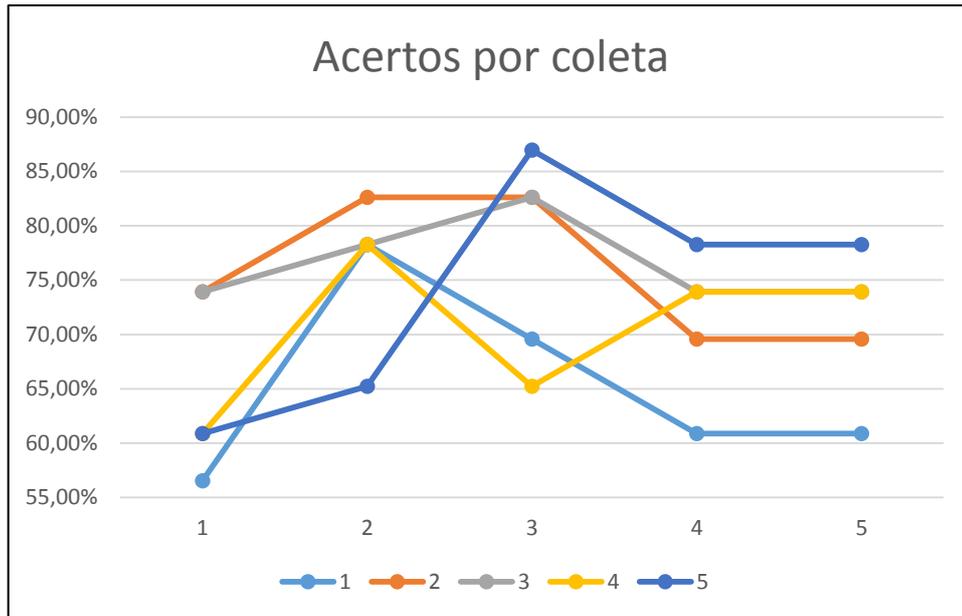
4. Treinamento de uma nova rede neural, RNA<sub>1</sub>, utilizando agora as amostras rotuladas de sinal, geradas na fase 3, com a mesma arquitetura e parâmetros fixos da rede anterior, de forma a prover uma rede atualizada para o usuário, supondo que sua habilidade deverá ter melhorado após o experimento inicial. Novamente, foram realizados 50 treinamentos completos na rede neural RNA<sub>1</sub> para selecionar a que apresentou o melhor desempenho, utilizando limiar de separação de classes igual a 0,5.
5. As etapas 3 e 4 são repetidas duas vezes até treinarmos a rede RNA<sub>3</sub>, o que corresponde a quatro baterias de testes.
6. Fase de testes finais, dividida em duas etapas:
  - 6.1. Na primeira, apenas o sinal de EEG é usado para classificar cada sinal coletado e mover o cursor no sentido indicado pela rede personalizada do usuário. O resultado mostrado para o usuário sempre usa o limiar 0.5.
  - 6.2. Na segunda, após a classificação do sinal, na etapa 6.1, utiliza-se o sinal GSR (eletrodermal) para realizar a correção da direção do cursor na tela, conforme explicado na sessão VII.1.2

O experimento dura em média 35 minutos, desde a etapa de esclarecimento dos procedimentos aos voluntários até o término do item 6.2. A

Tabela 4 mostra o desempenho obtido após a execução dos passos 1 a 6.1 do algoritmo acima e de sua análise podemos constatar que é durante a coleta 1 (ou seja, a segunda coleta realizada) o usuário consegue o melhor desempenho, que logo em seguida tende a diminuir. Podemos explicar isso pelas características intrínsecas do experimento, que causou um certo cansaço a todos os participantes. Dois casos interessantes são os que se referem ao voluntário 2 e 9, que estavam visivelmente preocupados antes do experimento e assim continuaram até o fim. Para esses pudemos constatar que o desempenho final foi inferior ao da coleta 0, o que não deveria ocorrer. De fato, esses foram os únicos casos em que isso ocorreu e refletem o estado de tensão em que os mesmos se mantiveram durante todo o procedimento de treinamento.

*Tabela 4 – Estatísticas extraídas da etapa de treinamento da rede*

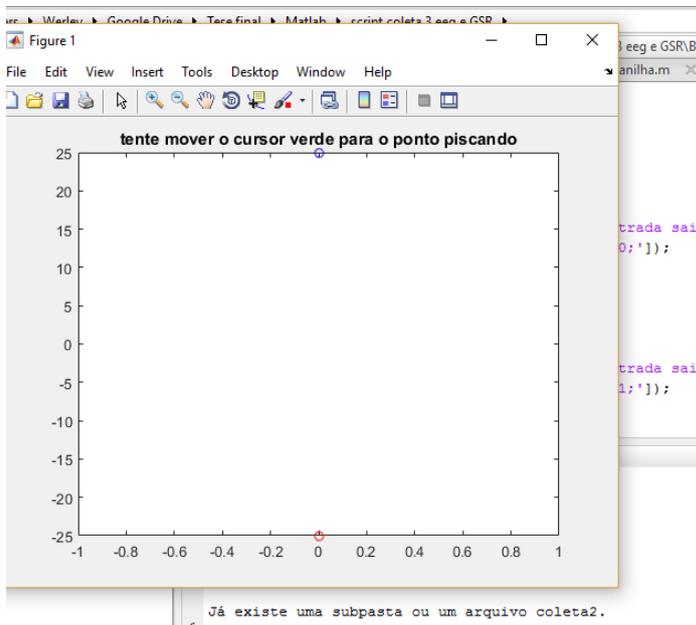
Voluntario	Desempenho (acertos)				
	Coleta 0	Coleta 1	Coleta 2	Coleta 3	Coleta 4
1	56,52%	78,26%	69,57%	60,87%	60,87%
2	73,91%	82,61%	82,61%	69,57%	69,57%
3	73,91%	78,26%	82,61%	73,91%	73,91%
4	60,87%	78,26%	65,22%	73,91%	73,91%
5	60,87%	65,22%	86,96%	78,26%	78,26%
6	65,22%	65,22%	82,61%	73,91%	73,91%
7	69,57%	73,91%	60,87%	78,26%	78,26%
8	73,91%	73,91%	82,61%	78,26%	78,26%
9	78,26%	78,26%	60,87%	60,87%	60,87%
10	73,91%	69,57%	78,26%	78,26%	78,26%



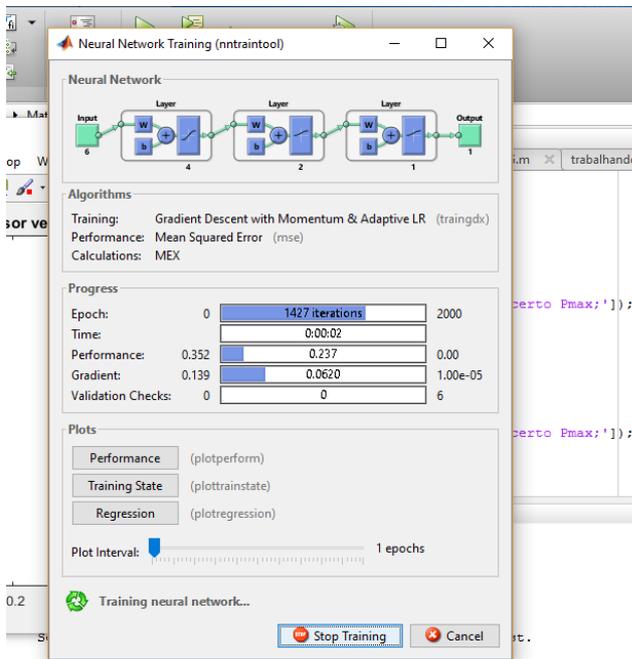
Na, Figura 26 mostramos a tela apresentada quando ele tem que pensar no movimento e o treinamento da Rede Neural, momento no qual o usuário descansa entre as fases de coletas.

Nas Figura 27 a Figura 36 a seguir, mostramos as curvas de distribuição dos sinais de saída de acordo com o seu respectivo grupo, para os pensamentos de subida (verde) e de descida (vermelho), fornecidas pelas redes neurais personalizadas de cada usuário em cada bateria de testes realizados. Da análise desses gráficos, podemos perceber que as duas distribuições são de fato distintas, principalmente durante as coletas 0 e 1 (ou seja, as primeiras e segundas coletas realizadas). Nas coletas seguintes, o desempenho começa a cair,

o que pode ser comprovado pela aproximação maior entre as curvas, aumentando a área de confusão entre os padrões de sinais.



(a)



(b)

Figura 26 - Interface gráfica com o usuário: (a) interação com o usuário; (b) descanso do usuário e treinamento da rede

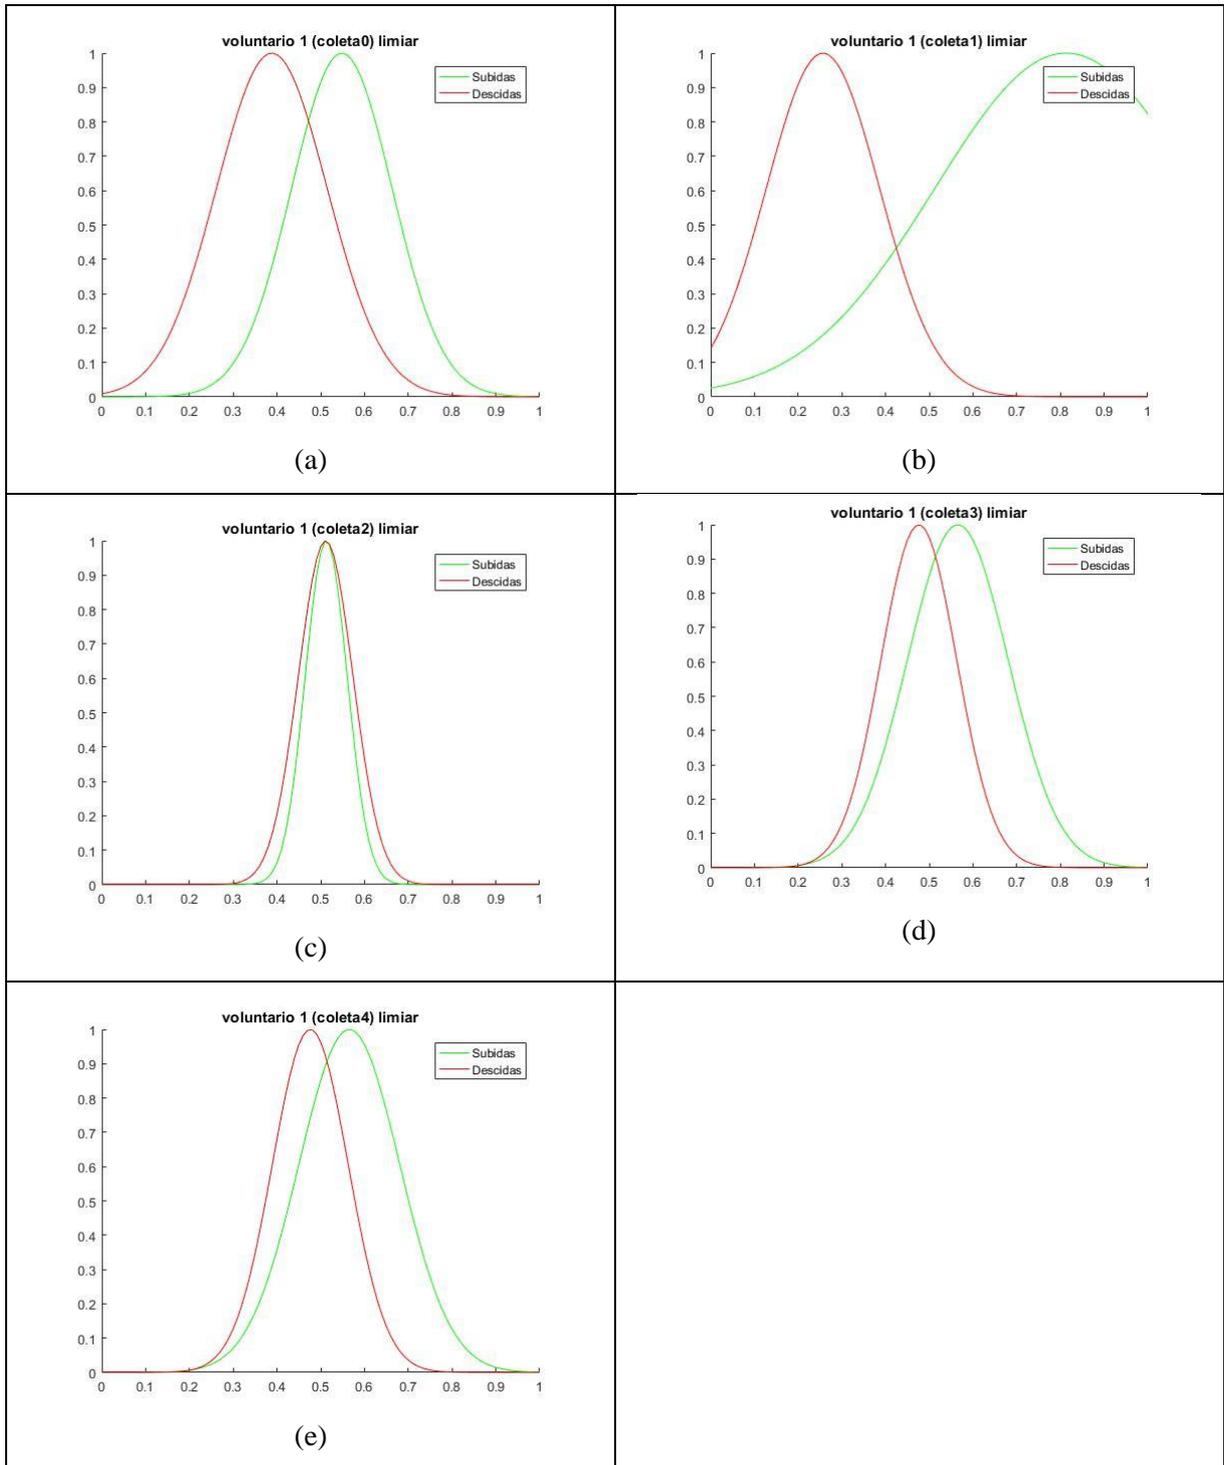


Figura 27: voluntario 1 – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

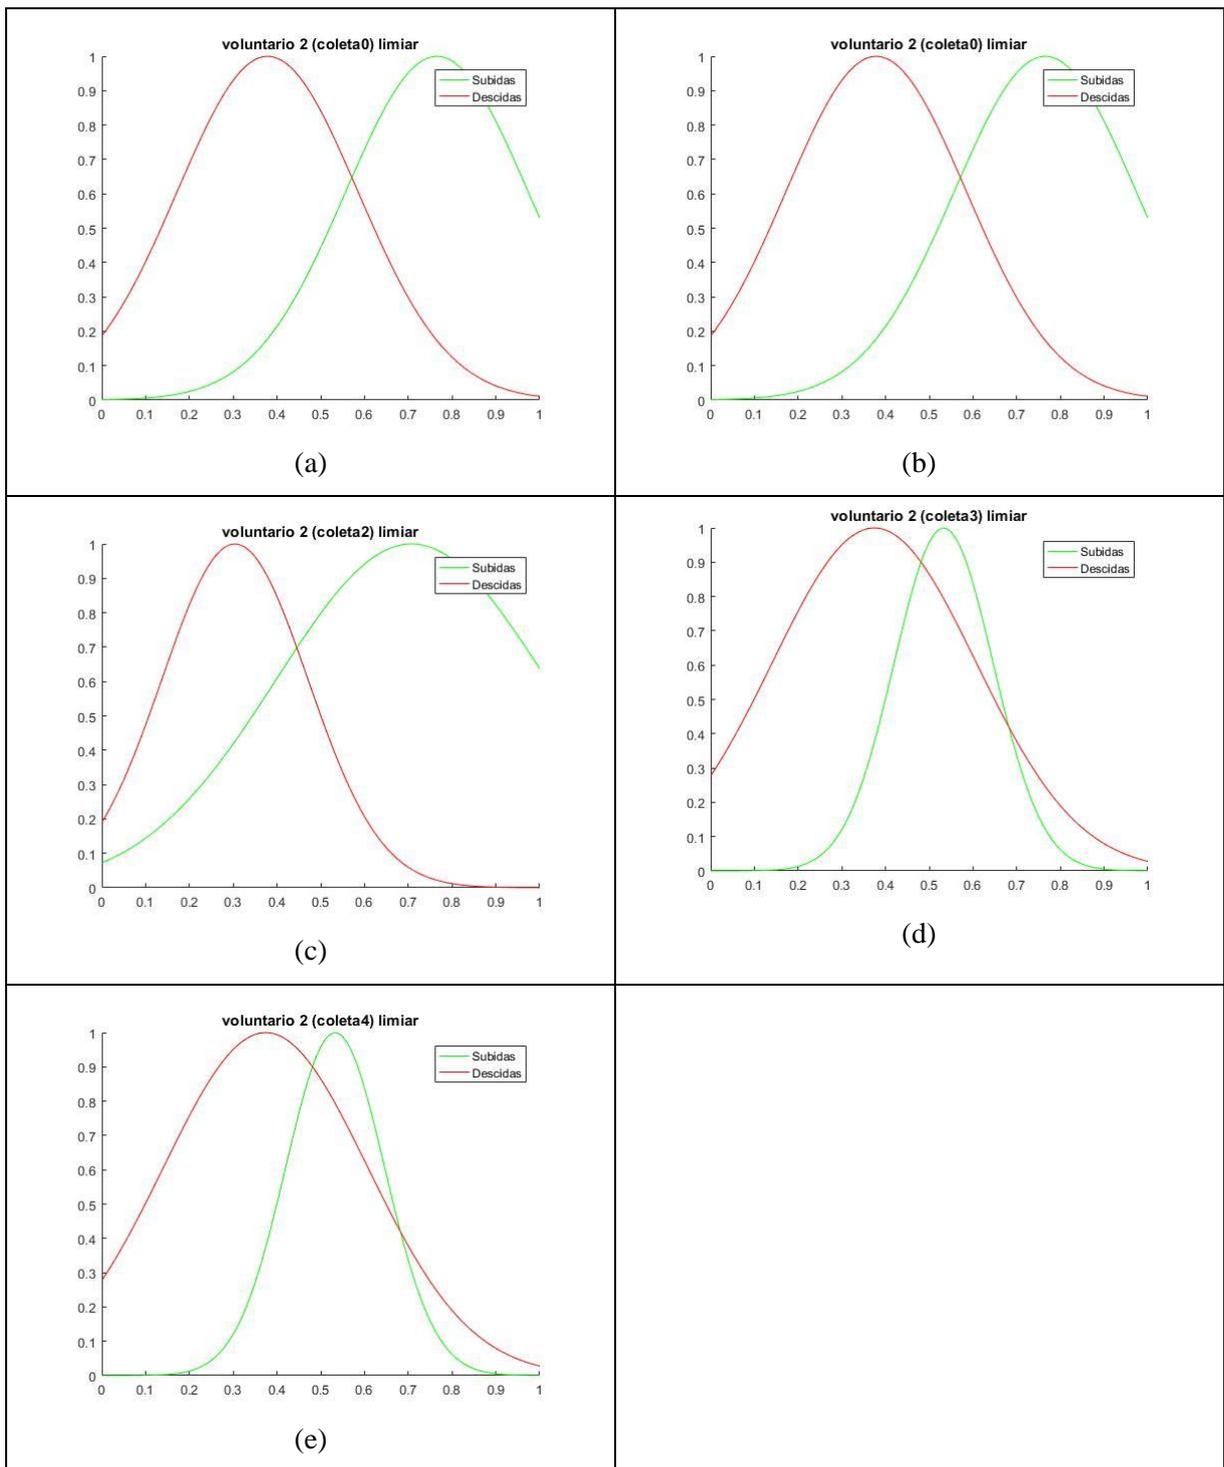


Figura 28: voluntario 2 – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

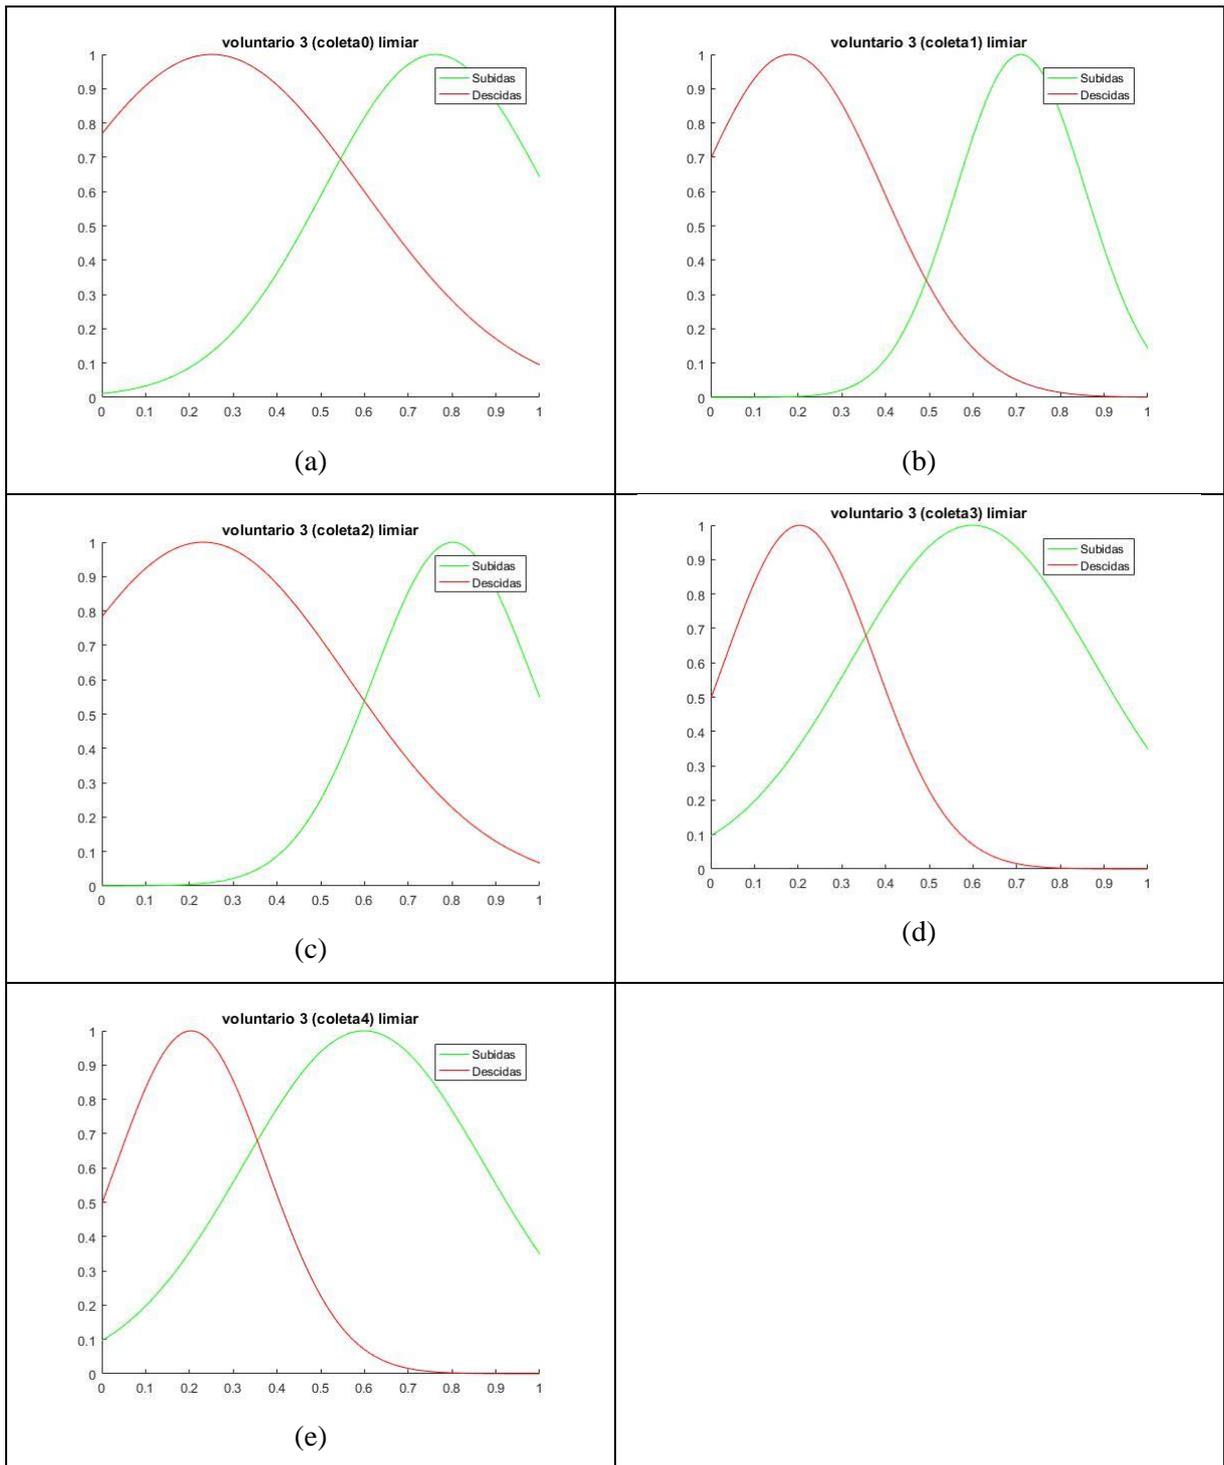


Figura 29: voluntario – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

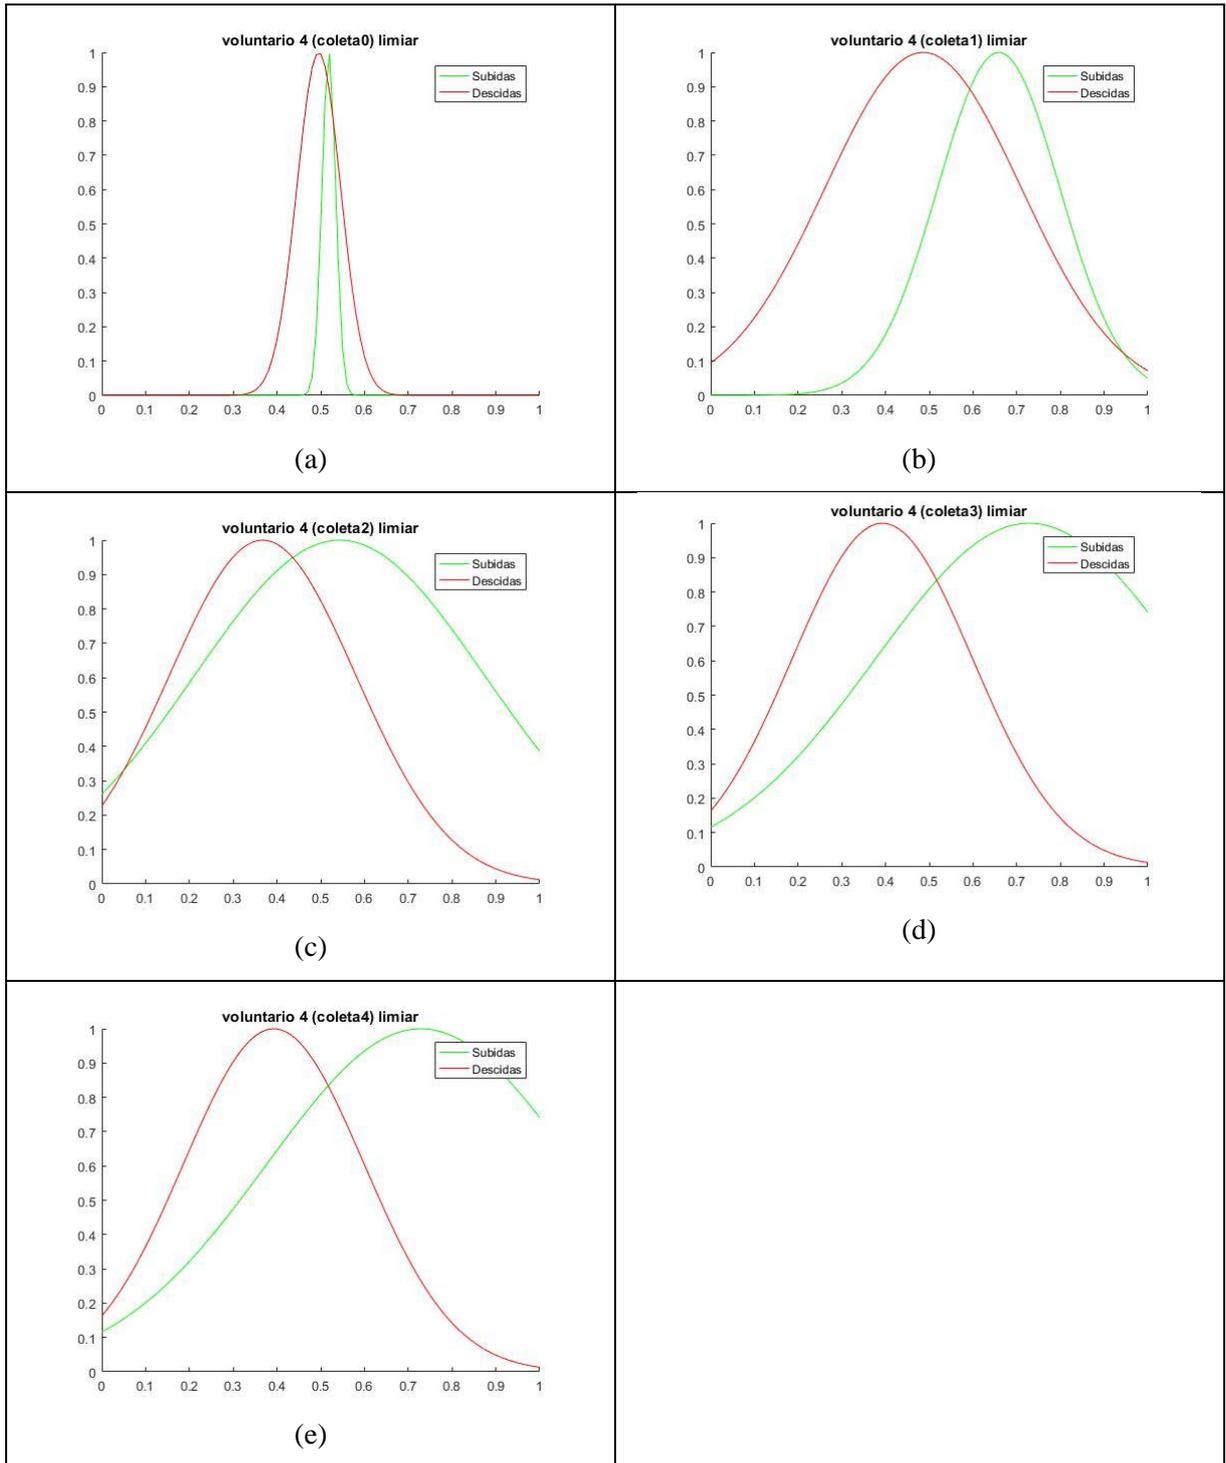


Figura 30: voluntario 4 – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

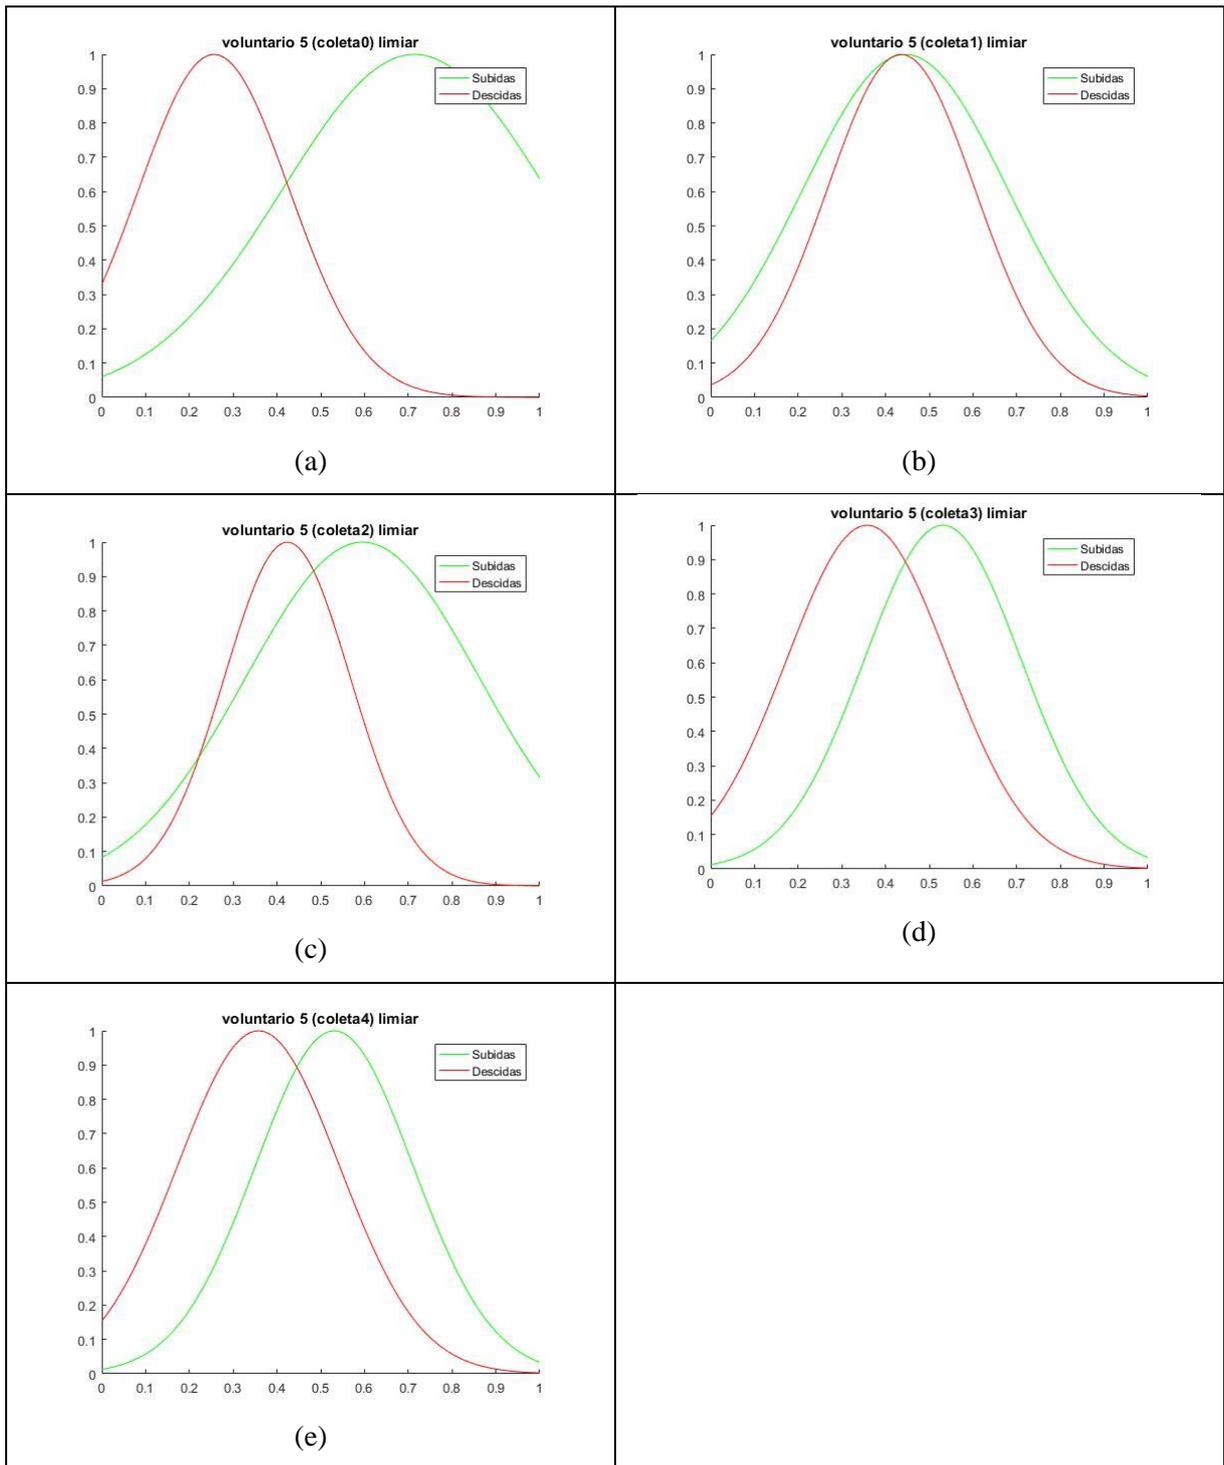


Figura 31: voluntario 5 – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

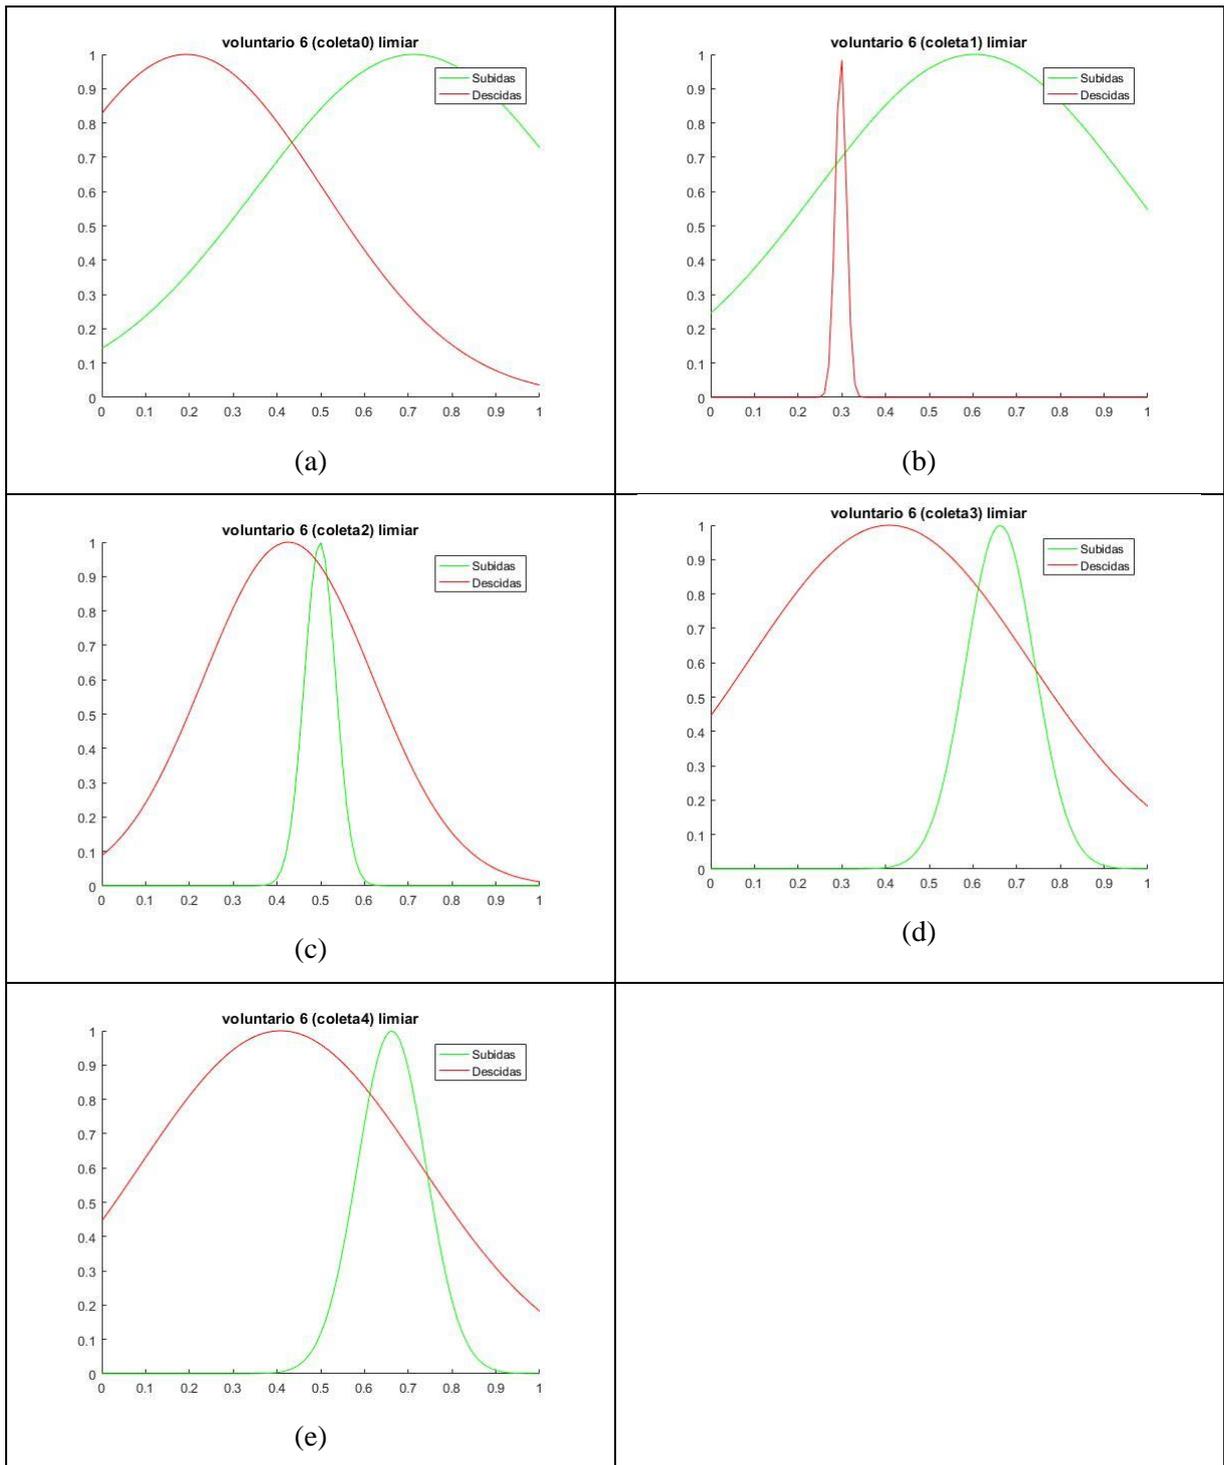


Figura 32: voluntario 6 – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

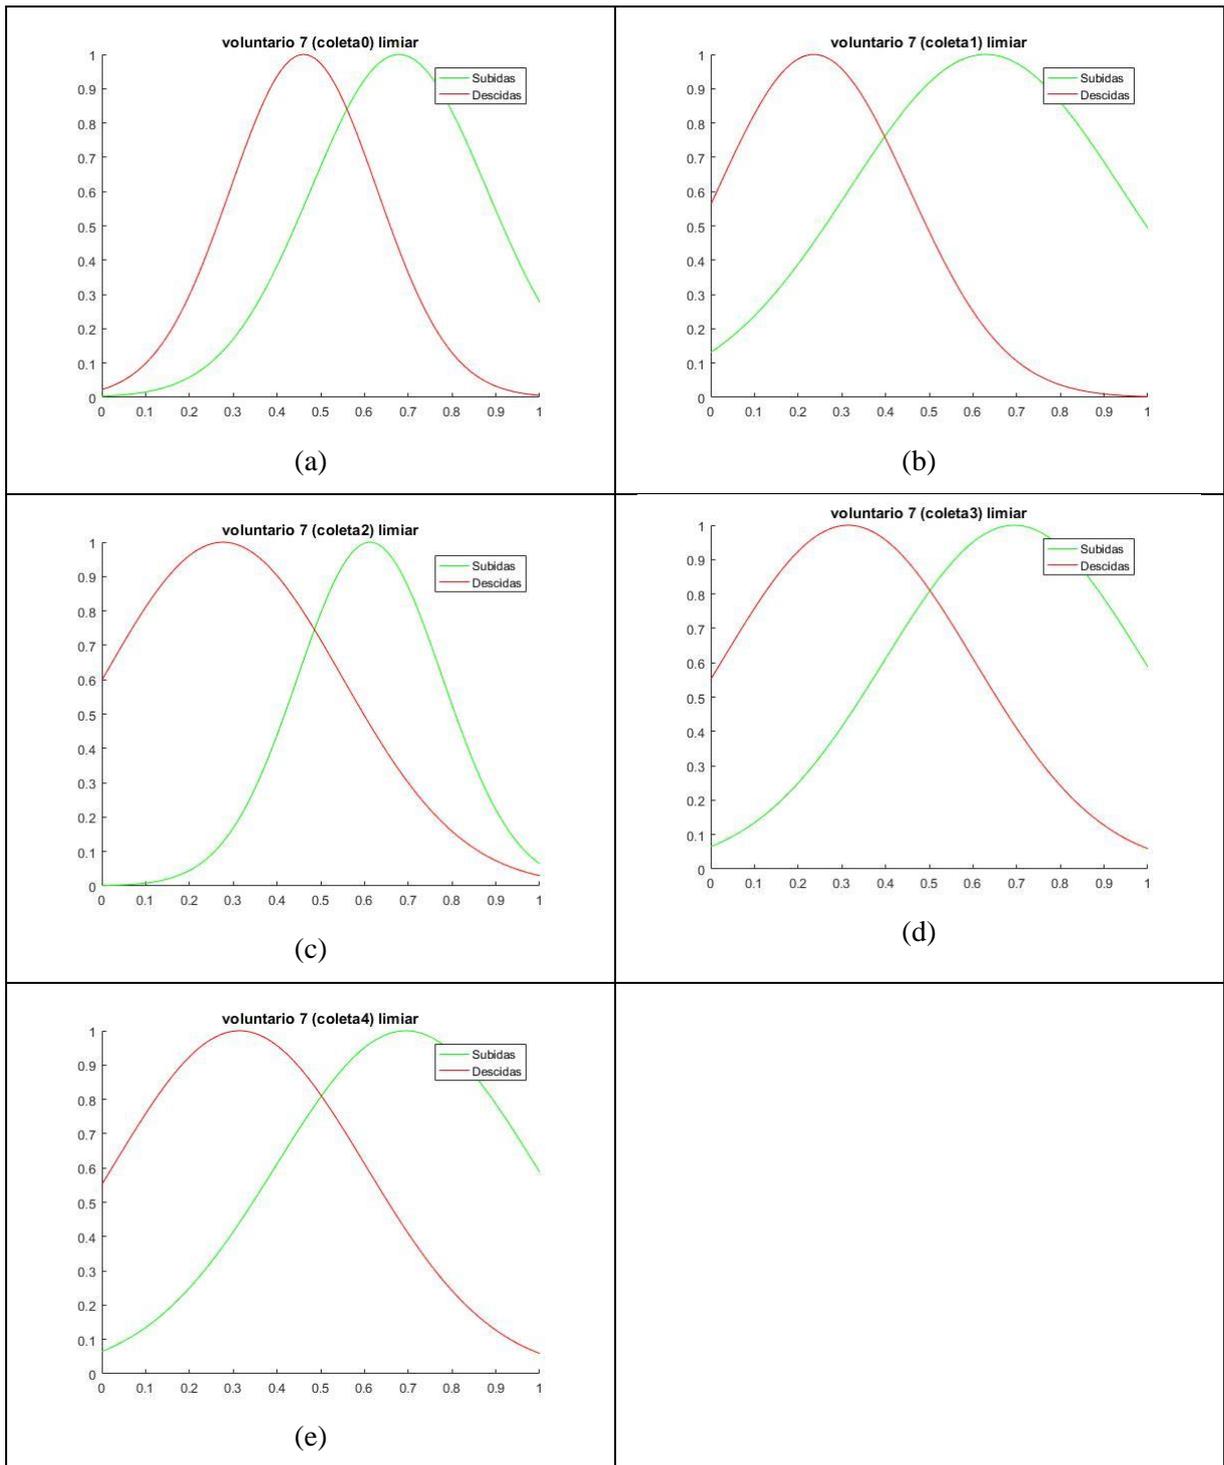


Figura 33: voluntario 7 – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

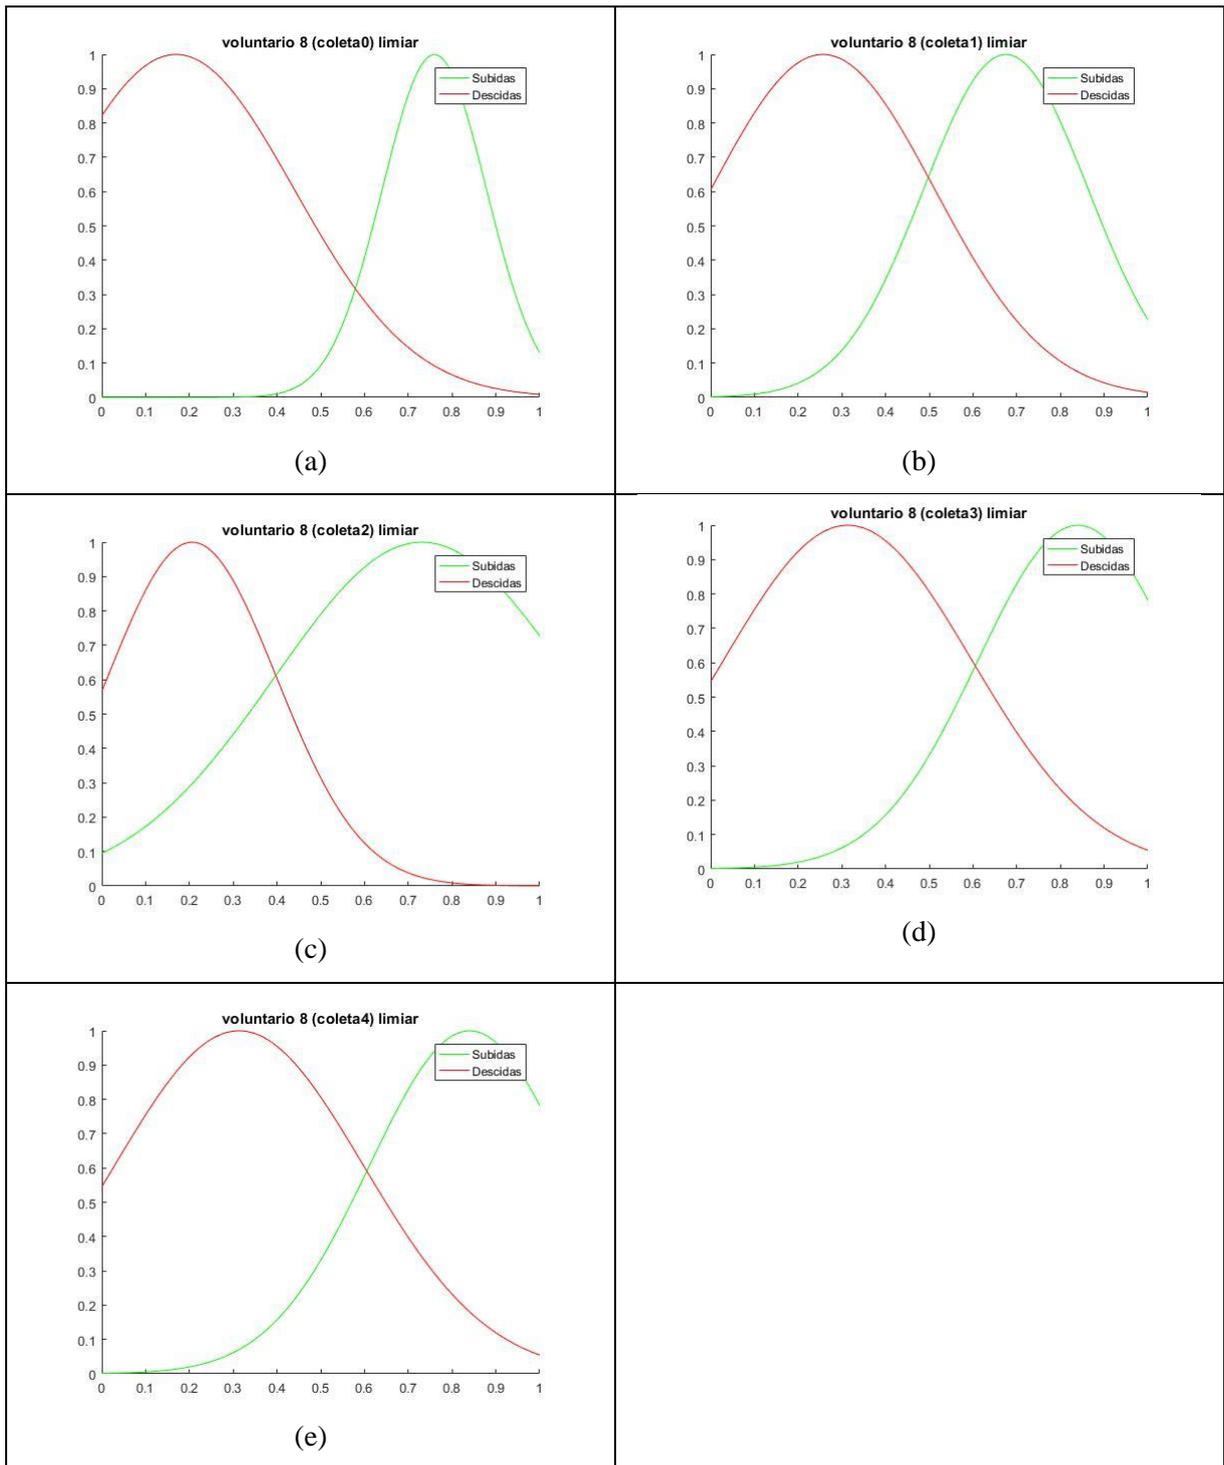


Figura 34: voluntario 8 – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

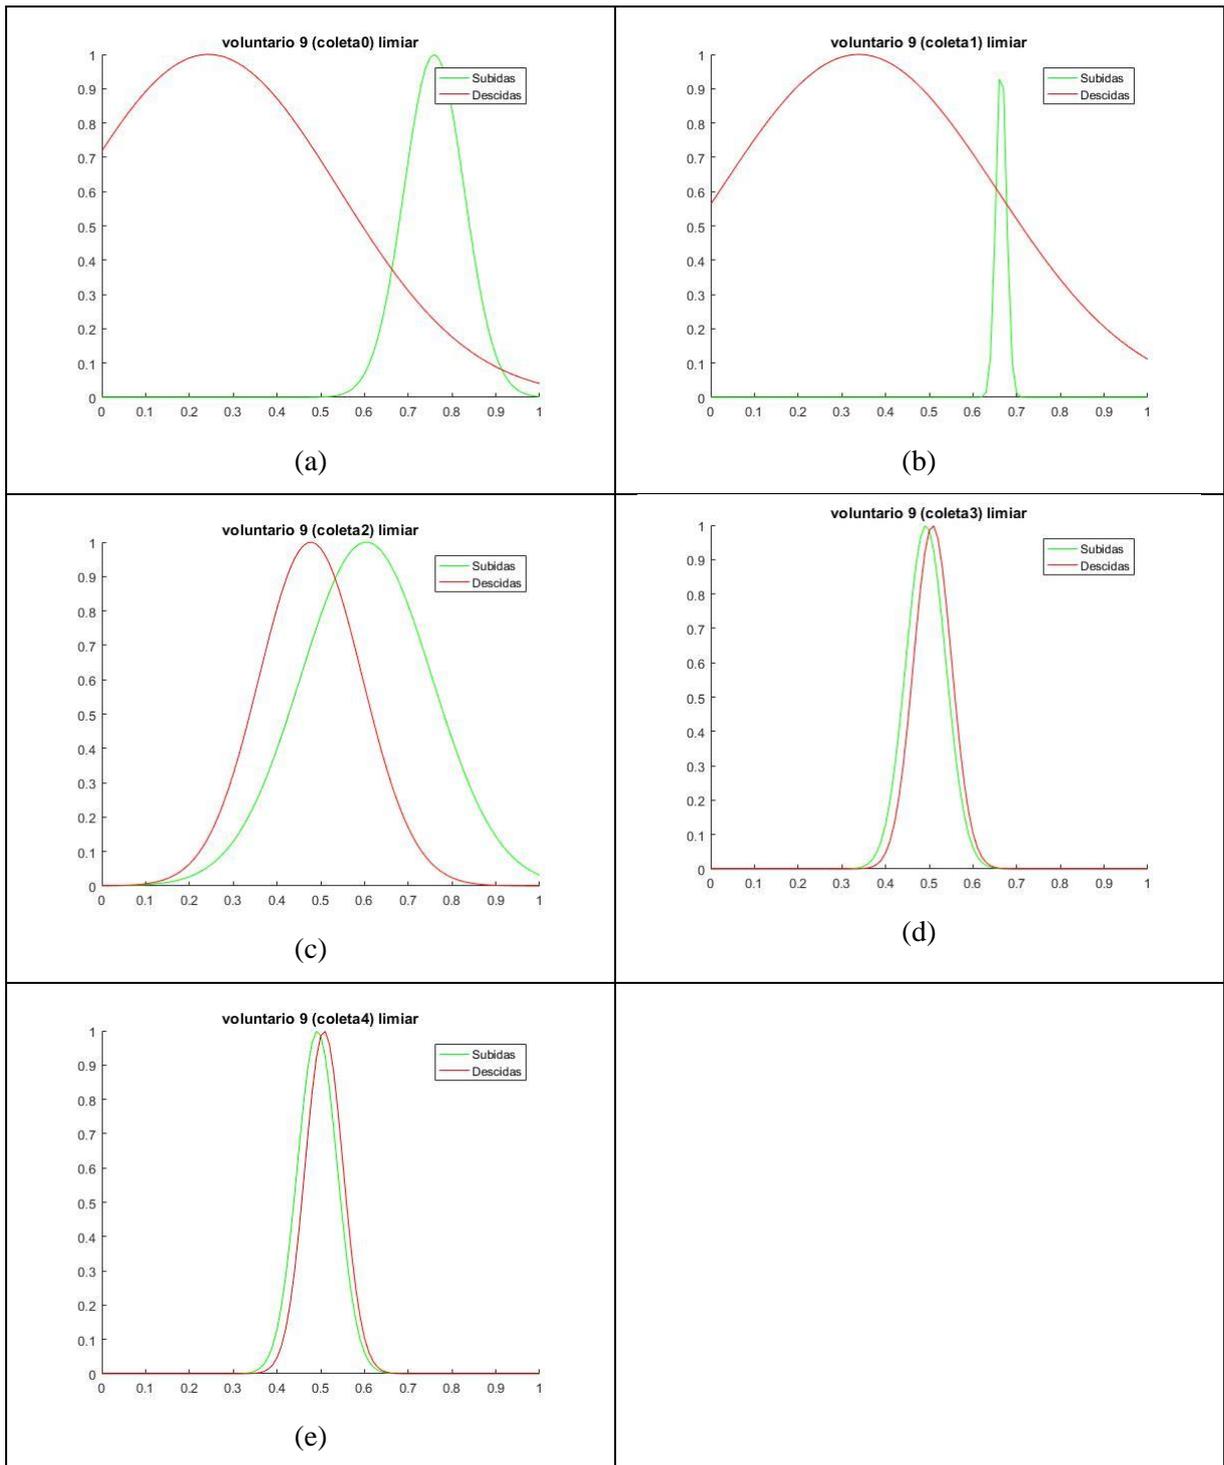


Figura 35: voluntario 9 – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

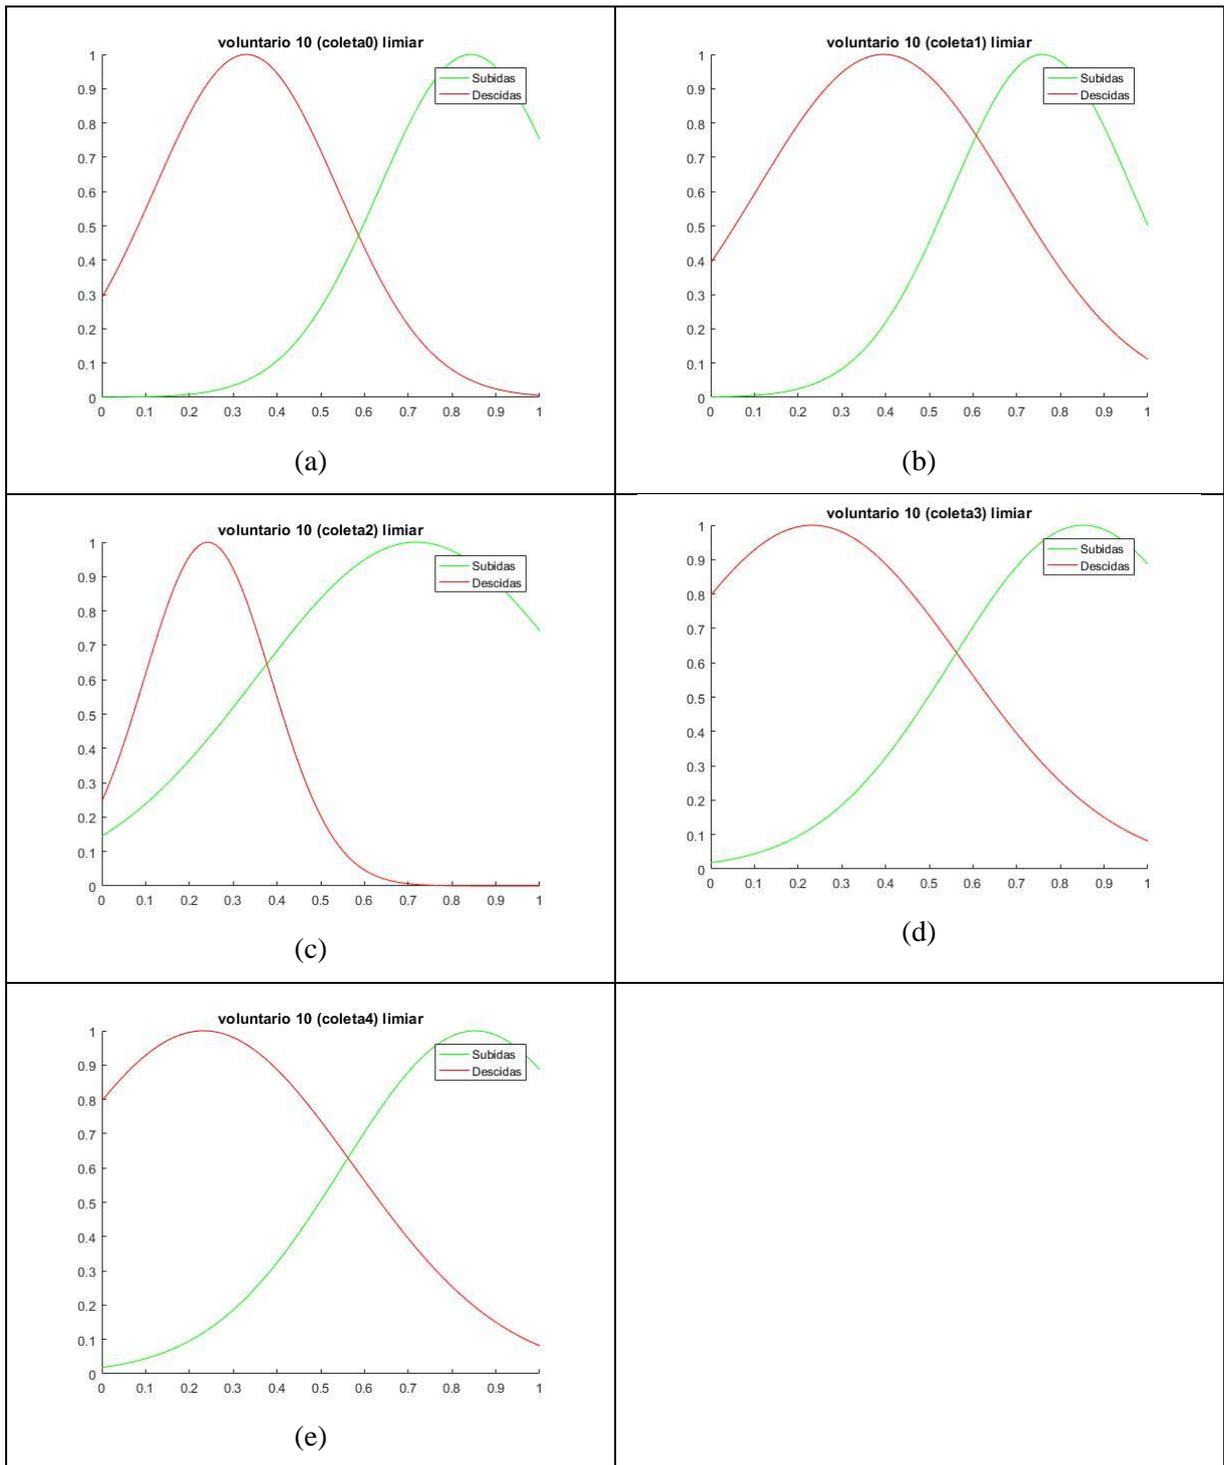


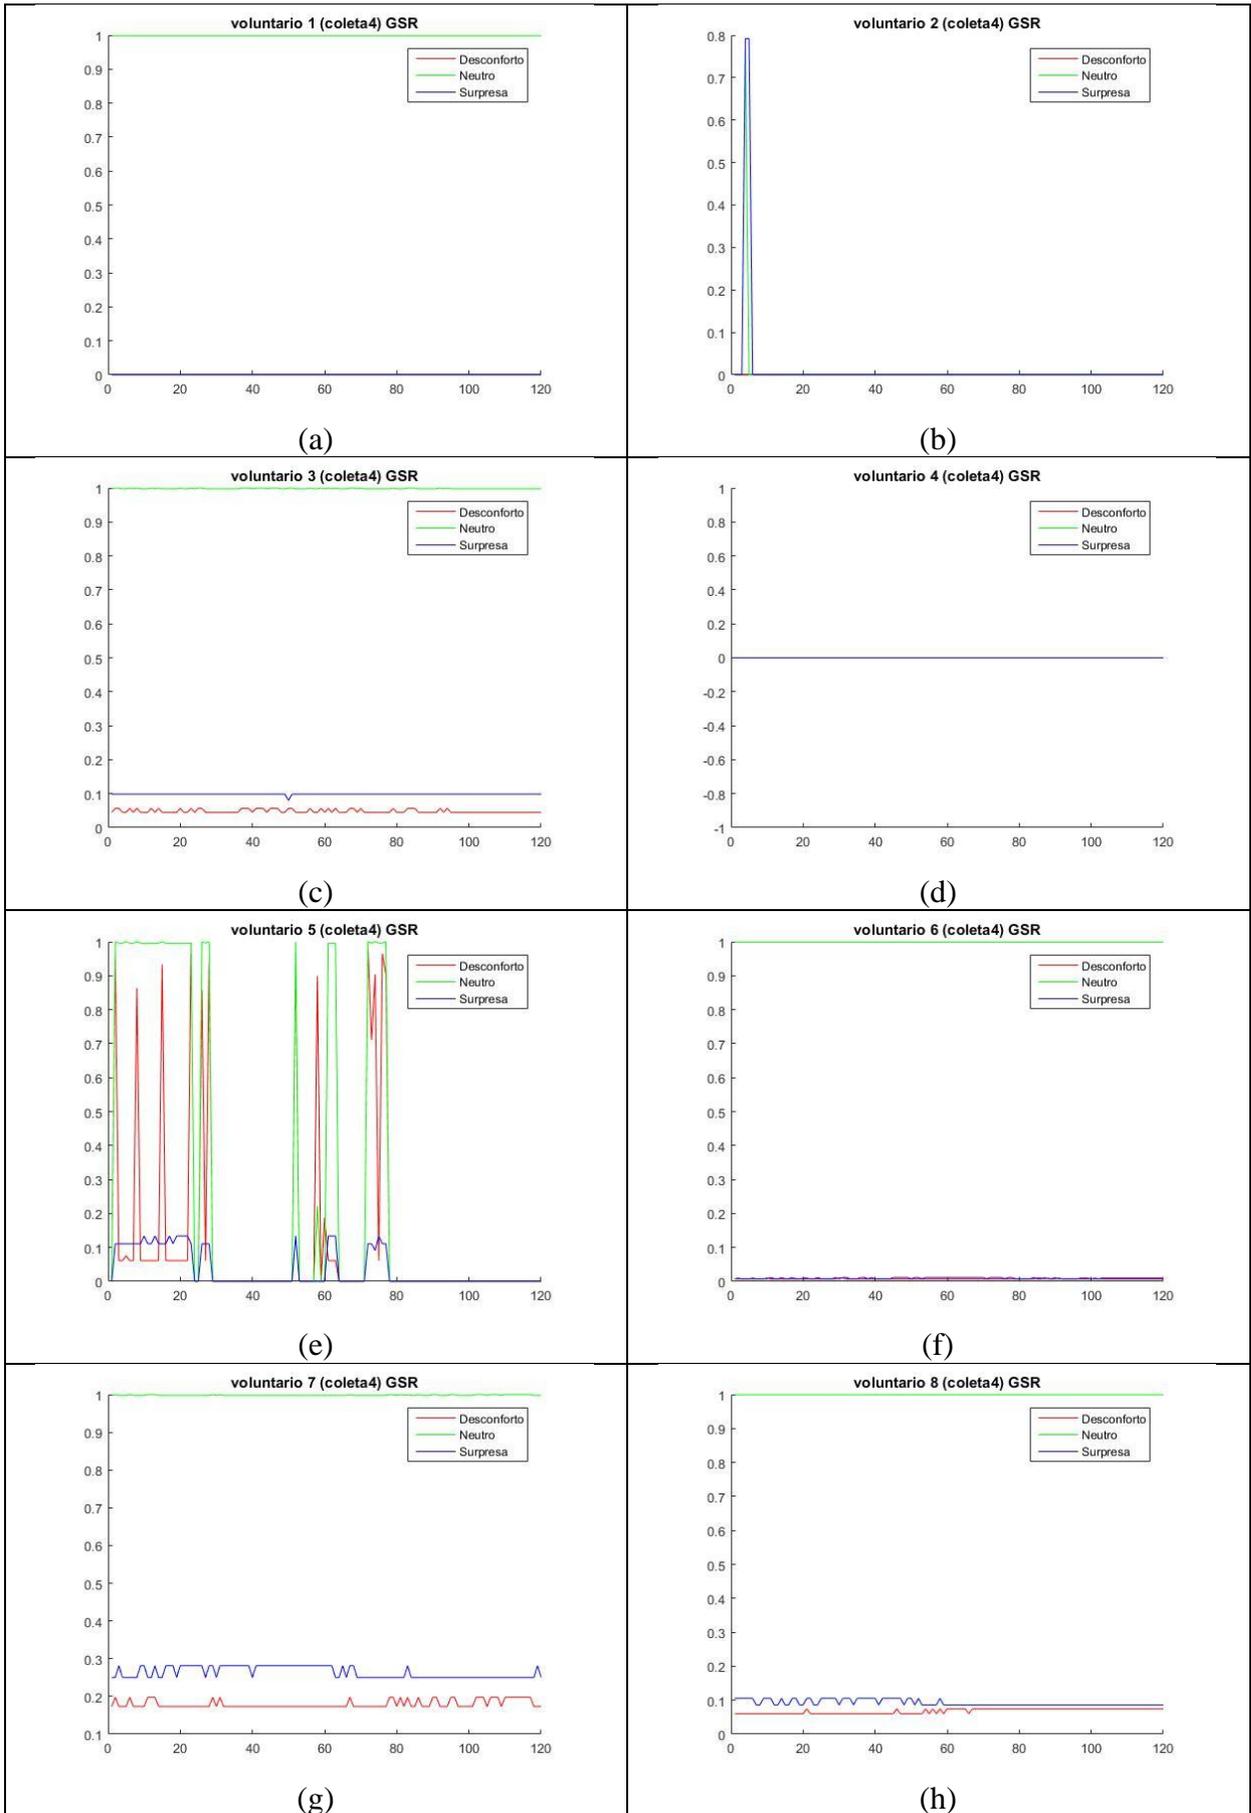
Figura 36: voluntario 10 – Distribuição dos sinais correspondentes aos pensamentos de subida e descida no decorrer do experimento.

O experimento mostrou ainda que os voluntários obtiveram melhor desempenho utilizando somente a onda  $\mu$  (EEG) para movimentar o cursor, mas ao contrário do esperado o sinal eletrodermal (GSR) não alterou em nada o desempenho da rede. Na etapa 6.2 (coleta 4), percebemos que o uso do GSR para a correção da trajetória do cursor (classificação pela rede personalizada, seguida da aplicação da correção da saída, de acordo com os valores do sinal GSR). Pode-se atribuir ao desempenho nulo desse sinal ao pouco treino que o usuário teve

com esta nova variável, somente uma bateria de testes, fazendo com que todos os valores coletados fossem classificados como neutro e não alterassem a trajetória do cursor.

O comportamento do sinal pode ser visto na Figura 37, em que observa-se que os usuários exprimiram um comportamento de desconforto sempre abaixo do que foi modelado para as curvas de distribuição do sinal GSR, tendo apresentado uma predominância do sinal “neutro” durante todo o tempo da última coleta.

Essa constatação, porém, não descarta a utilização dessa técnica em estudos futuros, pelo contrário, porém com uma alteração no procedimento. Nossa ideia é, similarmente ao que foi feito com o sinal EEG, coletarmos o padrão de emissão do GSR para cada usuário através da aplicação de um questionário que induza o usuário aos três tipos de sentimentos (neutro, positivo e negativo), aos moldes do que é feito durante o processo de calibração de um detector de mentiras. Após essa fase de coleta, iremos construir redes neurais que classifiquem esses sinais em separado, para só então o sistema decidir se deve ou não alterar a trajetória do cursor.



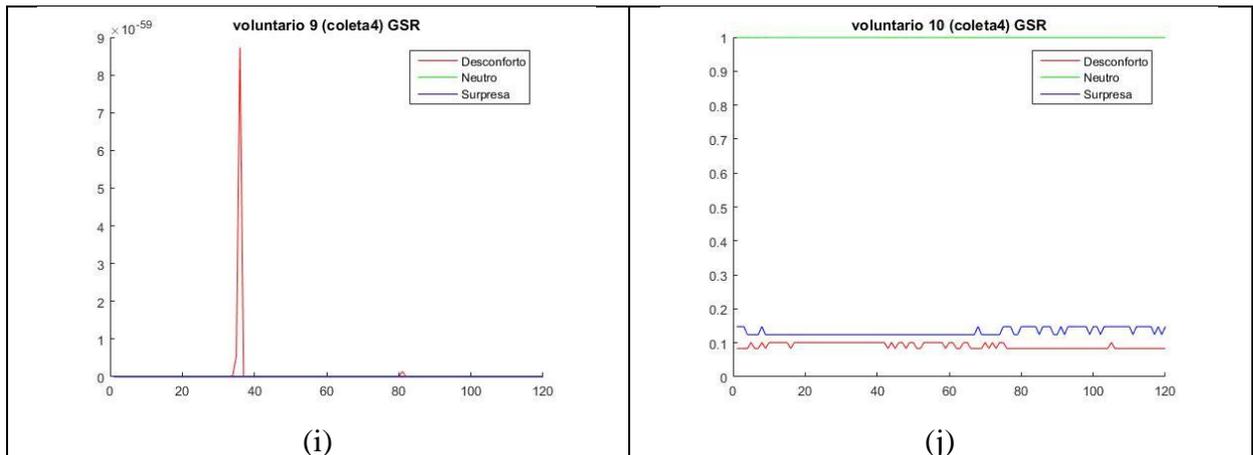


Figura 37 – comportamento do Sinal GSR dos 10 voluntários durante as duas últimas fases finais do experimento.

O experimento durou cerca de 35 minutos e, no decorrer do mesmo, foi possível verificar que, à medida em que o usuário se acostumava com o funcionamento do sistema, o resultado convergia. Esse resultado era esperado e está de acordo com a literatura consultada [17].

## VIII.2 TRABALHOS FUTUROS

Nesse trabalho mostrou-se que é possível construir um aparato de baixo custo para coleta de sinais EEG, se forem voltados exclusivamente a implementação do BCI, rompendo-se assim a barreira de custo dos produtos atualmente vendidos no mercado e que incorporam aplicações genéricas para outras atividades, como laudos médicos. Mostramos que a atividade eletrodermal, por ser um comportamento controlável mentalmente, pode ser usada como BCI, mas achamos que ainda é possível melhorar a modelagem do seu comportamento ou torna-la independente do sinal EEG.

Para trabalhos futuros podemos destacar algumas linhas de trabalho possíveis a partir do conhecimento adquirido neste trabalho.

O sinal GSR é um sinal controlado diretamente pelo sistema límbico[4] este por sua vez também gera os sinais de aprovação e desaprovação que define todas as nossas escolhas e atos [3]. Uma modelagem adequada desse comportamento pode gerar soluções interessantes para pessoas com limitações físicas severas que as impedem de expressar suas necessidades e sentimentos. Visto que o circuito eletrônico usado nesse trabalho tem custo baixo, o uso do GSR pode, mais rapidamente que o BCI convencional, gerar soluções interessantes para a sociedade.

Para se obter resultados melhores na coleta eletrodermal (GSR) acreditamos ser necessário personalizar a modelagem do comportamento dessas curvas, de forma análoga ao que é feito com os polígrafos, conforme explicado anteriormente.

Finalmente, o estudo mostrou que é possível construir um equipamento de baixo custo para aplicações de BCI que, conseqüentemente, poderiam atingir um número maior de potenciais usuários e futuros programadores.

## IX REFERÊNCIAS BIBLIOGRÁFICAS

- [1] LIN, JS. & Hsieh, “A Wireless BCI-Controlled Integration System in Smart Living Space for Patients”, *CH. Wireless Pers Commun*, vol. 88: 395. doi:10.1007/s11277-015-3129-0, 2016.
- [2] AMARAL, J. R; OLIVEIRA, Jorge Martins de. Introdução as Três Unidades do Cérebro Humano Disponível em:< <http://www.cerebromente.org.br/n05/mente/limbic.htm> >. Acesso em: 28 out 2016.
- [3] NISHIDA, S. M., **Neurobiologia das emoções – Sistema Límbico**, Neuro Biologia, Curso de Ciências Biomédicas, UNESP, 55 transparências: color.
- [4] BOUCSEIN, W. (2012). *Electrodermal Activity*, Second Edition. Springer Science+Business Media.
- [5] FAUSETT, L. *Fundamentals of Neural Networks – Architectures, Algorithms and applications*, 1<sup>nd</sup> Edition, Prentice-Hall, pp. 1-37, 59-76, 1994.
- [6] NARENDRA, KUMPATI S. *Adaptative Control Using Neural Networks* .In: SUTTON, Richard S.; WERBOS, Paul J.; MILLER III, W. Thomas, “*Neural Networks for Control*”, MIT Press, vol. 211996. pp.115–142.
- [7] LESKOV, I. F. ; LOPES, H. . “Amplificador e Filtros de Baixo Custo para Sinais de EEG (Eletroencefalografia)”, *In: Simpósio Internacional de Iniciação Científica da USP, São Carlos. XVII Congresso de Iniciação Científica e Tecnológica em Engenharia, 2000.*
- [8] IACOVIELLO, Daniela; PETRACCA, Andrea; SPEZIALETTI, Matteo; PLACIDI, Giuseppe A real-time classification algorithm for EEG-based BCI driven by self-induced emotions, *Computer Methods and Programs in Biomedicine*, Volume 122, Issue 3, 2015, Pages 293-303, ISSN 0169-2607, Disponível em: <<http://dx.doi.org/10.1016/j.cmpb.2015.08.011> >. Acesso em: 28 out 2016.
- [9] NOTEBOOM, J. T.; FLESHNER, M.; ENOKA, R. M., “Activation of the arousal response can impair performance on a simple motor task”, *Journal of Applied Physiology*, vol. 91, pp.:821-831, 2001.
- [10] SUAREZ, L. F; CARDOZO, Eleri; SORIANO, Diogo C.. (s.d.). Um Sistema para Brain-Computer Interface (BCI) Baseado em SSVEP, *in: ENCONTRO DE ALUNOS E DOCENTES DO DCA, VI, 2013*, pp 72-75, 2013

- [11] GODÓI, A. C. B., **Detecção de Potenciais Evocados P300 para Ativação de uma Interface Cérebro-Máquina**, pp. 12-38, 48-53 ,Dissertação para título de Mestrado Escola Politécnica da USP, 2010.
- [12] ZHAO, J., Li, W., & Li, M.. *Comparative Study of SSVEP- and P300-based Models for the Telepresence Control of Humanoid Robots*. PLoS ONE 10(11): e0142168. doi:10.1371/journal.pone.0142168, 2015.
- [13] MALMIVUO, J.; PLONSEY, J. M. *Electroencephalography in: Bioelectromagnetism*, New York: Oxford University Press, cap 13, 1995
- [14] NAJARIAN, Kayvan; SPLINTER, Robert. (s.d.). Electroencephalogram *in: Biomedical Signal and Image Processing*, CRC Press – Taylor & Francis Group, pp 197-216, 2006.
- [15] JÚNIOR, Antônio Pertence. **Amplificadores Operacionais e Filtros Ativos – Teoria, Projetos, Aplicações e Laboratório**, 6ª Edição, Bookman, 2007.
- [16] FILHO, Kepler de Souza Oliveira, Transformadas de Fourier, Extraído de: < <http://astro.if.ufrgs.br/med/imagens/fourier.htm> >, em 28 de junho, 2011
- [17] WOLPAW, Jonathan R.; McFarland, Denis J.; NEAT, Gregory W; Forneris, Catherine A. *An EEG-Based Brain-Computer Interface for Cursor Control. In: Eletroencephalography and Clinical Neurophysiology*, pp. 252-259, Aug. 1991.
- [18] BLAIN, Stefanie; MIHAILIDIS, Alex; CHAU, Tom. Assessing the Potential of Electrodermal Activity as an Alternative Access Pathway. *In Medical Engineering Physics*, pp 498-505, 2008
- [19] JIANG, Jun; ZHOU, Zongtan; YIN, Erwei; YU, Yang; LIU, Yadong; HU, Dewen. A novel Morse code-inspired method for multiclass motor imagery brain-computer interface (BCI) design, *Computers in: Biology and Medicine*, Volume 66, 2015, Pages 11-19
- [20] Boucsein, Wolfram. *Principles of Electrodermal Phenomena in: Eletrodermal Activity second Edition*: New York: Springer, 2012, pp. 1-76.
- [21] Grove – GSR Sensor Introduction. Disponível em: <[http://wiki.seeed.cc/Grove-GSR\\_Sensor/](http://wiki.seeed.cc/Grove-GSR_Sensor/)>. Acesso em: 30 jun. 2017

- [22] Eletroencefalografia – sistema 10-20. Disponível em:  
<[https://pt.wikipedia.org/wiki/Eletroencefalografia\\_sistema\\_10-20](https://pt.wikipedia.org/wiki/Eletroencefalografia_sistema_10-20)> Acesso em: 30 jun.  
2017
- [23] Multilayer Neural Network Architecture. Disponível em:  
<<https://www.mathworks.com/help/nnet/ug/multilayer-neural-network-architecture.html> >  
Acesso em: 30 jun. 2017
- [24] HAYKIN, S., Redes Neurais Princípios e Prática 2ª edição, Bookman, pp 25-230,  
2001
- [25] BRAGA, A. P., CARVALHO, A. P. L. F., LUDEMIR, T. B., Fundamentos de Redes  
Neurais Artificiais, 11ª Escola de Computação, Imprinta Gráfica e Editora Ltda, 1998
- [26] TSUKAHANA, Reiko, AOKI, Hisashi. *Skin potential response in letter recognition  
task as an alternative communication channel for individuals with severe motor disability.*  
Clinical Neurophysiology 2002, pp 1723–1733.

## **X ANEXOS**



SERVIÇO PÚBLICO FEDERAL  
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
COMISSÃO DE ÉTICA NA PESQUISA DA UFRRJ / COMEP

Protocolo N° 852/16

**PARECER**

O Projeto de Pesquisa intitulado “*Utilização do sinal eletrodermal no aprendizado de reforço em aplicações de Interface Cérebro-Computador*” sob a responsabilidade do Prof.<sup>a</sup> Gizelle Kupac Viana, do Laboratório de Inteligência Artificial, Instituto de Ciências Exatas, processo 23083.010361/2016-62, atende os princípios éticos e está de acordo com a Resolução 466/12 que regulamenta os procedimentos de pesquisa envolvendo seres humanos.

UFRRJ,05/04/17.

Prof.<sup>a</sup> Dra. Lucía Helena Cunha dos Anjos  
Pró-Reitora Adjunta de Pesquisa e Pós-Graduação