

Universidade de Brasília – UnB
Campus Gama – FGA
Programa de Pós-Graduação em Engenharia Biomédica

**DESENVOLVIMENTO E AVALIAÇÃO DE UM SISTEMA DE
ESPECTROSCOPIA FUNCIONAL DE INFRAVERMELHO PRÓXIMO
PARA DETECÇÃO DE MOVIMENTO INTENCIONAL
COM BASE NA ATIVIDADE CEREBRAL**

FERNANDO VINÍCIUS GONÇALVES DE SOUZA

Orientador: DR. CRISTIANO JACQUES MIOSSO



UNB – UNIVERSIDADE DE BRASÍLIA

FGA – FACULDADE GAMA



Programa de
Pós-Graduação em
ENGENHARIA BIOMÉDICA

**DESENVOLVIMENTO E AVALIAÇÃO DE UM SISTEMA DE
ESPECTROSCOPIA FUNCIONAL DE INFRAVERMELHO PRÓXIMO
PARA DETECÇÃO DE MOVIMENTO INTENCIONAL
COM BASE NA ATIVIDADE CEREBRAL**

FERNANDO VINÍCIUS GONÇALVES DE SOUZA

ORIENTADOR: DR. CRISTIANO JACQUES MIOSSO

DISSERTAÇÃO DE MESTRADO EM
ENGENHARIA BIOMÉDICA

PUBLICAÇÃO: 127A/2020

BRASÍLIA/DF, AGOSTO DE 2020


UNB – UNIVERSIDADE DE BRASÍLIA
FGA – FACULDADE GAMA
PROGRAMA DE PÓS-GRADUAÇÃO

DESENVOLVIMENTO E AVALIAÇÃO DE UM SISTEMA DE
ESPECTROSCOPIA FUNCIONAL DE INFRAVERMELHO PRÓXIMO
PARA DETECÇÃO DE MOVIMENTO INTENCIONAL
COM BASE NA ATIVIDADE CEREBRAL

FERNANDO VINÍCIUS GONÇALVES DE SOUZA


DISSERTAÇÃO DE MESTRADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA BIOMÉDICA

APROVADA POR:



Dr. Cristiano Jacques Miosso

(Orientador)



Dr. Adson Ferreira da Rocha

(Examinador interno)



Dr^a Mylène Christine Queiroz de Farias

(Examinador externo)

FICHA CATALOGRÁFICA

SOUZA, FERNANDO

Desenvolvimento e avaliação de um sistema de espectroscopia funcional de infravermelho próximo para detecção de movimento intencional com base na atividade cerebral.

[Distrito Federal], 2020.

85p., 210 × 297 mm (FGA/UnB Gama, Mestrado em Engenharia Biomédica, 2020).

Dissertação de Mestrado em Engenharia Biomédica, Faculdade UnB Gama, Programa de Pós-Graduação em Engenharia Biomédica.

- | | |
|----------------------------------|------------------------------------|
| 1. Classificação de Sinais | 2. Espectroscopia de Infravermelho |
| 3. Tomografia por Difusão Óptica | 4. Imageamento Motor |
| I. FGA UnB/UnB. | II. Título (série) |

REFERÊNCIA

SOUZA, FERNANDO (2020). Desenvolvimento e avaliação de um sistema de espectroscopia funcional de infravermelho próximo para detecção de movimento intencional com base na atividade cerebral. Dissertação de mestrado em engenharia biomédica, Publicação 127A/2020, Programa de Pós-Graduação, Faculdade UnB Gama, Universidade de Brasília, Brasília, DF, 85p.

CESSÃO DE DIREITOS

AUTOR: Fernando Vinícius Gonçalves de Souza

TÍTULO: Desenvolvimento e avaliação de um sistema de espectroscopia funcional de infravermelho próximo para detecção de movimento intencional com base na atividade cerebral

GRAU: Mestre

ANO: 2020

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

fernandovinicius1708@gmail.com

Brasília, DF – Brasil

AGRADECIMENTOS

Gostaria de agradecer a meu orientador, Prof. Cristiano Jacques, pelos ensinamentos e orientações durante a pesquisa. É um professor que teve e tem uma grande influência na minha vida acadêmica. Agradeço, também, a meu amigo Lucas Silva Lopes, egresso do PPGEB-UnB, que me auxiliou bastante durante a fase inicial de desenvolvimento desse trabalho.

Aos profissionais do Programa de Pós-Graduação em Engenharia Biomédica da UnB, meus agradecimentos por todas às vezes em que solicitei alguma ajuda ou atendimento e fui prontamente atendido.

Deixo também meus agradecimentos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), por me apoiar financeiramente durante o desenvolvimento dessa pesquisa.

RESUMO

Pessoas que possuem doenças do neurônio motor têm dificuldades de interagir e de se comunicar com o ambiente ao seu redor. Uma das doenças do neurônio motor mais comuns é a Esclerose Lateral Amiotrófica (ELA), em que os acometidos pela doença perdem a capacidade de se comunicar verbalmente. Em um estágio avançado da ELA, chamado de Síndrome do Encarceramento Total, do inglês *Complete Locked-In State* (CLIS), os pacientes perdem o controle de todas as respostas musculares voluntárias, porém possuem um estado de consciência normal.

Uma das alternativas para pessoas que possuem essas síndromes é a utilização de uma Interface Cérebro Computador (ICC) como mecanismo de comunicação. ICCs são sistemas eletrônicos que tentam discernir padrões em sinais de atividades encefalográficas para utilizá-los como auxílio à seres humanos com mobilidades reduzidas. Dentre as técnicas utilizadas para captar esses sinais encefalográficos, a Espectroscopia Funcional de Infravermelho Próximo, do inglês *functional Near Infrared Spectroscopy* (fNIRS), tem sido objeto crescente de estudo nos últimos anos.

A fNIRS é uma técnica não-invasiva, que utiliza uma abordagem óptica para adquirir tais sinais. Seu princípio baseia-se em mensurar as taxas de oxigenação e desoxigenação do fluxo sanguíneo no córtex cerebral. Ela situa-se em um meio termo entre as técnicas de Eletroencefalografia (EEG) e Imagem por Ressonância Magnética Funcional, do inglês *functional Magnetic Resonance Imaging* (fMRI), porém com maior flexibilidade e menor risco à saúde de quem a utiliza.

Nesse contexto, a pesquisa propôs a desenvolver um sistema eletrônico de aquisição multicanal de sinais de fNIRS, e avaliá-lo em um cenário de classificação de sinais reais de humanos, buscando diferenciar movimentos intencionais de não-intencionais. A metodologia consistiu em projetar a instrumentação de aquisição, implementar um modelo de classificação SVM, e coletar sinais do córtex cerebral de humanos, com base em um protocolo experimental aprovado por um Comitê de Ética.

O processo de classificação foi realizado utilizando um modelo preditivo do tipo SVM, com kernel gaussiano. Para estimar melhor as métricas de desempenho do modelo, foi utilizada a técnica de validação cruzada K-Fold, com $k=5$.

Ao todo foram avaliados três cenários distintos de classificação. Participaram das coletas, no total, cinco voluntários. Cada sessão de coleta teve duração de 6 minutos, onde cada participante foi instruído a passar metade do tempo em repouso e a outra metade realizando movimentos sequenciais com as mãos.

O primeiro consistiu em adquirir sinais com apenas um canal, formado por uma topologia simples de uma fonte de luz com um fotodetector. Os sinais foram coletados em duas sessões em um mesmo dia, com condições de iluminação controladas. Cada sessão utilizou uma fonte

de emissão distinta uma da outra. A acurácia média obtida ficou superior a 90% para os dois participantes.

O segundo experimento avaliou um cenário de classificação com a aquisição de 10 canais simultaneamente, adquiridos com 3 voluntários, em um mesmo dia cada. Os 10 canais foram gerados utilizando duas fontes de emissão em conjunto com cinco fotodetectores. A acurácia média para esse cenário foi de 98%, indicando que o modelo conseguiu discernir bem a presença da ausência de movimento.

O último experimento teve como objetivo avaliar o desempenho de classificação com sinais coletados em dias distintos para um mesmo participante, simulando condições de iluminação distintas. Para tal, foram repetidas as coletas com os últimos 3 voluntários, dois dias após às primeiras sessões. O modelo foi treinado com os sinais da primeira sessão, e a inferência foi feita com os sinais da segunda sessão. Nesse cenário, as métricas de desempenho obtidas revelaram que não foi possível discernir com boa acurácia as classes avaliadas.

No geral, os resultados obtidos com os experimentos foram similares aos de trabalhos da literatura levantada, validando o sistema de aquisição implementado.

Palavras-chave: fNIRS, NIRS, DOT, Classificadores, Aprendizado Supervisionado, SVM.

ABSTRACT

People who suffers from motor neuron diseases have difficulties to interact and communicate with the environment around them. One of the most common motor neuron diseases is Amyotrophic Lateral Sclerosis (ALS), in which those affected by the disease lose the ability to communicate verbally. In an advanced stage of ALS, called Complete Locked-In State (CLIS), patients lose control of all voluntary muscle responses, but still have a normal conscious state.

One of the possible alternatives for people who have these syndromes is a Brain Computer Interface (BCI), for use as a communication mechanism. BCIs are electronic systems that try to discern patterns in signals of encephalographic activities, using these patterns as an aid to humans with reduced mobility. Among the techniques used to capture these encephalographic signals, the functional Near Infrared Spectroscopy (fNIRS) has been an object of increasing study in recent years.

fNIRS is a non-invasive technique that uses an optical approach to acquire such signals. Its principle is based on measuring the oxygenation and deoxygenation rates of blood flow in the cerebral cortex. It situates between the techniques of Electroencephalography (EEG) and functional Magnetic Resonance Imaging (fMRI), but with greater flexibility and less risk to the health of those who use it.

In this context, the research proposed to develop an electronic system for multichannel acquisition of fNIRS signals, and to evaluate it in a scenario of classification of real human signals, seeking to differentiate intentional from unintentional movements. The methodology consisted of designing the acquisition instrumentation, implementing an SVM classification model, and collecting signals from the human cerebral cortex, based on an experimental protocol approved by a Human Ethics Committee.

The classification process was performed using a predictive model of the SVM type, with Gaussian kernel. To better estimate the model's performance metrics, the K-Fold cross-validation technique was used, with $k = 5$.

Three different classification scenarios were evaluated, and five volunteers participated of the experiments. Each acquisition session lasted 6 minutes, and each participant was instructed to spend half the time at rest and the other half to perform sequential hand movements.

The first consisted of acquiring signals with only one channel, formed by a simple topology of one light source with one photodetector. The signals were collected in two sessions on the same day, with controlled lighting conditions. Each session used a different emission source. The average accuracy obtained was greater than 90% for the two participants.

The second experiment evaluated a classification scenario with the acquisition simultaneously of 10 channels, acquired with 3 volunteers, on the same day each. The 10 channels were generated using two emission sources together with five photodetectors. The average accuracy for this scenario was 98%, indicating that the model was able to discern well the presence of the absence of movement.

The last experiment aimed to evaluate the classification performance with signals collected on different days for the same participant, simulating different lighting conditions. For this, collections were repeated with the last 3 volunteers, two days after the first sessions. The model was trained with the signals from the first session, and the inference was made with the signals from the second session. In this scenario, the performance metrics obtained revealed that it was not possible to discern the evaluated classes, with the adopted methodology.

In general, the results obtained with the experiments were similar to those of studies in the literature, validating the implemented acquisition system.

Keywords: fNIRS, NIRS, DOT, SVM, Machine Learning.

SUMÁRIO

1	Introdução	1
1.1	Contextualização e Problematização	1
1.2	Objetivos	3
1.2.1	Objetivo Geral	3
1.2.2	Objetivos Específicos	3
1.3	Justificativa	4
2	Fundamentação Teórica	5
2.1	Neurofisiologia Associada À Intenção de Movimentos	5
2.1.1	Anatomofisiologia Básica do Sistema Nervoso	5
2.1.2	Hemodinâmica Cerebral	7
2.1.3	Imagética Motora	8
2.2	Espectroscopia de Infravermelho Próximo	9
2.2.1	Histórico	9
2.2.2	Princípios Físicos	10
2.2.3	Modelos Matemáticos	12
2.2.4	Aquisição do Sinal de fNIRS	15
2.3	Classificação de Sinais	19
2.3.1	Problema Geral de Classificação	21
2.3.2	Extração de Características	21
2.3.3	Divisão do Conjunto de Dados para Treinamento e Teste	23
2.3.4	Métricas de Desempenho de Classificadores	24
2.3.5	Máquinas de Vetores de Suporte (SVM)	26

3	Materiais e Métodos	31
3.1	Desenvolvimento do sistema de aquisição dos sinais de fnirs	31
3.1.1	Circuito de Emissão	31
3.1.2	Circuito de Aquisição	33
3.1.3	Controle e Processamento Digital	43
3.1.4	Circuito de Alimentação	45
3.2	Circuito Implementado	46
3.3	Implementação e Avaliação dos Classificadores	49
3.3.1	Software	49
3.3.2	Arquitetura Geral	49
4	Resultados e Discussão	53
4.1	Procedimento Experimental	53
4.1.1	Comitê de Ética	54
4.2	Aquisição de curva pletismográfica	55
4.3	Detecção de movimento utilizando apenas um fotodetector e um comprimento de onda	56
4.4	Detecção de movimento utilizando um fotodetector e dois comprimentos de onda distintos	61
4.5	Detecção de movimento utilizando cinco fotodetectores e dois comprimentos de onda distintos	62
4.6	Avaliação de desempenho de classificação usando bases de treinamento e de teste coletadas em dias distintos	66
5	Conclusão	68
	Lista de Referências	69
	A Leiautes	76
	B Esquemáticos	78

LISTA DE TABELAS

2.1	Estruturas e funções do córtex cerebral. Fonte: [47].	8
2.2	Cenários possíveis em um problema de classificação binária. Fonte: [22].	25
2.3	Matriz de confusão para um problema de classificação binária.	25
2.4	Principais funções de Kernel utilizadas em SVM.	30
3.1	Características técnicas do MCP6S28. Fonte: [50].	36
3.2	Características técnicas do amplificador operacional MCP6002 (Valores típicos). Fonte: [49].	42
3.3	Configurações técnicas utilizadas para adquirir sinais com o ADS1256.	43
3.4	Pacotes utilizados para manipulação dos dados e implementação dos classificadores. A versão do PYTHON utilizada foi a 3.7.5.	49
3.5	Parâmetros utilizados para o janelamento dos sinais coletados.	51
3.6	<i>Features</i> utilizadas para treinamento dos modelos preditivos.	51
3.7	Parâmetros utilizados para o modelo SVM, de acordo com a biblioteca <code>scikit-learn</code>	52
4.1	Características físicas dos voluntários que participaram dos experimentos.	53
4.2	Média e desvio padrão das métricas de desempenho de classificação dos sinais coletados com o participante A, considerando apenas uma única fonte de luz com um fotodetector.	58
4.3	Média e desvio padrão das métricas de desempenho de classificação dos sinais coletados com o participante B, considerando apenas uma única fonte de luz com um fotodetector.	60
4.4	Média e desvio padrão das métricas de desempenho de classificação dos sinais coletados com os participante A e B, considerando duas fontes de luz.	61
4.5	Média e desvio padrão das métricas de desempenho de classificação dos sinais coletados com os participante C, D e E, considerando um total de 10 canais independentes.	66

4.6	Métricas de desempenho de classificação avaliadas em base de sinais coletados em dias distintos, para os participantes C, D e E.	66
-----	------------------------------------------------------------------------------------------------------------------------------------------	----

LISTA DE QUADROS

LISTA DE FIGURAS

2.1	Composição do sistema nervoso. Fonte: [42].	6
2.2	Meninges que separam o crânio do encéfalo. Adaptada de: [2].	6
2.3	Encéfalo e suas divisões. Fonte: [47].	7
2.4	Estruturas do córtex cerebral. Fonte: [2].	7
2.5	Princípio da espectroscopia de infravermelho próximo. Fonte: [13].	11
2.6	Janela óptica para tecidos biológicos. Fonte: [62].	11
2.7	Bloco de matéria homogêneo, em formato de paralelepípedo. Adaptado de [65].	13
2.8	Comparação do espectro de emissão, para um mesmo comprimento de onda, entre um (2.9a) Diodo Emissor de Luz, do inglês <i>Light-Emitting diode</i> (LED) e um (2.9b) Diodo Laser, do inglês <i>Laser Diode</i> (LD). Adaptado de [13].	16
2.9	(2.9a) Sinal em tempo contínuo. (2.9b) Sinal amostrado em intervalos de tempo regulares. Fonte: [21].	17
2.10	(2.10a) Espectro de um sinal em tempo contínuo. Espectros do sinal amostrado com (2.10b) valor igual, (2.10c) inferior e (2.10d) superior à taxa de Nyquist. Fonte: [21].	18
2.11	Efeito de aliasing observado no domínio do tempo. Em vermelho está o sinal que se quer amostrar, e em preto-tracejado, o sinal amostrado a uma taxa inferior à de Nyquist, gerando o efeito aliasing.	18
2.12	Efeito da quantização de um sinal senoidal de frequência 5 Hz, amostrado à uma taxa de 100 Hz. Em (2.12a), o sinal foi quantizado com 3 bits, enquanto que em (2.12b), o mesmo sinal foi quantizado com 6 bits.	20
2.13	Processo de validação cruzada com K-Fold ($K = 5$).	24
2.14	Exemplo de um conjunto de dados linearmente separável.	27
2.15	Exemplo de um conjunto de dados linearmente não-separável.	29

3.1	Diagrama de blocos do circuito de emissão de luz Infravermelho Próximo, do inglês <i>Near Infrared</i> (NIR).	31
3.2	Esquema de ligação dos decodificadores de 4 para 16. Ao todo, 5 pinos digitais da BeagleBone Black (BBB) controlam qual dos 26 LEDs irá acender. 32	
3.3	Exemplo do circuito de chave eletrônica para controlar qual LED será utilizado, onde apenas um LED é acionado por vez. O circuito acima é replicado 13 vezes.	32
3.4	Diagrama de blocos do circuito de emissão de luz NIR.	33
3.5	Circuito de controle de potência dos LEDs.	33
3.6	Dispositivo OPT101. Fonte: [75].	34
3.7	Resposta espectral do OPT101. Fonte: [75].	35
3.8	Configuração escolhida para o OPT101. Adaptado de [75].	35
3.9	Disposição dos detectores e LEDs no placa de aquisição, que possui dimensões 5 cm × 5 cm. Cada quadrado representa um OPT101, e cada círculo representa um par de LEDs, sendo um vermelho e outro infravermelho.	36
3.10	Diagrama de blocos interno do MCP6S28. Fonte: [50].	36
3.11	Configuração do circuito utilizado para interfaceamento de cada um dos três MCP6S28.	37
3.12	Topologia Sallen-Key para filtro passa-altas tipo Butterworth de segunda ordem.	38
3.13	(3.13a) Resposta em frequência da magnitude do filtro butterworth passa-altas projetado. (3.13b) Resposta em frequência da fase do filtro. (3.13c) Resposta ao degrau unitário.	39
3.14	Topologia Sallen-Key para filtro passa-baixas tipo Butterworth de segunda ordem.	40
3.15	(3.15a) Resposta em frequência da magnitude do filtro butterworth passa-baixas projetado. (3.15b) Resposta em frequência da fase do filtro. (3.15c) Resposta ao degrau unitário.	41
3.16	Topologia do amplificador não-inversor.	41
3.17	Circuitos de filtros e amplificação utilizado no sistema.	42
3.18	Diagrama de blocos do ADS1256. Fonte: [74].	43

3.19	Resposta em frequência do filtro digital interno ao ADS1256, para uma taxa de amostragem de 30000 Amostras por Segundo, do inglês <i>Samples per Second</i> (SPS). Fonte: [74].	44
3.20	Configuração do circuito eletrônico utilizado para adquirir sinais com o ADS1256.	44
3.21	BeagleBone Black. Fonte: [5]	45
3.22	Interface gráfica implementada para validar as aquisições. Nesse exemplo em particular, está sendo mostrado a aquisição em tempo real, com um canal apenas, com os sensores posicionados no pulso.	45
3.23	Circuito de alimentação do sistema.	46
3.24	Detalhe do circuito da placa que contém os LEDs e fotodiodos. Cada placa dessa possui 5 fotodiodos e 3 pares de LEDs, possibilitando 30 medidas (15 de luz vermelha + 15 de infravermelha).	47
3.25	(3.25a) Circuito de chaveamento e controle das fontes de emissão. (3.25b) Detalhe da placa principal, onde estão presentes os circuitos de aquisição e de processamento.	47
3.26	Conjunto completo.	48
3.27	Arquitetura simplificada dos sistemas de classificação implementados. . .	50
4.1	Curva pletismográfica adquirida com o participante A. Em (4.1a) é mostrado o sinal no domínio do tempo, e em (4.1b) a densidade espectral de potência no domínio da frequência.	55
4.2	Aquisição com a fonte de luz vermelha para o participante A. Em (4.2a) é apresentado o sinal no domínio do tempo, e em (4.2b) a densidade espectral de potência em função da frequência.	57
4.3	Aquisição com a fonte de luz infravermelha para o participante A. Em (4.2a) é apresentado o sinal no domínio do tempo, e em (4.2b) a densidade espectral de potência em função da frequência.	57
4.4	Espectrograma dos sinais coletados com o participante A. A linha branca em cada imagem separa o estado de repouso (esquerda) do estado de movimento (direita).	58
4.5	Aquisição com a fonte de luz vermelha para o participante A. Em (4.5a) é apresentado o sinal no domínio do tempo, e em (4.5b) a densidade espectral de potência em função da frequência.	59

4.6	Aquisição com a fonte de luz infravermelha para o participante A. Em (4.5a) é apresentado o sinal no domínio do tempo, e em (4.5b) a densidade espectral de potência em função da frequência.	59
4.7	Espectrograma dos sinais coletados com o participante B. A linha branca em cada imagem separa os casos de repouso (esquerda) dos casos com movimento (direita). Cada coluna desse espectrograma é considerado como um exemplo para o classificador.	60
4.8	Sinais coletados com o participante C, provenientes de um dos cinco fotodetectores para dois comprimentos de onda distintos. Em (4.8a) é apresentado o sinal coletado sobre a luz vermelha, e em (4.8b) sobre a luz infravermelha. Em (4.8c) é apresentado os espectrogramas dos sinais anteriores.	63
4.9	Sinais coletados com o participante D, provenientes de um dos cinco fotodetectores para dois comprimentos de onda distintos. Em (4.8a) é apresentado o sinal coletado sobre a luz vermelha, e em (4.9b) sobre a luz infravermelha. Em (4.8c) é apresentado os espectrogramas dos sinais anteriores.	64
4.10	Sinais coletados com o participante E, provenientes de um dos cinco fotodetectores para dois comprimentos de onda distintos. Em (4.8a) é apresentado o sinal coletado sobre a luz vermelha, e em (4.10b) sobre a luz infravermelha. Em (4.8c) é apresentado os espectrogramas dos sinais anteriores.	65
A.1	Placa Principal	76
A.2	Placa Chaveamento LEDs	76
A.3	Placa Sensores	77

LISTA DE NOMENCLATURAS E ABREVIACOES

ADC Conversor Analgico-Digital, do ingls <i>Analog-to-Digital Converter</i>	17
AD Analgico-Digital	17
BBB BeagleBone Black	32
CI Circuito Integrado.....	34
CLIS Sndrome do Encarceramento Total, do ingls <i>Complete Locked-In State</i>	1
DAC Conversor Digital-Analgico, do ingls <i>Digital-to-Analog Converter</i>	32
DC Corrente Contnua, do ingls <i>Direct Current</i>	34
DOT Tomografia ptica Difusa, do ingls <i>Diffuse Optical Tomography</i>	2
DPF Fator Diferencial de Caminho, do ingls <i>Differential Pathlength Factor</i>	14
EEG Eletroencefalografia.....	1
ELA Esclerose Lateral Amiotrfica	1
EOG Eletrooculograma.....	2
fMRI Imagem por Ressonncia Magntica Funcional, do ingls <i>functional Magnetic Resonance Imaging</i>	1
fNIRS Espectroscopia Funcional de Infravermelho Prximo, do ingls <i>functional Near Infrared Spectroscopy</i>	2

HbO Oxiemoglobina.....	9
HbR Desoxihemoglobina	9
IA Inteligência Artificial.....	19
ICC Interface Cérebro Computador.....	1
ICM Interface Cérebro Máquina.....	1
IM Imagética Motora.....	8
LBB Lei de Beer-Lambert	12
LBBM Lei de Beer-Lambert Modificada.....	14
LD Diodo Laser, do inglês <i>Laser Diode</i>	15
LDA Análise de Discriminantes Lineares, do inglês <i>Linear Discriminant Analysis</i>	2
LED Diodo Emissor de Luz, do inglês <i>Light-Emitting diode</i>	15
NIR Infravermelho Próximo, do inglês <i>Near Infrared</i>	11
NIRI Imageamento no Infravermelho Próximo, do inglês <i>Near Infrared Imaging</i>	10
NIRS Espectroscopia de Infravermelho Próximo, do inglês <i>Near Infrared Spectroscopy</i>	

PGA	Amplificador de Ganho Programável, do inglês <i>Programmable Gain Amplifier</i>	35
PMT	Tubos Fotomultiplicadores, do inglês <i>Photomultiplier Tubes</i>	16
PSD	Densidade Espectral de Potência, do inglês <i>Power Spectral Density</i>	22
SBC	Computador em placa única, do inglês <i>Single-Board Computer</i>	43
SNC	Sistema Nervoso Central	5
SNP	Sistema Nervoso Periférico	5
SPI	<i>Serial Peripheral Interface</i>	35
SPS	Amostras por Segundo, do inglês <i>Samples per Second</i>	17
SVM	Máquinas de Vetores de Suporte, do inglês <i>Support Vector Machines</i>	2
TBJ	Transistor Bipolar de Junção	32

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E PROBLEMATIZAÇÃO

A forma de se comunicar pode representar um desafio para pessoas que possuem algum tipo de distúrbio no neurônio motor [76]. Esses distúrbios são geralmente progressivos e atacam células responsáveis por controlar atividades musculares voluntárias, podendo comprometer tarefas essenciais à vida humana, como, por exemplo, falar e andar [4].

Um dos tipos mais recorrentes de doenças do neurônio motor é a Esclerose Lateral Amiotrófica (ELA). A ELA pode destruir as funções respiratórias e bulbares nos pacientes acometidos pela doença [15], fazendo com que eles não consigam se comunicar verbalmente. Neste caso, é necessária a utilização de dispositivos de comunicação assistidos que dependem de sinais não-verbais, como movimentação de dedos ou olhos, para a interação com o meio ao seu redor [26]. Existe um estado avançado da ELA, denominado Síndrome do Encarceramento Total, do inglês *Complete Locked-In State* (CLIS), em que acometido pela síndrome perde o controle até mesmo da última resposta muscular que lhe resta, permanecendo sem mobilidade alguma, porém mantendo sua consciência intacta [15].

Uma das alternativas que tem se mostrado promissora no auxílio à comunicação para pacientes com CLIS é a utilização de uma Interface Cérebro Computador (ICC), também conhecida como Interface Cérebro Máquina (ICM) [76]. ICC é um sistema de comunicação usando hardware e software que, por meio de sinais de controle obtidos de atividades eletroencefalográficas, permite que humanos interajam com o ambiente ao seu redor [57]. Em outras palavras, é um sistema de inteligência artificial projetado para reconhecer padrões em sinais gerados pelo cérebro [54].

Dentre as técnicas não-invasivas utilizadas para adquirir sinais gerados pelo cérebro por meio de ICC, a Eletroencefalografia (EEG) tem sido a mais utilizada, devido à sua alta resolução temporal e à sua capacidade de medir diversos estados cerebrais [14]. Entretanto, a EEG tem uma resolução espacial relativamente baixa, limitando a medição de atividade cerebral específica de uma região [27]. Uma resolução espacial maior, em comparação com EEG, pode ser obtida por meio de Imagem por Ressonância Magnética

Funcional, do inglês *functional Magnetic Resonance Imaging* (fMRI), porém a resolução temporal desta técnica é baixa. A fMRI impõe uma restrição de mobilidade ao paciente durante a aquisição do sinal [25], e, além disso, um equipamento desse tipo possui grandes dimensões e alto custo financeiro, inviabilizando-o para uma aplicação prática. Já a Espectroscopia Funcional de Infravermelho Próximo, do inglês *functional Near Infrared Spectroscopy* (fNIRS), situa-se em um meio termo entre as técnicas de EEG e de fMRI, considerando os aspectos de resolução espacial e temporal, bem como o de mobilidade [32].

A fNIRS é uma técnica que utiliza uma abordagem óptica com o intuito de mensurar alterações na oxigenação sanguínea no córtex cerebral [25]. Quando comparada a EEG ou fMRI, essa técnica pode ser considerada de fácil utilização, segura, acessível, relativamente tolerante a movimentos, menos suscetível a artefatos, além de poder ser operada por meio de um dispositivo portátil com interface sem-fio [23]. Comparado à EEG, especificamente, a fNIRS permite a classificação de uma atividade cortical mais estável e requer um pré-processamento menor em relação à anterior [8]. Além disso, com o uso da fNIRS também é possível obter uma reconstrução da imagem da região monitorada, por meio de uma técnica denominada Tomografia Óptica Difusa, do inglês *Diffuse Optical Tomography* (DOT) [35].

Após a etapa de aquisição de sinais gerados a partir de atividades cerebrais – sejam eles obtidos por fNIRS, EEG ou fMRI –, a ICC busca reconhecer padrões nesses sinais para detectar alguma intenção proveniente do usuário [34]. Algoritmos de regressão ou de classificação podem ser utilizados a fim de se atingir esse objetivo, porém o uso de classificadores tem sido a abordagem mais utilizada em pesquisas recentes [45].

Especificamente nas ICC que utilizam fNIRS (ICC-fNIRS), algumas pesquisas têm sido realizadas nos últimos anos em aplicações utilizando algoritmos classificadores tradicionais, como Máquinas de Vetores de Suporte, do inglês *Support Vector Machines* (SVM), e Análise de Discriminantes Lineares, do inglês *Linear Discriminant Analysis* (LDA). No trabalho descrito em [34], os autores propuseram uma ICC-fNIRS utilizando classificadores SVM para distinguir entre duas classes (verdadeiro/falso ou sim/não). Na mesma linha, em [7] foi realizada uma abordagem comparativa entre classificadores SVM e LDA, utilizando o mesmo protocolo que [34]. Um outro trabalho nesse sentido foi proposto classificar quatro classes, por meio de um sistema de ICC híbrida fNIRS-EEG, utilizando um classificador do tipo LDA [12]. Recentemente, no trabalho descrito em [15], foi desenvolvido um estudo comparativo entre sinais de fNIRS, EEG e Eletrooculograma (EOG) adquiridos simultaneamente, em pacientes com CLIS, utilizando classificadores SVM, com o intuito de distinguir entre duas opções de decisão.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Esse trabalho tem como objetivo desenvolver um sistema eletrônico de aquisição multicanal de sinais de Espectroscopia Funcional de Infravermelho Próximo. O sistema desenvolvido será avaliado por meio de um estudo de classificação de discernimento entre movimento intencional e não-intencional, utilizando sinais reais de humanos, coletados com base em um protocolo experimental aprovado por comitê de ética.

1.2.2 Objetivos Específicos

Para contemplar o objetivo geral, serão adotados os procedimentos específicos seguintes:

- Desenvolvimento de uma instrumentação para aquisição de sinais de fNIRS, com os requisitos:
 - Aquisição, a taxa constante e com alta resolução de quantização, de sinais de até 20 fotodetectores.
 - Controle de ativação e de potência de 13 pares de fontes de emissão em duplo comprimento de onda.
 - Desenvolvimento de leiautes e placas para os circuitos projetados.
 - Desenvolvimento de software embarcado para controle da instrumentação e exportação dos dados adquiridos.
- Implementação de modelos preditivos para classificar estados de movimento:
 - Estudo com a técnica de classificação com SVM.
 - Desenvolvimento um software que implemente as duas técnicas descritas.
 - Avaliação dos resultados obtidos das classificações com métricas de desempenho utilizadas em trabalhos semelhantes:
 - * Acurácia
 - * Precisão
 - * Revocação
 - * Medida-F
 - Aquisição de sinais reais em seres humanos coletados com base em um protocolo experimental aprovado por comitê de ética em pesquisa com seres humanos.

1.3 JUSTIFICATIVA

A difícil forma de comunicação encontrada em pessoas que sofrem de ELA ou de CLIS é um dos grandes desafios da ciência atualmente. Uma das formas mais promissoras de comunicação nestes casos é com o auxílio de ICC. Diversos trabalhos acadêmicos têm surgido, nos últimos anos, nesse segmento. Porém poucos têm tido como objetivo o desenvolvimento de um sistema em que possibilite o paciente usar no cotidiano, sem se preocupar com possíveis interferências causadas por movimentos ou por campos eletromagnéticos, como nos casos de ICC que utilizam técnicas de EEG ou de fMRI.

O alto custo financeiro de equipamentos comerciais de fNIRS restringe o uso dessa tecnologia em larga escala. O desenvolvimento de uma instrumentação de fNIRS multicanal com dimensões reduzidas, acessível e portátil, além de discernir movimentos intencionais de não-intencionais, permite também realizar avaliação de fadiga muscular [73], detecção de câncer [55], reconstrução de imagens com DOT [24, 35, 38], dentre outras possibilidades.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo aborda os principais conceitos teóricos da técnica de Espectroscopia funcional de Infravermelho Próximo e suas aplicações. Dentre os aspectos abordados estão os princípios neurofisiológicos, os modelos matemáticos, os requisitos de aquisição e as técnicas de classificação para esse tipo de sinal.

2.1 NEUROFISIOLOGIA ASSOCIADA À INTENÇÃO DE MOVIMENTOS

2.1.1 Anatomofisiologia Básica do Sistema Nervoso

O sistema nervoso permite ao ser humano interagir fisicamente e emocionalmente com o ambiente ao seu redor. É ele quem controla e regula as funções fisiológicas voluntárias e involuntárias de um indivíduo [42]. O sistema nervoso pode ser dividido em Sistema Nervoso Central (SNC) e Sistema Nervoso Periférico (SNP). Uma representação gráfica dos dois tipos é apresentada na Figura 2.1. O SNC é formado por encéfalo e medula espinhal, e é responsável pela recepção de informações e pela tomada de decisões [61]. Já o SNP é formado por todos os componentes neurais fora do SNC, como nervos e neurônios motores, e é encarregado de transmitir as informações de órgãos sensoriais para o SNC [47].

O SNC é formado por células básicas responsáveis pela condução do impulso nervoso, chamadas de neurônios. Estima-se que existam cerca de 86 bilhões de neurônios em um SNC humano [29]. Cada tipo de neurônio pode ter, desde algumas dezenas, até centenas de milhares de conexões com outros neurônios. Essas conexões são organizadas em circuitos ou redes que se comunicam para o processamento de todas as informações conscientes e inconscientes do encéfalo e da medula espinhal [42].

2.1.1.1 Encéfalo

O encéfalo, principal elemento do SNC [61], é localizado dentro da caixa craniana, que funciona como uma espécie de proteção. Abaixo do crânio, existem membranas, denominadas meninges, que funcionam como um segundo tipo de proteção. Os três tipos

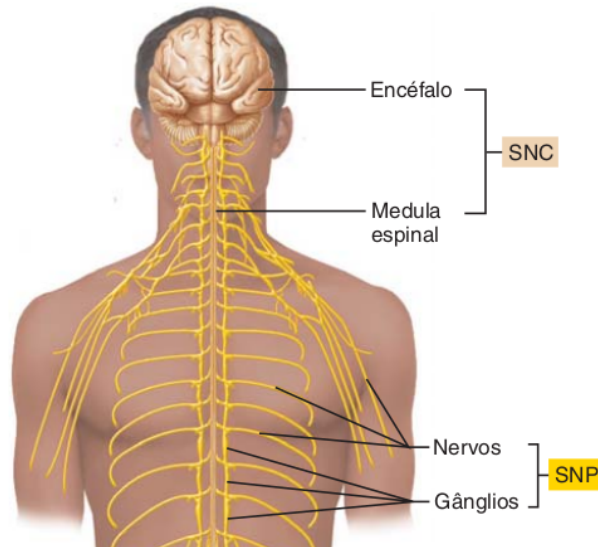


Figura 2.1. Composição do sistema nervoso. Fonte: [42].

de meninges são: dura-mater, aracnoide e pia-máter (Figura 2.2) [10].

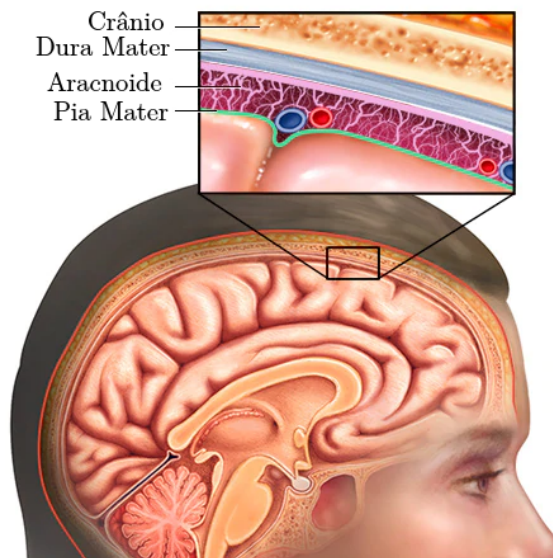


Figura 2.2. Meninges que separam o crânio do encéfalo. Adaptada de: [2].

O encéfalo, de forma simplificada, pode ser subdividido em tronco encefálico, cerebelo, diencefalo e telencefalo [47]. O telencefalo forma o que é conhecido popularmente como cérebro [42]. No cérebro, existe uma substância cinzenta localizada em sua superfície, chamada de córtex cerebral. O córtex cerebral tem espessura entre 2 mm e 4 mm, e sua área pode se estender até cerca de 2500 cm^2 , correspondendo à aproximadamente 40% da massa total do encéfalo [47].

O córtex cerebral é responsável por funções complexas do cérebro como percepção, memória, cognição e consciência [56], e pode ser dividido em estruturas de acordo com tais funções. A Tabela 2.1 apresenta essas estruturas e as suas respectivas funções, e




Figura 2.3. Encéfalo e suas divisões. Fonte: [47].

a Figura 2.4 contém uma representação gráfica da localização dessas estruturas no cérebro.




Figura 2.4. Estruturas do córtex cerebral. Fonte: [2].

2.1.2 Hemodinâmica Cerebral

Da massa corporal de um ser humano, em média, 2% equivale apenas ao cérebro. Entretanto, cerca de 20% do total de oxigênio presente no sangue é consumido por ele [10]. A execução de um ato motor qualquer gera uma ativação em uma área específica do cérebro, demandando um aumento no fornecimento de oxigênio e de glicose [61].

O alto consumo de oxigênio e glicose acaba implicando em uma alta taxa metabólica do tecido nervoso e, como as células nervosas não têm capacidade de armazenar nenhuma dessas duas moléculas, é necessário que o cérebro seja irrigado continuamente com sangue arterial [2]. A falta de fluxo sanguíneo contínuo no cérebro pode acarretar em uma isquemia cerebral ou em um AVC isquêmico, podendo levar à graves sequelas e até mesmo à morte de um indivíduo [39].

O metabolismo dos neurônios aumenta conforme sua atividade e, quanto mais ativos, maior é a demanda de sangue arterial para o cérebro [2]. Esse fluxo sanguíneo cerebral é suprido por duas artérias carótidas e por duas artérias vertebrais, que se fundem para formar o círculo de Willis [29]. As artérias do círculo de Willis se estendem por toda superfície do cérebro, e se ramificam em vasos menores chamados artérias e arteríolas de

Tabela 2.1. Estruturas e funções do córtex cerebral. Fonte: [47].

Estrutura	Função (Área Funcional)
Lobo frontal	Movimento voluntário (córtex motor primário)
	Planejamento do movimento (córtex pré-motor)
	Movimento dos olhos (campo ocular frontal)
	Produção da fala (área de Broca)
	Funções cognitivas executivas (área de associação anterior)
	Resposta emocional (área de associação límbica)
Lobo parietal	Sensibilidade somática geral (córtex e área de associação sensitiva somática)
	Percepção espacial de objetos, sons, partes do corpo (área de associação posterior)
	Compreensão da fala (área de Wernicke)
Lobo occipital	Visão (córtex visual e áreas de associação)
Lobo temporal	Audição (córtex auditivo e área de associação)
	Olfato (córtex olfatório)
	Identificação de objetos (área de associação posterior)
	Resposta emocional, memória (área de associação límbica)
Ínsula	Paladar (córtex gustatório)

penetração [29, 47].

O sistema nervoso possui características de circulação sanguínea diferentes da circulação sistêmica – também chamada de grande circulação [42] –, exigindo um fornecimento constante de nutrientes e oxigênio para seu correto funcionamento [2]. Para suprir esse fornecimento constante, as arteríolas do sistema nervoso possuem a capacidade alterar dinamicamente seu diâmetro, conforme a necessidade [29].

Utilizando um método para medição do fluxo sanguíneo no córtex cerebral por meio de injeção de substâncias radioativas na artéria carótida, pesquisadores conseguiram detectar variações na taxa do fluxo de sangue em até 150%, em questões de segundos, após submeterem pacientes a alguns estímulos visuais e/ou motores [29].

2.1.3 Imagética Motora

A Imagética Motora (IM), também chamada de imagética de movimento, é definida como um processo no qual um ato motor ou um movimento é mentalmente ensaiado, sem que ele venha de fato a acontecer [19]. Estudos apontam que existe uma forte correlação entre a execução e a imaginação de um movimento [3], indicando que as respostas neurofisiológicas variam de forma similar tanto em simulações mentais quando na execução

motora [61].

Com o uso técnicas de mapeamento cerebral, como fMRI e Tomografia por Emissão de Pósitrons, do inglês *Positron Emission Tomography* (PET), também foi possível detectar evidências da correlação entre a imaginação de um movimento e sua execução [3]. A sobreposição de regiões cerebrais ativas na execução de movimento e em seu imageamento não chega a ser surpreendente. Estudos nesse sentido são realizados com atletas desde a década de 1980, visando melhorar o desempenho a respeito da mecânica de movimentos [46].

A IM pode ser classificada em dois tipos: visual e cinestésica. Na primeira, IM ocorre com uma simulação mental – em uma espécie de vídeo mental – de uma tarefa motora. Já a IM cinestésica faz com que o indivíduo busque obter as sensações físicas relacionadas às contrações musculares de um determinado movimento [69].

2.2 ESPECTROSCOPIA DE INFRAVERMELHO PRÓXIMO

2.2.1 Histórico

O uso da relação entre luz emitida e luz transmitida como método de investigação de tecidos humanos é conhecido há mais de um século. Wilhelm Conrad Röntgen, em 1895, constatou que radiações não-visíveis de uma faixa espectral específica – hoje conhecidas como raio-X – poderiam ser utilizadas para diagnósticos médicos [23]. Em 1929, Max Cutler publicou um estudo sobre a utilização de luz visível para detecção de câncer de mama [18].

Alguns estudos realizados no século XIX tiveram grande relevância para o surgimento da oximetria médica, que é uma área de estudo que utiliza técnicas ópticas para medição da oxigenação sanguínea. Em particular, destacam-se os trabalhos publicados pelo fisiologista alemão Hoppe-Seyler na década de 1860 sobre a análise espectral da Oxihemoglobina (HbO), além dos estudos sobre a variação da intensidade da luz ao penetrar tecidos humanos, realizados pelo médico alemão Karl von Vierordt na década de 1870. Em 1894, o químico Gustav von Hüfner realizou a primeira análise espectroscópica *in vitro* das quantidades absolutas e relativas de HbO e Desoxihemoglobina (HbR) [23].

Já no século XX, na década de 1930, Matthes e Gross realizaram, de forma não-invasiva, medições para determinação espectroscópica da concentração de HbO e HbR na região da orelha. Em 1943, Horecker desenvolveu o primeiro oxímetro comercial [64]. Em 1970, a Hewlett-Packard introduziu comercialmente o primeiro dispositivo para monitoramento da saturação de oxigênio no sangue, com medições na orelha, utilizando 8 comprimentos de onda distintos [48]. Pouco depois, em 1974, Aoyagi propôs uma nova

abordagem da oximetria de pulso, com as medições feitas nas pontas dos dedos, que é o método amplamente usado hoje em dia [63].

Enquanto as aplicações práticas de oximetria clínica não-invasiva se concentravam em determinar a saturação global de oxigênio do sangue arterial do corpo, por meio de medições na orelha ou na ponta dos dedos, Frans Jöbsis propôs a utilização da Espectroscopia de Infravermelho Próximo, do inglês *Near Infrared Spectroscopy* (NIRS), na cabeça. Na década de 1970, Jöbsis publicou um estudo constatando que o crânio, e ossos de maneira geral, não representam uma barreira para a luz na faixa do infravermelho próximo. Seu estudo é considerado pioneiro, pois ele provou a viabilidade da espectroscopia local não-invasiva da oxigenação do tecido cortical através do crânio e é a base da fNIRS [37].

Os estudos seguintes aos de Jöbsis tiveram como objetivo aprimorar a compreensão da fisiologia do sinal, a instrumentação NIRS e os conceitos matemáticos. Em 1988, Delpy propôs uma modificação da Lei Beer-Lambert, levando em consideração a dispersão da luz. Essa modificação permitiu o cálculo dos níveis de oxigenação a partir do sinal NIRS medido, e ficou conhecida como Lei de Beer-Lambert Modificada [20].

Da década de 2000 até os dias de hoje, os grandes avanços na área de espectroscopia funcional de infravermelho próximo se concentraram em aumentar a quantidade de optodos nas instrumentações, com o objetivo de mapear topograficamente a atividade cerebral ao longo do tempo [71].

2.2.2 Princípios Físicos

Espectroscopia é a ciência que estuda as interações da radiação com a matéria, e possui aplicações em diversas áreas, como, por exemplo, em análises químicas e bioquímicas, nas indústrias farmacêuticas e alimentícias, em ciência forense, dentre outras [65].

A NIRS, aplicada à anatomofisiologia, foca na análise espectroscópica de informações físicas e químicas dos tecidos sanguíneos. Em outras palavras, é um método óptico difuso para a medição da taxa de oxigenação sanguínea em uma determinada região do corpo humano. Imageamento no Infravermelho Próximo, do inglês *Near Infrared Imaging* (NIRI), DOT e fNIRS são técnicas baseadas no mesmo princípio: a luz de infravermelho próximo é emitida na cabeça em uma posição específica e passa por processos aleatórios de espalhamento e absorção no tecido, fazendo com que a intensidade da luz transmitida seja atenuada em até 9 ordens de magnitude [72]. Uma fração da luz propaga através do tecido em um caminho em forma de banana (*banana shape*) de volta à superfície, onde é detectada por um fotodetector sensível à luz nesse comprimento de onda [13]. Esse processo é ilustrado na Figura 2.5.




Figura 2.5. Princípio da espectroscopia de infravermelho próximo. Fonte: [13].

A luz de Infravermelho Próximo, do inglês *Near Infrared* (NIR), penetra tecidos biológicos – como sangue e pele – com mais facilidade que a luz visível. Isso se deve ao fato de que, nessa faixa específica de comprimento de onda, ocorre uma menor absorção e uma menor dispersão da luz nesses tecidos [66]. Essa característica garante, no caso da fNIRS, que a luz emitida pelo fotoemissor possa penetrar o crânio e atingir profundidade suficiente para a monitoração da oxigenação sanguínea nos tecidos cerebrais. Essa faixa óptica na qual os tecidos biológicos são relativamente transparente à luz NIR é chamada de janela óptica biológica, e compreende os comprimentos de onda 600 nm à 900 nm [62]. A Figura 2.6 ilustra essa ideia da janela óptica.




Figura 2.6. Janela óptica para tecidos biológicos. Fonte: [62].

A absorção e a dispersão da luz NIR em alguns componentes do tecido como colágenos, proteínas ou lipídeos permanecem aproximadamente constantes ao longo do tempo. Entretanto, no caso de alguns cromóforos, como a HbO e a HbR, isso não ocorre, pois esses componentes são fortes absorvedores de luz NIR, e suas concentrações variam de acordo com o metabolismo e o fluxo sanguíneo [28].

A HbO e a HbR reagem de forma diferente, no que diz respeito à absorção e à dispersão, quando expostas à luz NIR. A hemoglobina oxigenada tem uma absorção maior de luz entre 600 nm e 700 nm, enquanto que a hemoglobina desoxigenada absorve mais na faixa entre 800 nm e 900 nm [28].

Com base nessa característica, se dois comprimentos de onda diferentes forem escolhidos de forma que absorção da luz NIR pelas moléculas de HbO e de HbR seja máxima, após a captação da luz transmita pelo tecido monitorado, é possível determinar as variações na concentração das duas moléculas utilizando a Lei de Beer-Lambert Modificada [40]. Esse é o princípio que embasa a oximetria e a fNIRS.

No entanto, existem certas diferenças entre a oximetria e a fNIRS: a primeira busca monitorar as alterações na densidade óptica do tecido durante os intervalos de pulso, calculando a saturação de oxigênio da hemoglobina arterial; já a segunda mede a oxigenação do tecido e a saturação de oxigênio através de uma seção transversal do volume tecidual [23].

2.2.3 Modelos Matemáticos

A Lei de Beer-Lambert (LBB) relaciona, quantitativamente, o quanto a atenuação da luz emitida depende da concentração das partículas absorventes e do caminho óptico sobre o qual luz percorre. Matéria absorvente pode ser entendido como átomos, íons ou moléculas, dependendo do contexto [65]. A seguir é apresentada uma derivação da LBB.

2.2.3.1 Lei de Beer-Lambert

Considere um bloco de matéria homogêneo, em formato de um paralelepípedo, como o mostrado na Figura 2.7. Esse bloco possui comprimento b , volume V e contém n partículas absorventes idênticas. Um feixe de luz monocromática, de comprimento de onda λ , com intensidade I_0 , atinge o bloco perpendicularmente à sua superfície. Após percorrer a distância b , a luz emerge do corpo com uma intensidade I menor que I_0 , pois, ao atravessá-lo, a luz sofre absorção.

Considere uma seção transversal do bloco de área S , que possui uma espessura infinitesimal dx e que contém dn partículas (Figura 2.7). Associada a cada partícula, pode-se




Figura 2.7. Bloco de matéria homogênea, em formato de paralelepípedo. Adaptado de [65].

imaginar uma superfície dS , onde ocorre a captura de fótons que, se um fóton a atinge, a absorção ocorrerá imediatamente. Essa superfície dS é proporcional à quantidade de partículas dn ,

$$dS = \alpha(\lambda) \cdot dn, \quad (2.1)$$

onde $\alpha(\lambda)$ é uma constante de proporcionalidade chamada de *absortividade*, e que depende do comprimento de onda λ da luz incidente [65].

A razão entre a área total S e essa superfície dS representa a probabilidade média ρ de captura de fótons dentro da seção

$$\rho = \frac{dS}{S}. \quad (2.2)$$

A intensidade do feixe que adentra a seção S , denotada por I_x , é proporcional ao número de fótons por unidade de área por unidade de tempo. Denotando por dI_x a quantidade de luz removida da seção, tem-se que a razão de absorção equivale a probabilidade média de captura de um fóton, dada por

$$\rho = -\frac{dI_x}{I_x}. \quad (2.3)$$

Assim, igualando as expressões (2.2) e (2.3), temos que

$$-\frac{dI_x}{I_x} = \frac{dS}{S}. \quad (2.4)$$

Substituindo (2.1) em (2.4), e integrando sobre o intervalo de 0 a n

$$-\int_{I_0}^I \frac{dI_x}{I_x} = \int_0^n \frac{\alpha(\lambda) dn}{S}, \quad (2.5)$$

fornece

$$-\ln\left(\frac{I}{I_0}\right) = \frac{\alpha(\lambda)n}{S}. \quad (2.6)$$

A área S pode ser expressa pela razão entre o volume V e o comprimento b do bloco e, incorporando o sinal negativo ao logaritmo em (2.6), chega-se a

$$\ln\left(\frac{I_0}{I}\right) = \frac{\alpha(\lambda)bn}{V}. \quad (2.7)$$

A razão n/V é uma medida de concentração c , pois tem dimensão de partículas por unidade de volume. A razão logarítmica entre as intensidades de luz emitida e absorvida recebe o nome de *absorbância* e é representada por A . Rearranjando (2.7), chega-se à LBB:

$$A = \alpha(\lambda)bc. \quad (2.8)$$

Se em (2.8), a concentração c for expressa em função do número de *mols*, a constante de proporcionalidade é chamada de *absortividade molar* e usualmente é representada por $\varepsilon(\lambda)$, resultando em

$$A = \varepsilon(\lambda)bc. \quad (2.9)$$

2.2.3.2 Lei de Beer-Lambert Modificada

A LBB, expressa em (2.9), determina que é possível encontrar a concentração de uma substância com base na sua absortividade molar e no caminho óptico que a luz percorre. Entretanto, do jeito que a lei é apresentada, isso só é válido em meios homogêneos, onde só exista uma única substância. E, além disso, exige também que o caminho óptico que a luz percorra seja retilíneo e sofra pouco espalhamento [20]. Esses requisitos não são cumpridos na fNIRS, pois, nesse caso, a luz não percorre um caminho retilíneo, mas sim curvilíneo (Figura 2.5), e acaba sofrendo espalhamento em diversas direções [44]. Além disso, o meio de propagação em fNIRS não é homogêneo, pois a área monitorada é formada por diversos tecidos, como pele, ossos e sangue.

Para atender ao problema da fNIRS, algumas alterações na LBB foram propostas, gerando uma nova versão chamada Lei de Beer-Lambert Modificada (LBBM). Em sua formulação inicial da LBBM, Delpy [20] propôs uma alteração na LBB introduzindo um Fator Diferencial de Caminho, do inglês *Differential Pathlength Factor* (DPF), além de considerar o meio como não-homogêneo [40].

O DPF leva em consideração a distância entre a fonte de emissão de luz e o fotodetector, e a distância média que os fótons percorrem entre o emissor e o detector, para um determinado comprimento de onda λ . Além disso, Delpy introduziu também um fator geométrico $G(\lambda)$ que representa a perda causada pelo espalhamento no comprimento de

onda λ [40]. Então, para N comprimentos de ondas distintos, pode-se escrever:

$$A = \sum_{i=1}^N (\varepsilon_i(\lambda) \cdot b \cdot c_i) \cdot \text{DPF}(\lambda) + G(\lambda). \quad (2.10)$$

As perdas por espalhamento G são desconhecidas, tornando impossível determinar a absorvância A por (2.10). Delpy então propôs calcular a variação da absorvância:

$$\Delta A = \sum_{i=1}^N \varepsilon_i(\lambda) \cdot b \cdot \Delta c_i \cdot \text{DPF}(\lambda). \quad (2.11)$$

Para as moléculas HbO e HbR, como são utilizados 2 comprimentos de onda distintos, realizando a aquisição do sinal de fNIRS em dois instantes de tempo consecutivos, é possível determinar a variação da concentração dessas moléculas [40, 59]. Manipulando (2.11), chega-se ao sistema de equações que determina a variação de concentração de HbO e HbR:

$$\begin{bmatrix} \Delta \text{HbO} \\ \Delta \text{HbR} \end{bmatrix} = \begin{bmatrix} \varepsilon_{\text{HbR}}(\lambda_1) & \varepsilon_{\text{HbO}}(\lambda_1) \\ \varepsilon_{\text{HbR}}(\lambda_2) & \varepsilon_{\text{HbO}}(\lambda_2) \end{bmatrix}^{-1} \begin{bmatrix} \frac{\Delta A(\lambda_1)}{\text{DPF}(\lambda_1) \cdot b} \\ \frac{\Delta A(\lambda_2)}{\text{DPF}(\lambda_2) \cdot b} \end{bmatrix}, \quad (2.12)$$

onde os valores de $\varepsilon_{(\cdot)}$ e DPF são tabelados para cada molécula em função do comprimento de onda. Os outros dois parâmetros, ΔA e b dependem apenas do hardware de aquisição.

2.2.4 Aquisição do Sinal de fNIRS

2.2.4.1 Sistemas Emissor-Detector

Um instrumento típico de fNIRS é formado por um conjunto de emissores e detectores de luz, comumente chamados de optodos, dispostos ao redor da cabeça. Os fótons que entram em um ponto de emissão são absorvidos ou espalhados no couro cabeludo, crânio, fluido cerebrospinal, massa cinzenta ou massa branca, alguns seguindo uma trajetória em formato de banana (Figura 2.5) e são captados em um ponto de detecção próximo [13].

Fontes de Emissão

Entre as fontes de emissão mais utilizadas em fNIRS pode-se citar o Diodo Emissor de Luz, do inglês *Light-Emitting diode* (LED), e o Diodo Laser, do inglês *Laser Diode* (LD). Existem normas técnicas de segurança para a utilização tanto de LEDs como de LDs em

aplicações biomédicas, e, nesse sentido, os LEDs apresentam maior segurança aos olhos e à pele em relação aos LDs [62].

Os LDs são geralmente utilizados nos sistemas em que os optodos são confeccionados com fibras ópticas, e apresentam uma faixa de emissão, em termos de comprimento de onda, mais estreita que os LEDs (Figura 2.8). Entretanto, costumam ser mais caros e difíceis de adquirir-los, além de exigirem um circuito eletrônico mais sofisticado e com consumo de potência maior [13].

Já os LEDs possuem dimensões menores em relação aos LDs, são financeiramente mais baratos e possuem uma variedade comercial maior em relação ao comprimento de onda. Entretanto, sua emissão ocupa uma maior largura de banda. A principal vantagem dos LEDs em relação aos LDs, é o fato de consumirem menor potência elétrica, facilitando a concepção do circuito eletrônico de controle [13, 79].




Figura 2.8. Comparação do espectro de emissão, para um mesmo comprimento de onda, entre um (2.9a) LED e um (2.9b) LD. Adaptado de [13].

Detectores

Os tipos de detectores mais utilizados em equipamentos de fNIRS são os Tubos Fotomultiplicadores, do inglês *Photomultiplier Tubes* (PMT), e os Fotodiodos de Silício, do inglês *Silicon Photodiodes* (SPD). Os PMTs são os fotodetectores mais sensíveis disponíveis atualmente. Eles permitem contagem de fótons, possuem alto ganho e uma largura de banda elevada, da ordem dos 100 MHz. Entretanto, os PMTs precisam de centenas de Volts para funcionarem corretamente, são frágeis, requerem sistemas de resfriamento, e possuem alto custo [79, 59].

Já os SPDs operam em baixas tensões, são mais fáceis de encontrar comercialmente, mais baratos em termos financeiros. Além disso, não necessitam de sistemas de resfriamento e não são sensíveis a campos magnéticos, como no caso dos PMTs. Entre as

desvantagens dos SPDs, pode-se citar que precisam de ganho elevado em sua amplificação de transimpedância, e são facilmente suscetíveis a ruídos elétricos [78].

2.2.4.2 Conversão Analógico-Digital

A etapa de conversão Analógico-Digital (AD), também conhecida como digitalização, consiste em transformar um sinal contínuo – cujos domínio e contra-domínio podem assumir infinitos valores – em um sinal discreto e quantizado, para que um sistema computacional possa processá-lo. O dispositivo de realiza tal processo é o Conversor Analógico-Digital, do inglês *Analog-to-Digital Converter* (ADC). O processo de digitalização possui duas etapas fundamentais: amostragem e quantização.

Amostragem

Para processar um sinal de tempo contínuo em um sistema digital, é necessário primeiramente discretizá-lo em tempo. Esse é o papel da amostragem, que consiste em coletar amostras do sinal em intervalos de tempo fixos, chamados de intervalo de amostragem, usualmente representado por t_s [21]. O inverso desse intervalo é chamado de frequência ou taxa de amostragem, e é representado por f_s . A taxa de amostragem é medida em Hertz ou Amostras por Segundo, do inglês *Samples per Second* (SPS) [21].




Figura 2.9. (2.9a) Sinal em tempo contínuo. (2.9b) Sinal amostrado em intervalos de tempo regulares. Fonte: [21].

Alguns cuidados com a etapa de amostragem devem ser tomados. Segundo o teorema da amostragem de Nyquist-Shannon, um sinal pode ser apropriadamente amostrado se ele não possuir componentes de frequências acima da metade da taxa de amostragem [68]. Caso esse requisito não seja atendido, não há garantias de que o sinal amostrado possa ser reconstruído adequadamente.

Um dos efeitos colaterais da amostragem é que a representação em frequência de um sinal amostrado durante um intervalo de tempo finito é periódica, possuindo infinitas

cópias de seu espectro deslocadas por múltiplos inteiros de f_s . Quanto maior for a taxa de amostragem, mais separadas estarão essas cópias umas das outras. Entretanto se f_s for exatamente igual ao dobro da máxima componente de frequência do sinal, não haverá espaço de separação entre cada cópia do espectros. Esse valor específico de f_s recebe o nome de *Taxa de Nyquist*. Se f_s for inferior à taxa de Nyquist, as cópias do espectro do sinal se sobrepõem, causando um efeito chamado aliasing [1].

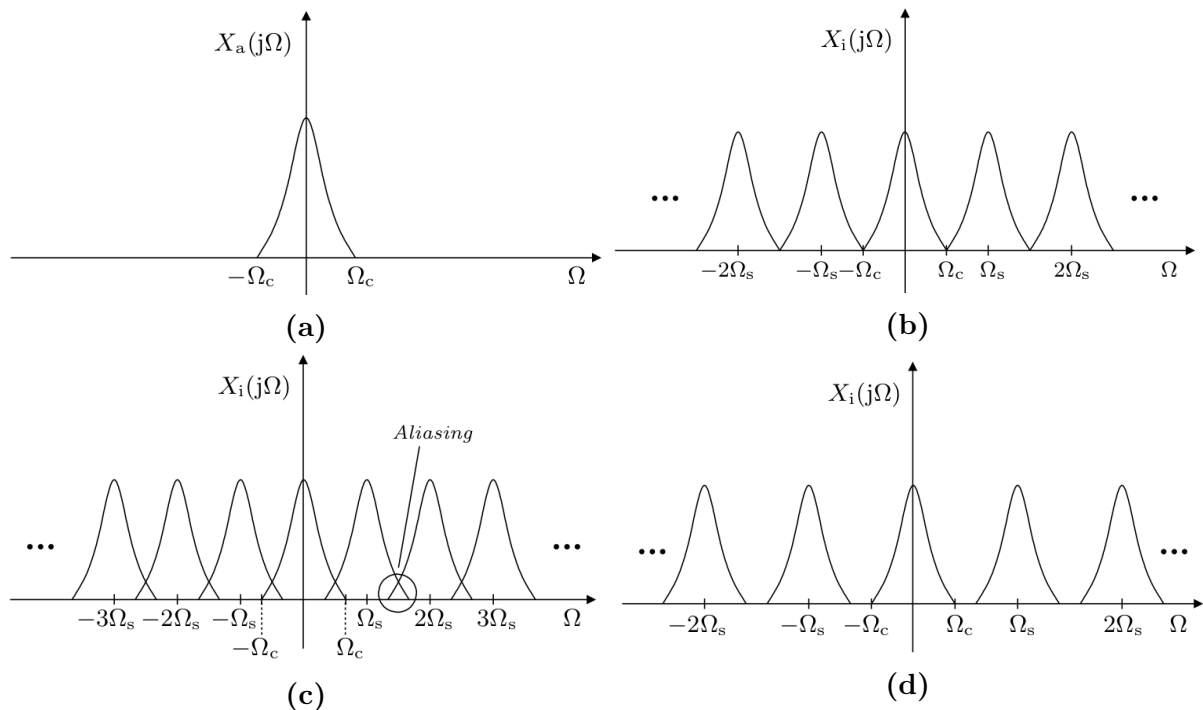


Figura 2.10. (2.10a) Espectro de um sinal em tempo contínuo. Espectros do sinal amostrado com (2.10b) valor igual, (2.10c) inferior e (2.10d) superior à taxa de Nyquist. Fonte: [21].

Para evitar o efeito do aliasing, além de garantir uma taxa de amostragem superior à de Nyquist, é necessário incluir uma etapa de filtragem anterior a de amostragem. Esse filtro deve ser do tipo passa-baixa, com frequência de corte inferior ao valor da taxa de Nyquist [1].




Figura 2.11. Efeito de aliasing observado no domínio do tempo. Em vermelho está o sinal que se quer amostrar, e em preto-tracejado, o sinal amostrado a uma taxa inferior à de Nyquist, gerando o efeito aliasing.

Quantização

A etapa de quantização está relacionada ao processo de mapear o sinal amostrado, usualmente em escala contínua, em um conjunto finito de valores, por meio de arredondamentos e truncamentos [21]. Diferentemente da etapa de amostragem, a quantização introduz erros irreversíveis ao sinal amostrado. Para diminuir o erro de quantização, é necessário aumentar a quantidade de níveis em que o sinal será representado.

A quantidade de níveis que o ADC quantiza um sinal é especificada em função da sua resolução em bits, e é calculada por

$$Q = 2^N, \quad (2.13)$$

onde Q representa a quantidade de níveis, e N o número de bits. A Figura 2.12 exemplifica esse processo, comparando um sinal quantizado com 3 bits (8 níveis) e com 6 bits (32 níveis).


Em [78, 79] é feita uma comparação entre vários estudos sobre a aquisição de sinais fNIRS. Há casos em que foi utilizada uma resolução para esse tipo de sinal de 12 bits ou 10 bits, porém a resolução de quantização mais comum encontrada nesses estudos foi de 16 bits.

2.3 CLASSIFICAÇÃO DE SINAIS


A tarefa de buscar padrões em eventos da natureza é uma das mais recorrentes na história da humanidade, e, recentemente, tem sido objeto de estudo de várias áreas, dentre elas, a de aprendizagem de máquina [9]. Aprendizagem de Máquina é um campo da Inteligência Artificial (IA) que tem como objetivo gerar modelos capazes de aprender, de forma automática, com base em experiências [51].

Nesse contexto, aprender pode ser entendido como a extração de padrões ou de estruturas de um conjunto de dados, por meio da otimização de parâmetros de um modelo [51]. Um modelo é algoritmo ou uma função que recebe um conjunto de dados como entrada e, a partir de um treinamento, fornece uma saída, que pode ser um valor numérico, uma classe ou uma descrição. Existem alguns tipos de aprendizagem, e, dentre os mais comuns, estão aprendizagem supervisionada e aprendizagem não-supervisionada [82].

Na aprendizagem supervisionada estão as tarefas chamadas preditivas ou preditoras. O objetivo desse tipo de aprendizagem é prever valores ou classes utilizando características ou atributos descritivos de um conjunto de dados de treinamento. A tarefa de



(a)



(b)

Figura 2.12. Efeito da quantização de um sinal senoidal de frequência 5 Hz, amostrado à uma taxa de 100 Hz. Em (2.12a), o sinal foi quantizado com 3 bits, enquanto que em (2.12b), o mesmo sinal foi quantizado com 6 bits.

prever valores numéricos contínuos é usualmente chamada de regressão, e seu objeto de interesse é encontrar um modelo ou uma função que descreva o comportamento de um determinado evento. Já a tarefa de predição de classes, conhecida como classificação, busca encontrar um modelo que rotule em categorias um dado futuro ou desconhecido com base em exemplos passados [9, 82].

Na aprendizagem não-supervisionada, o modelo gerado recebe um conjunto de dados não rotulados e busca descrevê-los baseando-se em características, como medidas de distância ou similaridade entre os dados. Agrupamentos, mapas auto-organizáveis, sumarização e regras de associação podem ser citados como exemplos de aprendizado não-supervisionado [9].

2.3.1 Problema Geral de Classificação

Classificação é o processo de rotular um exemplar desconhecido baseado em um conjunto de exemplares previamente rotulados. O termo *classe* diz respeito à quantidade de rótulos ou categorias presentes no conjunto de exemplares.

De forma genérica, pode-se definir classificação como o processo de mapear um conjunto de vetores de entrada, para um conjunto finito de classes. Se a quantidade de classes presentes no conjunto de dados for igual a 2, o processo de classificação é do tipo binário, e, em geral, denota-se as classes como *negativo* e *positivo* ou *0* e *1*. Se existirem mais classes, a classificação é dita multi-classe [82].

2.3.2 Extração de Características

Para um classificador ter bom desempenho em sua tarefa de predição, é fundamental que o conjunto de dados de entrada do mesmo descreva bem a natureza do sinal de interesse. As características de um sinal, também chamadas de atributos descritivos ou *features*, são os elementos que o classificador utiliza para rotular um exemplar desconhecido.

Para uso de classificadores em situações críticas, como na detecção de intenção de movimento para tomada de decisão, a extração de características é um processo de grande importância, pois o uso de atributos inadequados para classificação pode resultar em baixos índices de precisão e de acurácia do classificador, deixando-o sem utilidade.

A extração de características depende diretamente do tipo de sinal avaliado. Alguns parâmetros como média, pico, inclinação, latência, assimetria, curtose e densidade espectral de potência são amplamente utilizados em tarefas de classificação que envolvam sinais de fNIRS ou de EEG [45, 53, 52]. As características, nesse contexto, podem ser divididas como temporal, espacial e espaço-temporal [58].

Um aumento na quantidade de características do sinal pode levar a desempenhos melhores de classificação. Por outro lado, o aumento de atributos leva a um processamento computacional maior, o que pode tornar inviável tarefas de classificação em tempo real [30].

Média

A média das concentrações de HbO e HbR pode ser calculadas por

$$\mu_w = \frac{1}{N_w} \sum_{t=t_1}^{t_2} \Delta HbX(k), \quad (2.14)$$

onde μ_w é a média de uma determinada janela w , de duração $t_2 - t_1$ segundos, com N_W amostras. ΔHbX representa o tipo do sinal, se é HbO ou HbR [36].

Máximo e Mínimo

O pico, ou valor máximo, de uma janela de um sinal é uma das características mais utilizadas nos estudos que envolvem classificação de sinais de fNIRS [30]. Já o uso do mínimo de uma janela como característica é pouco recorrente, entretanto há estudos recentes que o utilizam, como em [67], [30] [81].

Inclinação

Na literatura abordada, foram encontrados trabalhos que utilizam a inclinação de uma janela como atributo descritivo. Basicamente, existem duas formas de se obter a inclinação de um sinal. Um método mais simples, porém bastante utilizado, determina a inclinação calculando a diferença entre as amostras de uma janela e uma versão sua deslocada [30]. Uma outra abordagem é interpolar uma curva em uma janela do sinal amostrado, para calcular a inclinação [80].

Assimetria e Curtose

Estudos recentes, como [36, 31], têm utilizado parâmetros estatísticos, como curtose e assimetria, como características de entrada de classificadores.

A assimetria s de uma janela w do sinal adquirido é definida como

$$s = \frac{E(\Delta HbX_w - \mu_w)^3}{\sigma^3}, \quad (2.15)$$

onde σ é o desvio padrão e $E(\cdot)$ é a esperança do sinal de ΔHbX .

Já a curtose k é calculada por

$$k = \frac{E(\Delta HbX_w - \mu_w)^4}{\sigma^4}. \quad (2.16)$$

Densidade Espectral de Potência (PSD)

A Densidade Espectral de Potência, do inglês *Power Spectral Density* (PSD), descreve a expectância da distribuição da potência de um processo estocástico em função das frequências que compõem o sinal [16]. Uma das formas de estimar a PSD de um sinal é

por meio do método de Welch, que consiste em aplicar janelas móveis no sinal, produzindo um periodograma. A PSD de um sinal \mathbf{x} pode ser calculada pelo quadrado da magnitude da transformada de Fourier,

$$P_f = \frac{1}{N} \sum_{n=1}^N |\mathcal{F}(\mathbf{x}_{w_n})|^2, \quad (2.17)$$

onde P_f^w denota a potência da f -ésima banda de frequência para um conjunto de versões janeladas \mathbf{x}_w do sinal amostrado.

Outras

Além das características descritas, também costumam ser exploradas em tarefas de classificação de sinais biomédicos: variância, valor eficaz, desvio padrão e mediana [30].

2.3.3 Divisão do Conjunto de Dados para Treinamento e Teste

Uma das abordagens mais tradicionais em problemas de classificação de sinais é dividir o conjunto de dados, já rotulados, em duas bases distintas, sendo uma para treinamento do modelo, e a outra para avaliar o classificador treinado. Existem diversas técnicas para realização dessa tarefa, sendo a validação cruzada uma das mais robustas.

2.3.3.1 Validação Cruzada

Validação cruzada é um método utilizado para avaliar o desempenho de modelos preditivos, e que busca estimar o erro de generalização dos algoritmos [33]. Essa técnica consiste em particionar a base de dados existentes já rotulados em um conjunto de treinamento e outro de teste. O conjunto de treinamento é utilizado para ajustar os parâmetros do modelo, e o conjunto de teste serve para estimar o quanto o modelo implementado é capaz de generalizar para novos exemplares não rotulados [41].

Alguns cuidados devem ser tomados durante o particionamento da base. No caso de classificação binária, é importante observar a proporção de ocorrência de cada uma das duas classes no conjunto completo. Isso é necessário para que, o particionamento da base em treino e teste, garanta que em cada uma delas haja a mesma proporção das classes. Esse tipo de validação é chamada de validação cruzada estratificada [6].

K-Fold

Uma das técnicas de validação cruzadas mais utilizadas é o *K-Fold*. Essa técnica consiste em dividir a base de dados em k subconjuntos, onde um total de $k - 1$ subconjuntos será usado para a fase de treinamento, e o subconjunto restante é utilizado para teste. Esse processo é repetido para todos os subconjuntos, sendo que em cada etapa são calculadas as métricas de desempenho de classificação. Ao fim, computa-se a média das métricas de cada iteração. A Figura 2.13 ilustra esse processo, com um exemplo de 5 subconjuntos ($K = 5$).




Figura 2.13. Processo de validação cruzada com K-Fold ($K = 5$).

2.3.4 Métricas de Desempenho de Classificadores

A avaliação do desempenho da tarefa de classificação constitui uma importante estratégia para validar o modelo preditivo implementado. O desempenho de um classificador depende da qualidade da etapa de treinamento, e da capacidade do modelo em generalizar [33]. As medidas de avaliação do desempenho de um classificador – também chamadas de métricas de avaliação – trazem, geralmente, informações sobre a quantidade de acertos ou erros do modelo.

Nos problemas de classificação binária, onde só existem duas classes na base de dados, quatro cenários podem acontecer em relação ao resultado da classificação. Os cenários e suas descrições são apresentadas na Tabela 2.2.

2.3.4.1 Matriz de Confusão

Uma das formas visualizar o desempenho de um classificador binário é por meio de uma matriz que compara as classes previstas pelo modelo com seus rótulos previamente conhecidos. Essa matriz é usualmente chamada de *matriz de confusão*, *matriz de contingência* ou *matriz de erro* [22], e uma representação dela é mostrada na Tabela 2.3.

Tabela 2.2. Cenários possíveis em um problema de classificação binária.
Fonte: [22].

Cenário	Descrição
Verdadeiro Positivo (VP)	O exemplo é classificado como positivo, e pertence de fato a essa classe.
Verdadeiro Negativo (VN)	O exemplo é classificado como negativo, e pertence de fato a essa classe.
Falso Positivo (FP)	O exemplo é classificado como positivo, porém não pertence a essa classe.
Falso Negativo (FN)	O exemplo é classificado como negativo, porém não pertence a essa classe.

Tabela 2.3. Matriz de confusão para um problema de classificação binária.

	Classe Preditada	
	Positiva	Negativa
Classe Real	Positiva	VP
	Negativa	FN
		FP
		VN

2.3.4.2 Acurácia

A *acurácia* é uma métrica que avalia o total de acertos do classificador em relação ao total de classificações, e é calculado como

$$\text{Acurácia} = \frac{VP + VN}{VP + FP + VN + FN}. \quad (2.18)$$

2.3.4.3 Precisão

A *precisão* avalia a quantidade de casos que pertencem de fato à classe *positiva*, em relação à quantidade de classificações *positivas* feita pelo modelo. É definida pela expressão

$$\text{Precisão} = \frac{VP}{VP + FP}. \quad (2.19)$$

2.3.4.4 Sensibilidade

A *sensibilidade*, também conhecida como *revocação*, *recall* ou *taxa de verdadeiros positivos*, mede a quantidade de *positivos* foram preditos pelo classificador em relação ao

total de dados pertencente a essa classe, e é calculada por

$$\text{Sensibilidade} = \frac{\text{VP}}{\text{VP} + \text{FN}}. \quad (2.20)$$

2.3.4.5 Especificidade

A *especificidade*, também chamada de *taxa de verdadeiros negativos*, mede a quantidade de *negativos* foram preditos pelo classificador em relação ao total de dados pertencente a essa classe, e é calculada pela expressão

$$\text{Especificidade} = \frac{\text{VN}}{\text{VN} + \text{FP}}. \quad (2.21)$$

2.3.4.6 Medida-F

A *medida-F*, também conhecida como *F-measure* ou *F1-score*, é uma média harmônica entre a precisão e a revocação, e é definida como

$$\text{Medida-F} = 2 \times \left(\frac{\text{Precisão} \times \text{Revocação}}{\text{Precisão} + \text{Revocação}} \right). \quad (2.22)$$

2.3.5 Máquinas de Vetores de Suporte (SVM)

Máquinas de Vetores de Suporte (SVM) constituem uma técnica estatística de aprendizado supervisionado, usualmente utilizada para tarefas de classificação e regressão. Os primeiros algoritmos com esse nome – SVM – surgiram por volta de 1992, com o trabalho de Boser [11], que propôs a solução de um problema classificação binária, por meio da separação de hiperplanos com margens rígidas, utilizando uma ideia derivada de um estudo feito por Vapnik e Chervonenkis em 1963 [77]. Posteriormente, foi aprofundado pelos trabalhos de Cortes e do próprio Vapnik em estudos publicados em 1995 [17], introduzindo as ideias de margens suaves e do uso de *kernels* para resolução de problemas não-lineares [77].

2.3.5.1 O Problema Inicial de SVM

Seja \mathbf{X} um subconjunto do espaço euclidiano \mathbb{R}^d , formado por vetores \mathbf{x}_i . Dado um conjunto de treinamento D na forma $\{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}$, o algoritmo de SVM

buscar entrar um vetor $\mathbf{w} \in \mathbb{R}^d$ com $\|\mathbf{w}\| = 1$ e um número real $b \in \mathbb{R}$, tal que:

$$\begin{aligned} \langle \mathbf{w}, \mathbf{x}_i \rangle + b &> 0, \quad \forall i \text{ com } y_i = +1 \\ \langle \mathbf{w}, \mathbf{x}_i \rangle + b &< 0, \quad \forall i \text{ com } y_i = -1. \end{aligned} \quad (2.23)$$

Em outras palavras, o hiperplano afim dado por (\mathbf{w}, b) separa perfeitamente o conjunto D em dois grupos $\{(\mathbf{x}_i, y_i) \in D : y_i = +1\}$ e $\{(\mathbf{x}_i, y_i) \in D : y_i = -1\}$.




Figura 2.14. Exemplo de um conjunto de dados linearmente separável.

2.3.5.2 Margens Rígidas

A solução encontrada em (2.23) não satisfaz a maioria dos casos. Um determinado exemplo \mathbf{x}_k pertença ao hiperplano (\mathbf{w}, b) não poderá ser classificado corretamente, pois $\langle \mathbf{w}, \mathbf{x}_k \rangle + b = 0$.

Uma alternativa a esse problema é redefini-lo, sujeitando-o às seguintes restrições:

$$\begin{aligned} \langle \mathbf{w}, \mathbf{x}_i \rangle + b &\geq +1, \quad \forall i \text{ com } y_i = +1 \\ \langle \mathbf{w}, \mathbf{x}_i \rangle + b &\leq -1, \quad \forall i \text{ com } y_i = -1. \end{aligned} \quad (2.24)$$

A restrição imposta em (2.24) implica que não devem existir pontos (exemplares) compreendidos na região $|\langle \mathbf{w}, \mathbf{x}_i \rangle + b| < 1$, implicando na terminologia *margens rígidas*.

Seja um vetor \mathbf{x}_l pertencente a $\langle \mathbf{w}, \mathbf{x}_i \rangle + b \leq -1$, e \mathbf{x}_u pertencente a $\langle \mathbf{w}, \mathbf{x}_i \rangle + b \geq +1$,

e que \mathbf{x}_l intercepta a reta perpendicular à \mathbf{x}_u , pode-se escrever:

$$\begin{aligned}\langle \mathbf{w}, \mathbf{x}_u \rangle + b &= +1 \\ \langle \mathbf{w}, \mathbf{x}_l \rangle + b &= -1.\end{aligned}\tag{2.25}$$

Do sistema em (2.25), é possível deduzir que:

$$\langle \mathbf{w}, \mathbf{x}_u - \mathbf{x}_l \rangle = 2.\tag{2.26}$$

Como \mathbf{w} e $\mathbf{x}_u - \mathbf{x}_l$ são ortogonais ao hiperplano separador, temos que

$$|\langle \mathbf{w}, \mathbf{x}_u - \mathbf{x}_l \rangle| = \|\mathbf{w}\| \cdot \|\mathbf{x}_u - \mathbf{x}_l\|,\tag{2.27}$$

implicando em:

$$\|\mathbf{x}_u - \mathbf{x}_l\| = \frac{2}{\|\mathbf{w}\|}\tag{2.28}$$

A norma $\|\mathbf{x}_u - \mathbf{x}_l\|$ equivale à distância entre os hiperplanos $\langle \mathbf{w}, \mathbf{x}_i \rangle + b \geq +1$ e $\langle \mathbf{w}, \mathbf{x}_i \rangle + b \leq -1$. Portanto, o hiperplano ótimo que separa as duas classes, maximizando a distância entre elas, é dado pelo problema de otimização que minimiza a norma $\|\mathbf{w}\|$:

$$\begin{aligned}\text{Minimizar } & \|\mathbf{w}\| \\ \text{Sujeito a } & y_i \cdot (\langle \mathbf{w}, \mathbf{x}_i \rangle + b - 1) \geq 0, \quad i = 1, \dots, n.\end{aligned}\tag{2.29}$$

2.3.5.3 Margens Suaves

A SVM de margens rígidas não possui muita aplicação prática. Isso se deve ao fato de que, em geral, com o uso dessa técnica, não é possível obter um hiperplano ótimo que separe as classes adequadamente quando há a presença de ruídos ou de *outliers* no conjunto de dados de treinamento.

Para solucionar esse problema mais complexo, Cortes e Vapnik introduziram o conceito de *variável de relaxação* (também chamada usualmente de *variável de folga*) [17]. Com essa abordagem, o problema de otimização descrito em (2.29) é modificado, passando a levar em consideração as variáveis de relaxação – denotadas por ξ –, tanto na função objetiva como nas restrições:

$$\begin{aligned}\text{Minimizar } & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \\ \text{Sujeito a } & y_i \cdot (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1 - \xi_i \\ & \xi_i \geq 0, \quad i = 1, \dots, n,\end{aligned}\tag{2.30}$$

onde C é uma constante, chamada de termo de regularização, que determina um peso à minimização dos erros no conjunto de treinamento.

2.3.5.4 Truque do Kernel

Os casos descritos anteriormente só permitem realizar a separação de classes por hiperplanos em um conjunto de dados linearmente separável. Para um conjunto de classes não linearmente separáveis, como o mostrado na Figura 2.15, é necessária uma modificação na abordagem do problema (2.30).




Figura 2.15. Exemplo de um conjunto de dados linearmente não-separável.

Essa modificação, proposta por Boser em 1992 [11], consiste em mapear o conjunto de dados de entrada em um espaço Hilbertiano \mathbf{H}_0 , possivelmente de dimensão infinita, onde há alta probabilidade de o algoritmo de SVM encontrar um hiperplano que separe linearmente o conjunto de dados [70]. O mapeamento é feito por meio de uma função de transformação $\Phi(\cdot)$, tal que $\Phi(\mathbf{x}) : \mathbf{X} \rightarrow \mathbf{H}_0$. O conjunto de dados de treinamento D então passa a ser $\{(\Phi(\mathbf{x}_1), y_1), (\Phi(\mathbf{x}_2), y_2), \dots, (\Phi(\mathbf{x}_n), y_n)\}$, e esse novo conjunto é utilizado para treinamento da SVM. O novo problema de otimização é dado por:

$$\begin{aligned}
 & \underset{\mathbf{w}}{\text{Minimizar}} && \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \\
 & \text{Sujeito a} && y_i \cdot (\langle \mathbf{w}, \Phi(\mathbf{x}_i) \rangle + b) \geq 1 - \xi_i \\
 & && \xi_i \geq 0, \quad i = 1, \dots, n,
 \end{aligned} \tag{2.31}$$

Para solucionar o problema descrito em (2.31), é necessário conhecer o mapeamento $\Phi(\cdot)$, o que em alguns casos nem sempre é possível.

Existe uma representação alternativa para o problema (2.31), conhecida como problema dual, obtida pelas condições de Karush-Kuhn-Tucker (KKT), que é escrita como:

$$\begin{aligned}
 \text{Maximizar}_{\boldsymbol{\alpha}} \quad & \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle \\
 \text{Sujeito a} \quad & \sum_{i=1}^n y_i \alpha_i = 0 \\
 & \alpha_i \in [0, C], \quad i = 1, \dots, n.
 \end{aligned} \tag{2.32}$$

onde $\boldsymbol{\alpha}$ é um vetor que contém os multiplicadores de Lagrange, na forma $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$. A solução do problema (2.32) depende, basicamente, em saber computar o produto interno $\langle \Phi(\cdot), \Phi(\cdot) \rangle$, não tornando obrigatório o conhecimento do mapeamento $\Phi(\mathbf{x}) : \mathbf{X} \rightarrow \mathbf{H}_0$, o que, em alguns casos, pode ser de grande complexidade computacional [70].

A função que computa o produto interno no espaço de características é chamada de kernel, e é definida como $K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$. Alguns dos principais kernels utilizados são mostrados na Tabela 2.4.

Tabela 2.4. Principais funções de Kernel utilizadas em SVM.

Kernel	Função
Linear	$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \mathbf{x}_i, \mathbf{x}_j \rangle$
Polinomial	$K(\mathbf{x}_i, \mathbf{x}_j) = (\langle \mathbf{x}_i, \mathbf{x}_j \rangle + r)^p$
Sigmoidal	$K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\beta_0 \langle \mathbf{x}_i, \mathbf{x}_j \rangle + \beta_1)$
RBF ou Gaussiano	$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\ \mathbf{x}_i - \mathbf{x}_j\ ^2}{2\sigma^2}\right)$

3 MATERIAIS E MÉTODOS

Este capítulo descreve as metodologias adotadas para o desenvolvimento do sistema eletrônico de aquisição dos sinais de fNIRS, os protocolos experimentais para a aquisição de sinais com voluntários, as técnicas que serão utilizadas para classificar os sinais adquiridos e quais métricas serão levadas em conta para avaliar o resultado das classificações.

3.1 DESENVOLVIMENTO DO SISTEMA DE AQUISIÇÃO DOS SINAIS DE FNIRS

3.1.1 Circuito de Emissão

O controle das fontes de emissão de luz é dividido em duas etapas:

- Seleção da fonte de emissão,
- Controle de potência da fonte.

A primeira é responsável por selecionar qual LED será utilizado como fonte. Já a segunda controla a potência de emissão dessa fonte. Um diagrama em blocos desse circuito é apresentado na Figura 3.1.

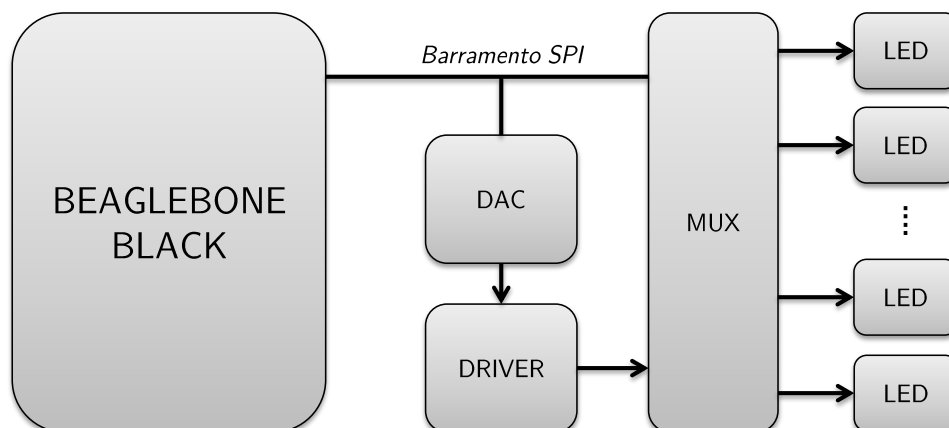


Figura 3.1. Diagrama de blocos do circuito de emissão de luz NIR.

Fonte de Emissão

O circuito implementado permite controlar até 26 LEDs, sendo metade de comprimento de onda 660 nm (vermelho) e o restante de 830 nm (infravermelho). A etapa de chaveamento das fontes de emissão é realizada com dois decodificadores de 4 para 16 controlados pela BeagleBone Black (BBB), e permite selecionar qualquer um dos 26 LEDs individualmente. O diagrama desses circuitos é apresentado nas Figuras 3.2 e 3.3.

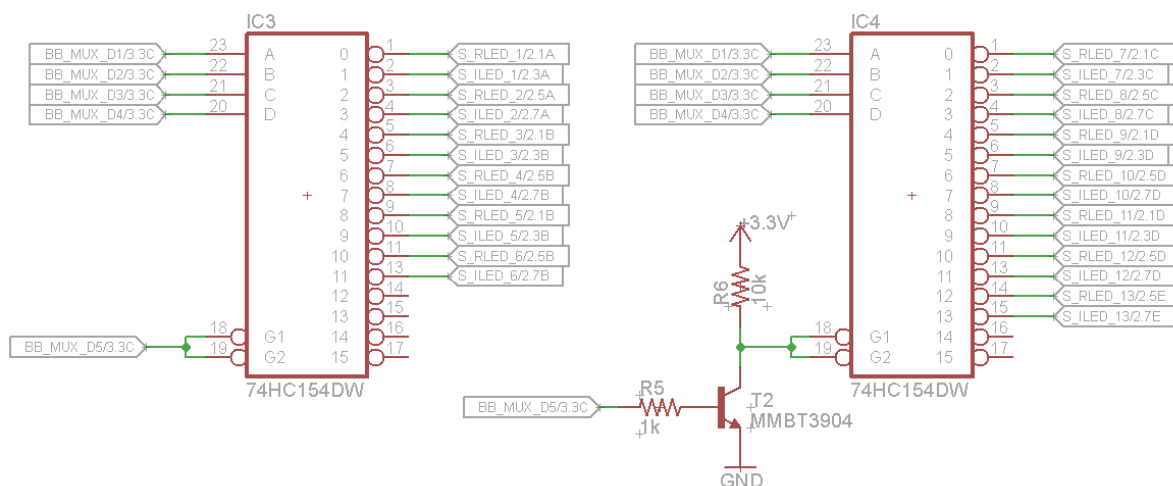


Figura 3.2. Esquema de ligação dos decodificadores de 4 para 16. Ao todo, 5 pinos digitais da BBB controlam qual dos 26 LEDs irá acender.




Figura 3.3. Exemplo do circuito de chave eletrônica para controlar qual LED será utilizado, onde apenas um LED é acionado por vez. O circuito acima é replicado 13 vezes.

Controle de Potência

A potência de emissão dos LEDs é controlada digitalmente, via software, pela BBB. Esse controle é feito utilizando um Conversor Digital-Analógico, do inglês *Digital-to-Analog Converter* (DAC), que gera tensões entre 0 V e 3.3 V, e um driver de corrente, utilizando um Transistor Bipolar de Junção (TBJ). O diagrama dessa etapa é mostrado na Figura 3.4.




Figura 3.4. Diagrama de blocos do circuito de emissão de luz NIR.

3.1.2 Circuito de Aquisição

O circuito de aquisição envolve toda a instrumentação analógica responsável por adquirir os sinais provenientes dos fotodiodos. Um diagrama de blocos descrevendo essa etapa é apresentado na Figura 3.5.

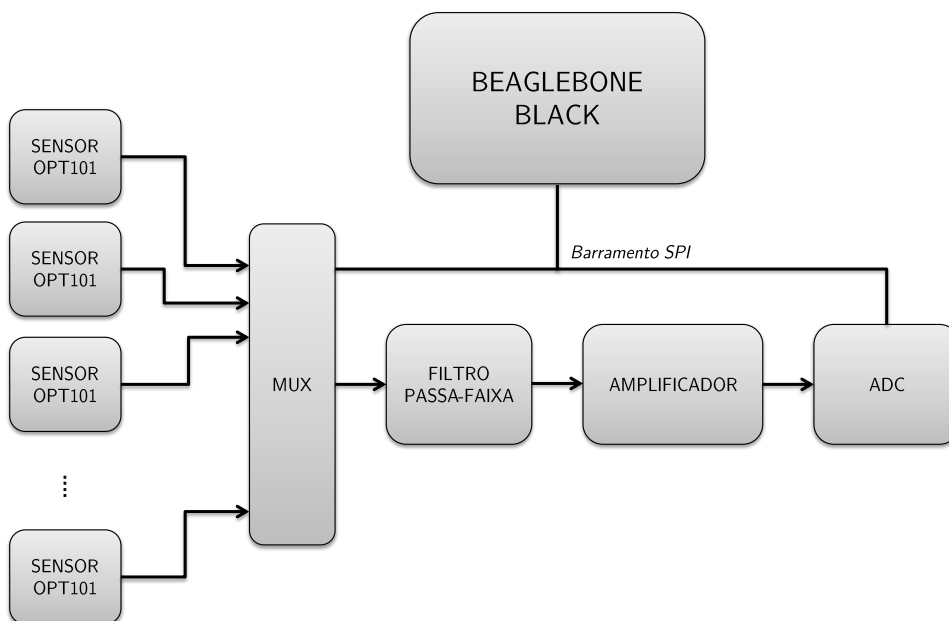


Figura 3.5. Circuito de controle de potência dos LEDs.

Esse circuito é dividido em 5 partes principais:

- Sensor Óptico,
- Seleção do Canal,
- Filtragem,

- Amplificação,
- Digitalização.

3.1.2.1 Sensor Óptico

Para captar o sinal da luz NIR emitida foi utilizado o Circuito Integrado (CI) OPT101. Esse dispositivo é um sensor optoeletrônico que converte sinal óptico em elétrico, sem adicionar ruído e capaz de amplificá-lo. Ele consiste em um fotodiodo monolítico acoplado a um amplificador de transimpedância, dispostos em um mesmo encapsulamento PDIP de 8 pinos (Figura 3.6). A combinação integrada do fotodiodo e do amplificador de transimpedância no mesmo encapsulamento elimina alguns problemas comumente encontrados em projetos de circuitos desse tipo, como corrente de fuga e interferência de ruídos [43].



Figura 3.6. Dispositivo OPT101. Fonte: [75].

O OPT101 possui uma resposta espectral que varia de 400 nm a 1100 nm, com alta sensibilidade entre 700 nm e 1000 nm (Figura 3.7), que é região de interesse da fNIRS. A sensibilidade e a resposta espectral do OPT101 permitem detectar variações hemodinâmicas no corpo humano de forma não invasiva [43].

Após captar a luz emitida, um amplificador de transimpedância interno ao CI faz a conversão do sinal de corrente proveniente do fotodiodo em um sinal de tensão elétrica proporcional à luz captada. Além disso, o OPT101 também permite aplicar ganho de tensão ao sinal gerado, de acordo com elementos externos conectados ao CI. A configuração utilizada no OPT101 para a aquisição do sinal fNIRS está representada na Figura 3.8. Nessa configuração, o ganho em Corrente Contínua, do inglês *Direct Current* (DC), é 51×10^6 V/A e a largura de banda é 0.33 kHz [75].

O arranjo escolhido para a placa de aquisição está representado na Figura 3.9. Cada placa possui 5 fotodetectores e 3 pares de LEDs (infravermelho e vermelho). No total, a placa de aquisição é capaz de fornecer $5 \times 3 \times 2 = 30$ medidas (canais).

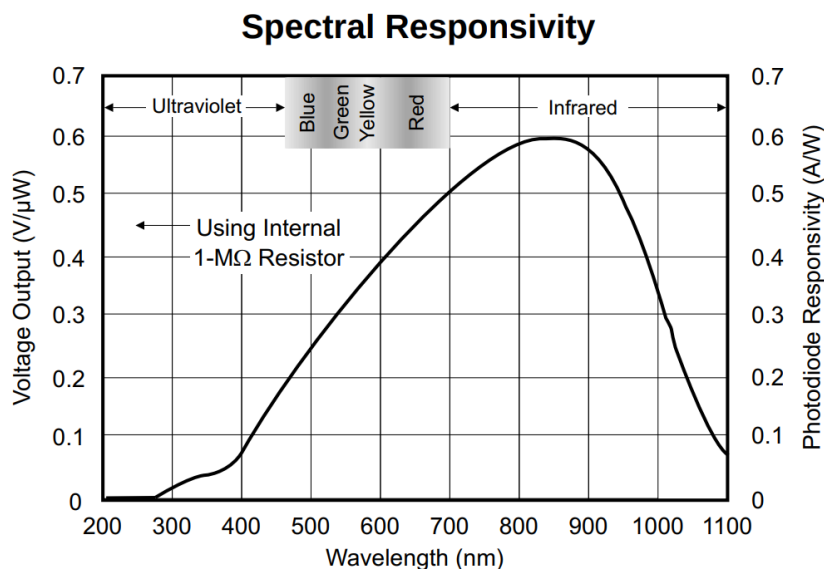


Figura 3.7. Resposta espectral do OPT101. Fonte: [75].




Figura 3.8. Configuração escolhida para o OPT101. Adaptado de [75].

3.1.2.2 Seleção dos Canais

Para realizar a leitura de cada fotodiodo, foi necessário utilizar uma etapa de chaveamento analógico, de forma a permitir que cada canal fosse amostrado separadamente. O CI escolhido para essa tarefa foi o MCP6S28, que é um multiplexador analógico de 8 entradas, atrelado a um Amplificador de Ganho Programável, do inglês *Programmable Gain Amplifier* (PGA), controlados digitalmente por meio de uma interface do tipo *Serial Peripheral Interface* (SPI) [50]. Um diagrama de blocos do circuito interno do MCP6S28 é apresentado na Figura 3.10.

Uma das principais características do MCP6S28 é que ele possui um excursãoamento *rail-to-rail*, tanto nas entradas como na saída, permitindo o uso de sinais com valores de




Figura 3.9. Disposição dos detectores e LEDs no placa de aquisição, que possui dimensões $5\text{ cm} \times 5\text{ cm}$. Cada quadrado representa um OPT101, e cada círculo representa um par de LEDs, sendo um vermelho e outro infravermelho.




Figura 3.10. Diagrama de blocos interno do MCP6S28. Fonte: [50].

tensão próximos à alimentação do CI. Ao todo foram utilizados três MCP6S28, o que possibilita a aquisição de até 24 fotodiodos. O estágio de ganho interno ao MCP6S28 não foi utilizado, sendo configurado em ganho unitário. O circuito eletrônico de interfaceamento do MCP6S28 é apresentado na Figura 3.11.

Tabela 3.1. Características técnicas do MCP6S28. Fonte: [50].

Características MCP6S28	
Ganho	1, 2, 4, 5, 8, 10, 16 e 32 V/V
Largura de Banda	12 MHz (-3 dB)
Erro de Ganho	$< 1\%$
Alimentação	2.5 V - 5.5 V
Consumo de Corrente	1.1 mA
Excursionamento Entrada	Rail-to-Rail
Excursionamento Saída	Rail-to-Rail
Comunicação	SPI 4-wire

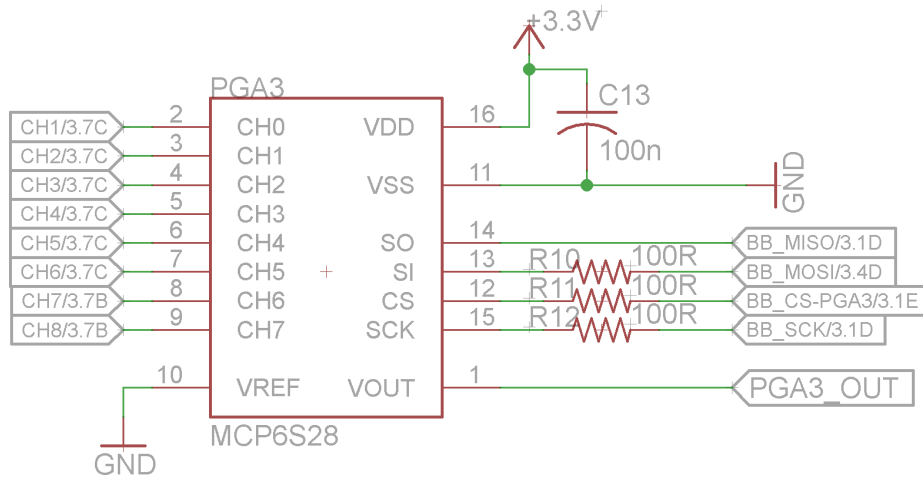


Figura 3.11. Configuração do circuito utilizado para interfaceamento de cada um dos três MCP6S28.

3.1.2.3 Filtragem

Entre as etapas de captação e amplificação do sinal, foi incluído um estágio de filtragem com o objetivo de confinar o sinal em uma banda limitada em frequência para evitar aliasing na etapa de digitalização, além de remover o nível DC do sinal para posterior amplificação. Essa etapa consiste em dois filtros ativos com ganho unitário, sendo um passa-altas seguido de um passa-baixas. A seguir são discutidos detalhes da implementação desses filtros.

Passa-Altas

O primeiro passo após captar o sinal gerado pelo fotodiodo é remover o nível DC do sinal, para posterior amplificação. Para tal, foi projetado um filtro passa-altas do tipo butterworth de segunda ordem. O filtro butterworth tem como características faixas de passagem e de rejeição planas, e uma região de transição moderada. A função de transferência desse filtro, no domínio da frequência, é

$$H(s) = \frac{s^2}{s^2 + \left(\frac{2\pi f_c}{Q}\right)s + (2\pi f_c)^2}, \quad (3.1)$$

onde f_c é a frequência de corte dada em Hertz, e Q é o fator de qualidade do filtro [60].

O circuito do filtro passa-altas foi implementado com a topologia Sallen-Key. Essa topologia permite implementar a função de transferência (3.1) com um amplificador operacional, dois resistores e dois capacitores, conforme mostrado na Figura 3.12.




Figura 3.12. Topologia Sallen-Key para filtro passa-altas tipo Butterworth de segunda ordem.

A frequência de corte do filtro da Figura 3.12, em Hertz, é

$$f_c = \frac{1}{2\pi\sqrt{R_1 R_2 C_1 C_2}}, \quad (3.2)$$

e o fator de qualidade é

$$Q = \frac{\sqrt{R_1 R_2 C_1 C_2}}{R_2 (C_1 + C_2)}, \quad (3.3)$$

onde R_1 e R_2 são os valores de resistência em Ohms, e C_1 e C_2 os valores de capacitância em Farads [60].

Os valores escolhidos de resistência e capacitância foram, respectivamente, $R_1 = R_2 = 330 \text{ k}\Omega$, e $C_1 = C_2 = 10 \text{ }\mu\text{F}$. Tais valores resultaram em uma frequência de corte $f_c = 48.23 \text{ mHz}$ e um fator de qualidade $Q = 0.5$. A função de transferência do filtro implementado com a topologia de Sallen-Key é

$$H(s) = \frac{s^2}{s^2 + 606.06 \cdot 10^{-3} \cdot s + 91.83 \cdot 10^{-3}}, \quad (3.4)$$

e sua resposta em frequência é apresentada na Figura 3.13.

Passa-Baixas

Antes de amplificar o sinal, foi incluída uma etapa de filtragem de altas frequências, com o objetivo de confinar o sinal em uma banda limitada, para evitar aliasing na etapa de amostragem. Para tal, foi projetado um filtro butterworth do tipo passa-baixas, de

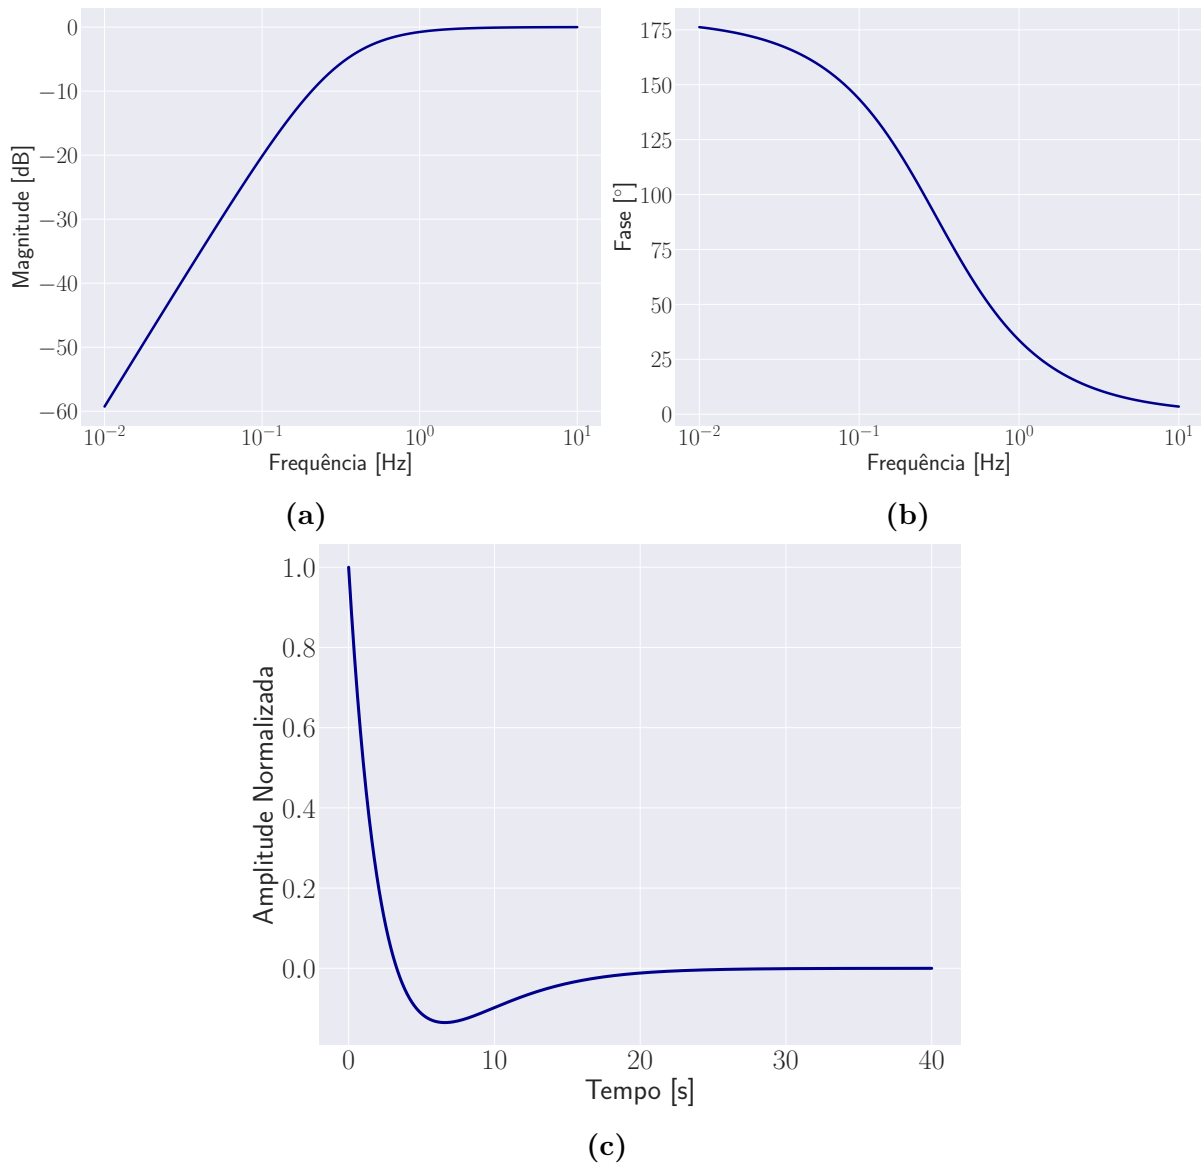


Figura 3.13. (3.13a) Resposta em frequência da magnitude do filtro butterworth passa-altas projetado. (3.13b) Resposta em frequência da fase do filtro. (3.13c) Resposta ao degrau unitário.

segunda ordem. A função de transferência desse filtro, no domínio da frequência, é

$$H(s) = \frac{(2\pi f_c)^2}{s^2 + \left(\frac{2\pi f_c}{Q}\right)s + (2\pi f_c)^2}. \quad (3.5)$$

Assim como no filtro passa-altas, também foi utilizada a topologia Sallen-Key para implementar o filtro passa-baixas de segunda ordem, mostrada na Figura 3.14.

Os valores escolhidos de resistência e capacitância foram, respectivamente, $R_1 = R_2 = 150 \text{ k}\Omega$, e $C_1 = C_2 = 100 \text{ nF}$. Tais valores resultaram em uma frequência de corte $f_c = 10.61 \text{ Hz}$ e um fator de qualidade $Q = 0.5$, ambos valores calculados por (3.2) e (3.3).




Figura 3.14. Topologia Sallen-Key para filtro passa-baixas tipo Butterworth de segunda ordem.

A função de transferência do filtro implementado com a topologia de Sallen-Key é

$$H(s) = \frac{s^2}{s^2 + 606.06 \cdot 10^{-3} \cdot s + 91.83 \cdot 10^{-3}}, \quad (3.6)$$

e sua resposta em frequência é apresentada na Figura 3.15.


3.1.2.4 Amplificação

Após a etapa de filtragem, foi inserido um circuito amplificador, com topologia não-inversora, para ajustar a amplitude dos sinais à escala do ADC. Nessa topologia, exemplificada na Figura 3.16, o sinal de saída possui a mesma fase do sinal de entrada porém, com um ganho de tensão (A_V) dado por:

$$A_V = 1 + \frac{R_2}{R_1} \quad (3.7)$$


O valor escolhido para a resistência R_1 foi de 100Ω , enquanto que no lugar da resistência R_2 , foi inserido um trimpot de $100 \text{ k}\Omega$. O ganho do amplificador pode ser ajustado entre 1 e 1000, conforme a necessidade.

O amplificador operacional escolhido para implementar os filtros passa-baixa, passa-alta e o circuito amplificador foi o MCP6002. Esse dispositivo é um amplificador operacional duplo, de baixo ruído, e que possui entradas e saídas *rail-to-rail*. Outra característica do MCP6002, é que sua alimentação é de fonte simples, dispensando um circuito de fonte-simétrica [49]. Algumas características do MCP6002 são apresentadas na Tabela 3.2. Na Figura 3.17, é apresentado o esquemático dos filtros cascadeados com o amplificador.



(a)

(b)



(c)

Figura 3.15. (3.15a) Resposta em frequência da magnitude do filtro but-terworth passa-baixas projetado. (3.15b) Resposta em frequência da fase do filtro. (3.15c) Resposta ao degrau unitário.




Figura 3.16. Topologia do amplificador não-inversor.

Tabela 3.2. Características técnicas do amplificador operacional MCP6002 (Valores típicos). Fonte: [49].

Características MCP6002	
Alimentação Fonte Simples	1.8 V - 6.0 V
Largura de Banda	1 MHz
Impedância de Entrada	10 TΩ
CMRR	76 dB
Ganho Malha Aberta	112 dB
Corrente Offset Entrada	±1 pA




Figura 3.17. Circuitos de filtros e amplificação utilizado no sistema.

3.1.2.5 Digitalização

Para a digitalização do sinal de fNIRS, foi utilizado um conversor analógico-digital ADS1256. Esse ADC é controlado digitalmente por meio de um barramento do tipo SPI, e é projetado especificamente para aplicações que requerem baixo ruído. Sua resolução é de 24 bits, o que gera 16 777 216 de níveis de quantização, e possui uma taxa de amostragem de até 30000 amostras por segundo, além de 8 entradas analógicas. O encapsulamento do ADS1256 é do tipo SSOP-28.

Internamente o ADS1256 possui um *buffer* para o sinal de entrada e um PGA, com ganhos entre 1-64. A etapa de conversão é realizada por um modulador do tipo delta-sigma de quarta ordem, seguido por um filtro digital passa-baixas programável. Todas essas etapas podem ser controladas digitalmente. A Figura 3.18 apresenta um diagrama de blocos do ADS1256.

Devido à etapa de condicionamento do sinal, não foi necessário utilizar os *buffers* internos do conversor, e o PGA foi configurado com ganho unitário. A frequência do corte filtro passa-baixas digital no ADS1256 está atrelada à taxa de amostragem. Com uma configuração de 30000 amostras por segundo, a frequência de corte do filtro é de 6106 Hz (Figura 3.19) [74]. A configuração do circuito eletrônico utilizado para interfacear o ADS1256 à Beaglebone Black é apresentada na Figura 3.20.

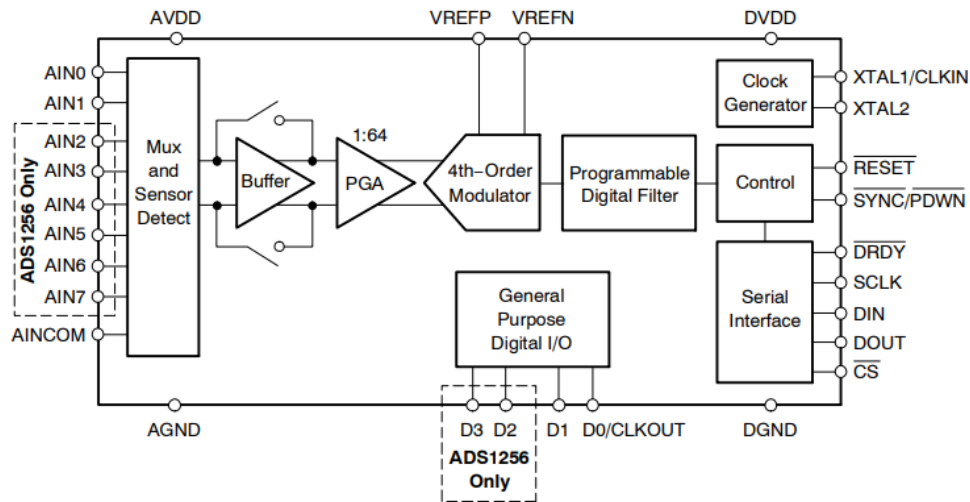


Figura 3.18. Diagrama de blocos do ADS1256. Fonte: [74].

Tabela 3.3. Configurações técnicas utilizadas para adquirir sinais com o ADS1256.

Parâmetros ADS1256	
Tipo	Delta-Sigma
Resolução	24 bits
Taxa de Amostragem	30000 SPS
Largura de Banda	6106 Hz (-3 dB)
Buffer	Desabilitado
PGA Ganho	1
Alimentação Analógica	5 V V
Alimentação Digital	3.3 V
Comunicação	SPI 4-wire
Potência (Modo Ativo)	38 mW
Potência (Modo Stand-by)	0.4 mW

3.1.3 Controle e Processamento Digital

Todo o gerenciamento dos circuitos eletrônicos implementados é realizado por uma placa BBB, mostrada na Figura 3.21. A BBB é um Computador em placa única, do inglês *Single-Board Computer* (SBC), *open-source* e *open-hardware*, que contém um processador AM335x 1 GHz ARM Cortex-A8 [5]. Entre as características da BBB, pode-se citar:

- Memória RAM 512MB DDR3
- Acelerador Gráfico 3D
- 2x PRU 32-bit
- 92 Pinos de I/O
- Suporte a protocolos de comunicação: Serial, SPI e I²C

A escolha por essa placa se deve ao fato de o processador pela possuir internamente,




Figura 3.19. Resposta em frequência do filtro digital interno ao ADS1256, para uma taxa de amostragem de 30000 SPS. Fonte: [74].

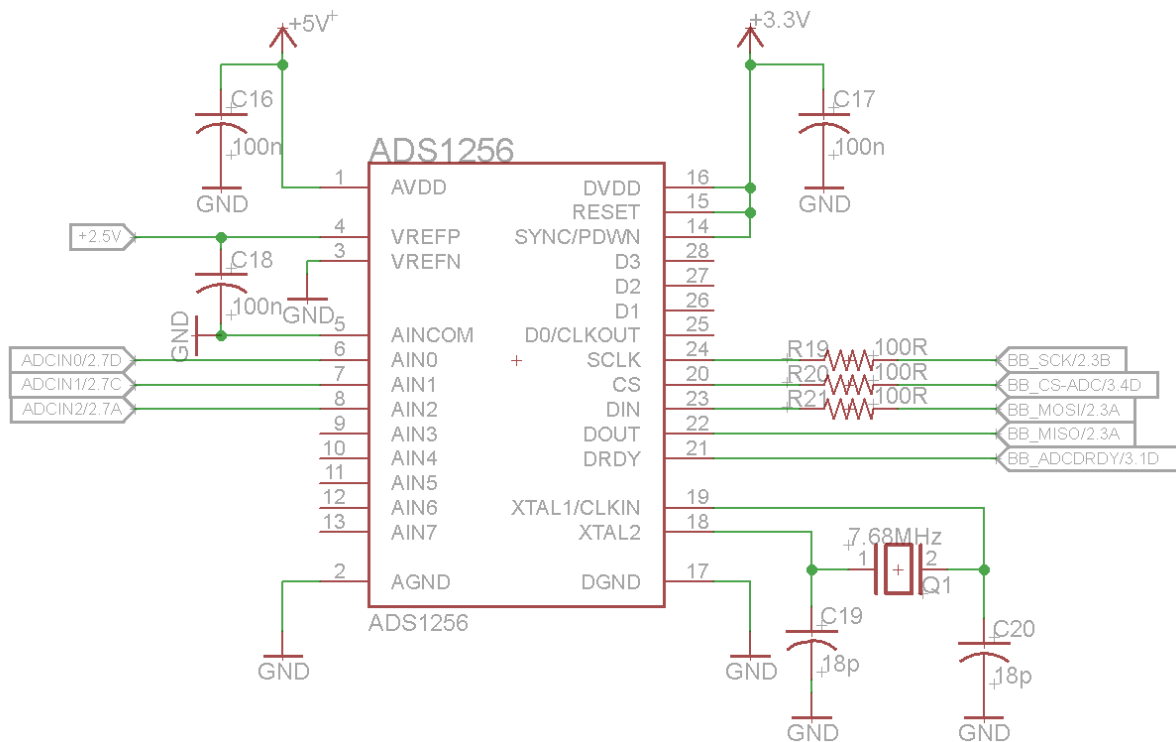


Figura 3.20. Configuração do circuito eletrônico utilizado para adquirir sinais com o ADS1256.

duas unidades microcontroladoras, chamadas Unidade de Programação de Tempo-Real, do inglês *Programmable Real-time Unit* (PRU), que permitem realizar tarefas em tempo real, em paralelo ao processamento principal. Essa característica é fundamental em sis-

temas desse tipo, onde a digitalização de sinais analógicos deve seguir o tempo de amostragem de forma determinística.






Figura 3.21. BeagleBone Black. Fonte: [5]

Para a validação das aquisições, foi implementado um interface gráfica, em linguagem de programação PYTHON, que funciona remotamente à BBB, por meio de uma conexão tipo *socket*. Essa interface recebe os dados, e plota o sinal de cada canal recebido, funcionando similar a um osciloscópio. A Figura 3.22 mostra uma captura de tela dessa interface, enquanto os sensores coletam um sinal no pulso de uma pessoa.



(a)



(b)

Figura 3.22. Interface gráfica implementada para validar as aquisições. Nesse exemplo em particular, está sendo mostrado a aquisição em tempo real, com um canal apenas, com os sensores posicionados no pulso.

3.1.4 Circuito de Alimentação

A alimentação elétrica do circuito vem de uma fonte de tensão DC de 12V com 1 A de corrente. Dessa tensão de entrada, são geradas quatro novas tensões reguladas para os sub-circuitos presentes no sistema, sendo duas de 5 V (uma exclusiva para a BBB), uma de 3.3 V e uma de 2.5 V (Figura 3.23).

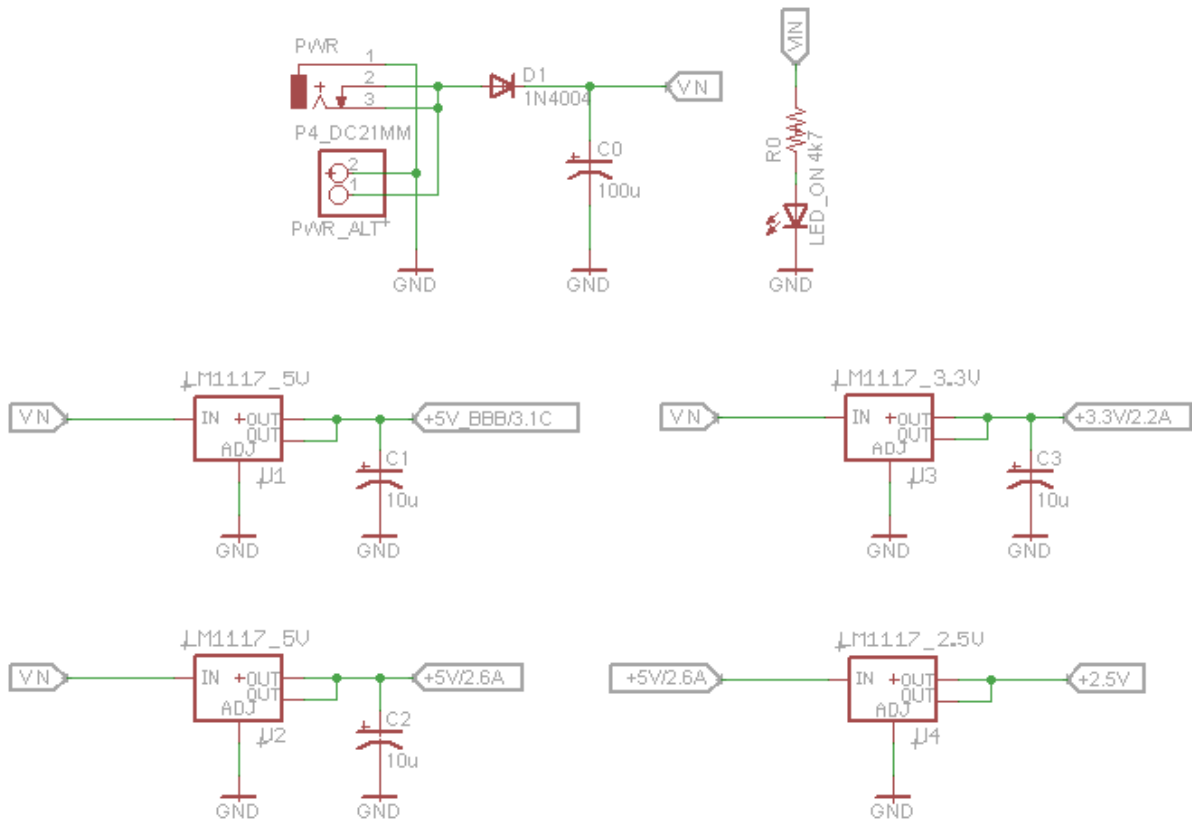




Figura 3.23. Circuito de alimentação do sistema.

3.2 CIRCUITO IMPLEMENTADO

O hardware de aquisição implementado é apresentado nas Figuras 3.24 , 3.25 e 3.26. Em especial, destaca-se a Figura 3.24b que apresenta a placa optodo, utilizada para a coleta dos sinais com os participantes. Nela estão presentes 5 fotodetectores e 3 pares de LEDs, com duplo comprimento de onda, possibilitando a aquisição de até 30 medidas por instante de tempo. A Figura 3.25a apresenta o circuito de chaveamento das fontes de emissão, enquanto que a Figura 3.25b mostra o circuito de processamento, onde está presente a placa Beaglebone.




(a)




(b)

Figura 3.24. Detalhe do circuito da placa que contém os LEDs e fotodiodos. Cada placa dessa possui 5 fotodiodos e 3 pares de LEDs, possibilitando 30 medidas (15 de luz vermelha + 15 de infravermelha).



(a)



(b)

Figura 3.25. (3.25a) Circuito de chaveamento e controle das fontes de emissão. (3.25b) Detalhe da placa principal, onde estão presentes os circuitos de aquisição e de processamento.




Figura 3.26. Conjunto completo.

3.3 IMPLEMENTAÇÃO E AVALIAÇÃO DOS CLASSIFICADORES

Nessa seção serão discutidos os métodos utilizados para implementação e avaliação dos resultados de classificação dos sinais adquiridos. Apenas os métodos direcionados para problemas de classificação binária supervisionada serão tratados.

3.3.1 Software

A etapa de tratamento dos dados coletados e os classificadores utilizados foram implementados em linguagem PYTHON, na versão 3.7.5. A Tabela 3.4 contém as versões e os módulos específicos utilizados de cada pacote usado para as implementações.

Tabela 3.4. Pacotes utilizados para manipulação dos dados e implementação dos classificadores. A versão do PYTHON utilizada foi a 3.7.5.

Pacote	Versão	Descrição
numpy	1.17.4	Biblioteca utilizada para manipulação de arrays multidimensionais, além de conter um conjunto de funções de álgebra linear.
matplotlib	3.1.1	Biblioteca utilizada para criação de gráficos.
scipy	1.3.2	Conjunto de funções e algoritmos voltados para aplicações em matemática, ciência e engenharia. Módulos utilizados: <code>signal</code> , <code>fftpack</code> , <code>linalg</code> e <code>io</code> .
scikit-learn	0.22.0	Biblioteca que implementa diversos algoritmos de aprendizagem de máquina, além de métodos avaliação de classificadores, e funções de manipulação de dados, como divisão em treinamento e teste, escalonamento, etc. Módulos utilizados: <code>classification_report</code> , <code>confusion_matrix</code> , <code>cross_validate</code> , <code>KFold</code> , <code>metrics</code> , <code>model_selection</code> , <code>svm</code> , <code>train_test_split</code> .

3.3.2 Arquitetura Geral

Os modelos preditivos implementados seguiram uma estrutura geral, que consiste de 6 etapas:

- Pré-processamento
- Extração de características
- Divisão da base de dados

- Treinamento do modelo com uma base de treino
- Predição em uma base de teste
- Avaliação do modelo

A Figura 3.27 apresenta a ordem sequencial de cada etapa.

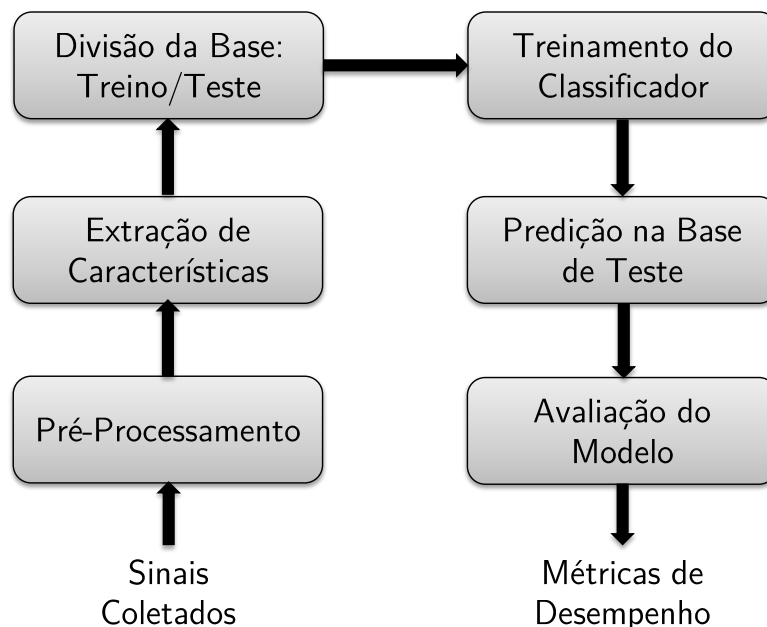


Figura 3.27. Arquitetura simplificada dos sistemas de classificação implementados.

Pré-processamento

A etapa de pré-processamento dos dados consistiu em segmentar os sinais adquiridos, utilizando técnicas de janelamento, com tamanho fixo e sobreposição de informação. Para cada participante, os sinais foram segmentados, utilizando uma janela de Hamming simétrica, em vetores de 10 segundos de duração, com sobreposição de 50% de cada janela anterior. A Tabela 3.5 descreve sucintamente os parâmetros utilizados.

Extração de Características

Nessa etapa, foram extraídos atributos dos sinais janelados, seguindo a metodologia de trabalhos similares, conforme explicitado na Subseção 2.3.2. Ao todo foram utilizadas 5 características, sendo elas: média, desvio padrão, máximo, mínimo e PSD. Cada exemplo utilizado para treinar e/ou validar os classificadores possui um total de 104 atributos descritivos.

Tabela 3.5. Parâmetros utilizados para o janelamento dos sinais coletados.

Parâmetro	Descrição
Tipo de Janela	Hamming Simétrica, calculada pela expressão: $w(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{M-1}\right)$, $0 \leq n < M-1$, onde M é o número de amostras da janela.
Sobreposição	50% da janela anterior.
Duração	10 segundos.

Tabela 3.6. *Features* utilizadas para treinamento dos modelos preditivos..

Atributo	Descrição
Média	Média aritmética da janela.
Desvio Padrão	Desvio padrão da janela.
Máximo	Máximo registrado em uma janela.
Mínimo	Mínimo registrado em uma janela.
PSD	Distribuição espectral de potência da janela, com largura de banda limitada entre 0 e 10 Hz, e 100 bandas de energia.

Divisão da Base em Treino e Teste

A divisão do conjunto de dados em base de treinamento e base de teste, após o pré-processamento e a extração de características, foi realizada com a técnica de validação cruzada K-Fold, com $K = 5$. Ou seja, 80% dos dados foram utilizados para treinamento do classificador, e os 20% restantes para avaliá-lo. A divisão dos *folds* em cada rodada foi realizada com amostragem aleatória.

O conjunto de dados de treinamento foi escalonado, utilizando a técnica de padronização, também chamada de Z-score. Inicialmente, foram computadas as médias e os desvios padrão de cada atributo presente na base de treino. Por fim foi aplicada a transformação, descrita pela expressão

$$x' = \frac{x - \bar{x}}{s^2}, \quad (3.8)$$

onde x' representa a transformação do atributo x , \bar{x} é a média do atributo na base de treino, e s^2 o desvio padrão. Os valores de \bar{x} e s^2 foram utilizados para, posteriormente, padronizar as bases de teste.

Treinamento do Modelo

Em cada iteração da validação cruzada por K-Fold, um novo modelo preditivo foi instanciado, e treinado com os respectivos *folds* de treino. Os parâmetros utilizados nos modelos SVM são apresentados na Tabela 3.7.

Tabela 3.7. Parâmetros utilizados para o modelo SVM, de acordo com a biblioteca `scikit-learn`.

Parâmetro	Valor	Descrição
Kernel	<code>rbf</code>	Kernel gaussiano, calculado por $\exp(\gamma \ \mathbf{x}_i - \mathbf{x}_j\ ^2)$.
γ	<code>scale</code>	Coefficiente de kernel, calculado como $\gamma = \frac{1}{L \cdot s^2}$, onde L é a quantidade de atributos, e s^2 sua variância.
C	<code>1.0</code>	Parâmetro de regularização.
<code>tol</code>	<code>1e-6</code>	Tolerância de convergência do algoritmo de otimização.

Teste e Avaliação dos Modelos

Em cada rodada do K-Fold, após o treinamento do modelo, foi realizada a predição nos *folds* de teste. Em seguida, foi computada a matriz de confusão, para posteriormente calcular as métricas de desempenho descritas na Subseção 2.3.4, sendo elas: precisão, acurácia, sensibilidade e medida-F. As métricas finais de desempenho foram determinadas pela média e desvio padrão das métricas de cada rodada, ao fim de todas as iterações do K-Fold, e separadamente para treinamento e teste.

4 RESULTADOS E DISCUSSÃO

Este capítulo descreve, em detalhes, o procedimento experimental adotado para avaliar a instrumentação desenvolvida. Em seguida, são apresentados os resultados de cada experimento, e uma discussão a cerca dos resultados obtidos.

4.1 PROCEDIMENTO EXPERIMENTAL

Os experimentos foram realizados dentro das instalações da Universidade de Brasília, no Campus da Faculdade do Gama, em salas com iluminação artificial controlada. A iluminação do ambiente foi proveniente de lâmpadas fluorescentes comuns, do tipo tubular, dispostas no teto de cada sala. Ao todo, cinco voluntários participaram das coletas, designados nesse trabalho por letras de A a E. Uma descrição física dos participantes é apresentada na Tabela 4.1.

Tabela 4.1. Características físicas dos voluntários que participaram dos experimentos.

Participante	Sexo	Etnia	Idade
A	Feminino	Negra	22
B	Masculino	Branca	22
C	Masculino	Parda	29
D	Masculino	Branca	55
E	Masculino	Parda	23

Cada participante foi instruído a permanecer sentado em uma cadeira com apoio dorsal, de forma que ele se sinta confortável, durante a aquisição dos sinais de fNIRS. O próprio participante posicionou a placa com os optodos (Figura 3.24b) na região central de sua testa, com sua mão não dominante, permanecendo nessa posição durante toda a coleta. Após estabelecida a posição de aquisição, foram realizados ajustes de ganho nos amplificadores de sinais, conforme cada caso, com o objetivo de garantir que o sinal de coleta permanecesse em uma faixa dinâmica segura do conversor AD.

A coleta de sinais, em cada sessão, teve duração exata de 6 minutos, monitorado por


um cronometro. Durante metade desse tempo (3 minutos), cada participante permaneceu com sua mão dominante em estado de repouso, e durante a outra metade, realizando movimentos sequenciais com os dedos, denominados de *finger-tapping*.

4.1.1 Comitê de Ética


O protocolo experimental utilizado para aquisição de sinais reais de fNIRS em seres humanos foi aprovado, sem ressalvas ou pendências, pelo Comitê de Ética em Pesquisa com Seres Humanos da Faculdade de Ciências da Saúde da Universidade de Brasília, sob o parecer consubstanciado de número **2.679.589**.

4.2 AQUISIÇÃO DE CURVA PLETISMOGRÁFICA

Para avaliar a montagem da instrumentação implementada, um experimento preliminar foi realizado, consistindo em adquirir um sinal de pletismografia com um dos participantes. O sinal em questão foi coletado com a placa sensora (Figura 3.24b) localizada no punho dominante do participante A, utilizando uma fonte de luz infravermelha e um fotodetector. A curva coletada é apresentada na Figura 4.1. A taxa de amostragem para essa aquisição foi de 4.5 kHz. A taxa de batimento cardíaco média, mensurada no momento da coleta por meio de oxímetro de pulso comercial, foi de aproximadamente 84 batimentos por minuto, coincidindo com o pico de frequência de maior amplitude (Figura 4.1b) de valor 1.4 Hz.



(a)



(b)

Figura 4.1. Curva pletismográfica adquirida com o participante A. Em (4.1a) é mostrado o sinal no domínio do tempo, e em (4.1b) a densidade espectral de potência no domínio da frequência.

4.3 DETECÇÃO DE MOVIMENTO UTILIZANDO APENAS UM FOTODETECTOR E UM COMPRIMENTO DE ONDA

O primeiro experimento voltado para a classificação de estados de movimento foi realizado utilizando um conjunto formado por um fotodetector e uma fonte de luz. Foram realizadas duas sessões de coleta com dois participantes distintos. Na primeira sessão foram coletados sinais utilizando uma fonte de luz vermelha, enquanto que na segunda uma fonte de luz infravermelha. Cada sessão de coleta teve duração exata de 6 minutos. Na primeira metade de cada coleta, os participantes foram orientados a ficar relaxados e em estado de repouso, sem a realização de movimentos com as mãos. Na segunda metade, eles realizaram movimentos de *finger-tapping* com suas respectivas mãos dominantes.

Os sinais foram amostrados a uma taxa constante de 4.5 kHz. A placa com o conjunto de fontes e detectores foi posicionada na testa de cada participante, em posição central. Após a etapa de coleta, os sinais de cada participante foram segmentados para compor um conjunto de dados para posterior classificação. Essa segmentação foi realizada com a técnica de janelamento, utilizando uma janela de Hamming simétrica, com duração de 10 segundos e sobreposição de 50% de cada janela anterior. Em cada janela de 10 segundos, foram extraídas 5 características, sendo elas: média, desvio padrão, máximo, mínimo e PSD. A PSD de cada janela foi calculada com um total de 100 bandas de energia de mesmo comprimento, entre as frequências de 0 a 10 Hz.

O conjunto de dados obtido para cada participante contém 350 exemplos de dimensão igual a 104, divididos igualmente em cada classe, ou seja, 175 exemplares representando estado de repouso e 175 representando estado de *finger-tapping*. As bases foram inseridas em um classificador SVM com kernel RBF, utilizando a técnica de validação cruzada K-Fold com $k = 5$. Ou seja, em cada iteração do K-Fold, 80% do conjunto foi utilizado para treinar um novo modelo instanciado, e os 20% restantes para avaliar o desempenho do classificador. As métricas de desempenho foram computadas e armazenadas a cada iteração, para as bases de treino e de teste. Ao fim do processo, foram extraídas média e desvio padrão de cada métrica armazenada.

Análise de classificação com o participante A

As Figuras 4.2 e 4.3 apresentam os sinais inteiros coletados nas duas sessões, utilizando as fontes de luz vermelha e infravermelha, respectivamente, para o participante A.




Figura 4.2. Aquisição com a fonte de luz vermelha para o participante A. Em (4.2a) é apresentado o sinal no domínio do tempo, e em (4.2b) a densidade espectral de potência em função da frequência.




Figura 4.3. Aquisição com a fonte de luz infravermelha para o participante A. Em (4.2a) é apresentado o sinal no domínio do tempo, e em (4.2b) a densidade espectral de potência em função da frequência.

Observa-se que, tanto para a luz vermelha como para a infravermelha, não é possível determinar visualmente uma grande diferença entre as atividades de repouso e de finger-tapping, nos gráficos dos sinais inteiros mostrados nas Figuras 4.2 e 4.3, seja no domínio do tempo ou no domínio da frequência. Entretanto, no espectrograma obtido com os sinais janelados já é possível verificar que há uma diferença visual entre essas atividades, conforme pode ser observado na Figura 4.4.

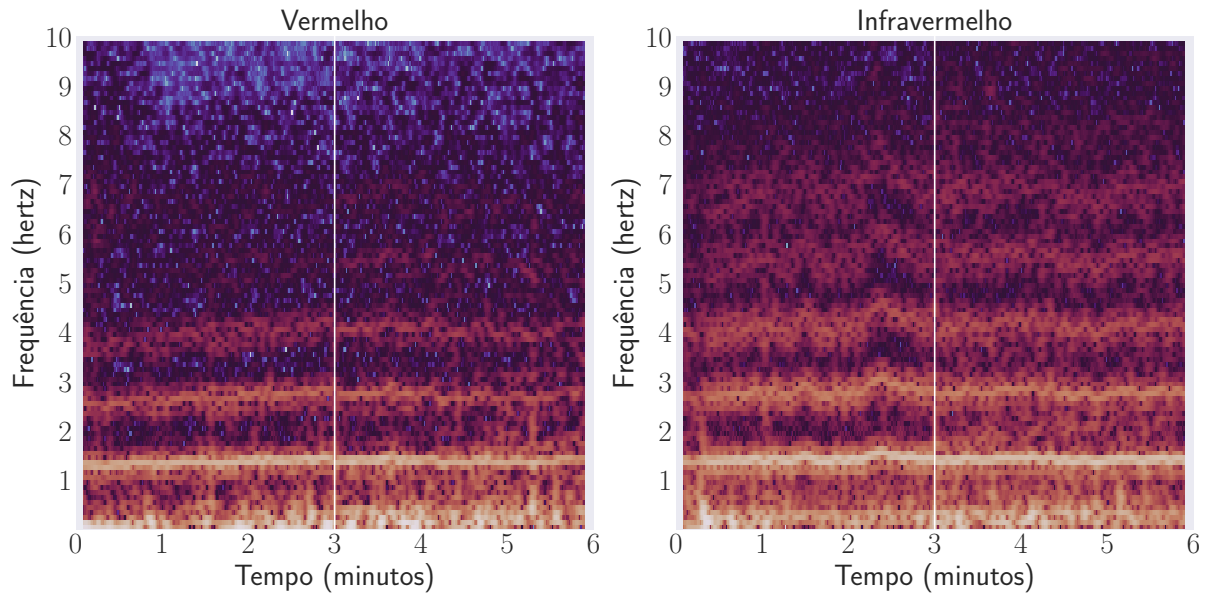


Figura 4.4. Espectrograma dos sinais coletados com o participante A. A linha branca em cada imagem separa o estado de repouso (esquerda) do estado de movimento (direita).

As métricas de desempenho obtidas no processo de classificação para as bases de treino e de teste, em cada comprimento de onda, são mostradas na Tabela 4.2. Os resultados obtidos para cada fonte de luz foram similares, com índices médios superiores a 96% nas bases de treino e de teste, em cada métrica calculada. Esses resultados indicam que é possível diferenciar, com boa acurácia, estados de repouso e de movimento utilizando uma topologia simples formada por uma fonte de luz e um fotodetector, para um mesmo participante.

Tabela 4.2. Média e desvio padrão das métricas de desempenho de classificação dos sinais coletados com o participante A, considerando apenas uma única fonte de luz com um fotodetector.

Métricas	Canais			
	Vermelho		Infravermelho	
	Treino	Teste	Treino	Teste
Acurácia	98.9 ± 0.3 %	97.7 ± 1.5 %	98.7 ± 0.4 %	97.7 ± 1.8 %
Precisão	97.9 ± 0.7 %	96.2 ± 2.6 %	97.5 ± 0.7 %	96.3 ± 3.8 %
Revocação	99.9 ± 0.3 %	99.4 ± 1.1 %	100.0 ± 0.0 %	99.5 ± 1.1 %
Medida-F	98.9 ± 0.2 %	97.8 ± 1.3 %	98.7 ± 0.4 %	97.8 ± 1.8 %

Análise de classificação com o participante B

Assim como no caso do participante A, não foi possível verificar uma diferença visual nos sinais coletados no domínio do tempo e da frequência, conforme pode ser visto nos

gráficos das Figuras 4.5 e 4.6. Já nos espectrogramas gerados a partir dos sinais segmentados em janelas, mostrados na Figura 4.7, é possível observar uma leve diferença nos estados de repouso e de movimento, porém não tão acentuada como no caso do participante A.




Figura 4.5. Aquisição com a fonte de luz vermelha para o participante A. Em (4.5a) é apresentado o sinal no domínio do tempo, e em (4.5b) a densidade espectral de potência em função da frequência.




Figura 4.6. Aquisição com a fonte de luz infravermelha para o participante A. Em (4.5a) é apresentado o sinal no domínio do tempo, e em (4.5b) a densidade espectral de potência em função da frequência.

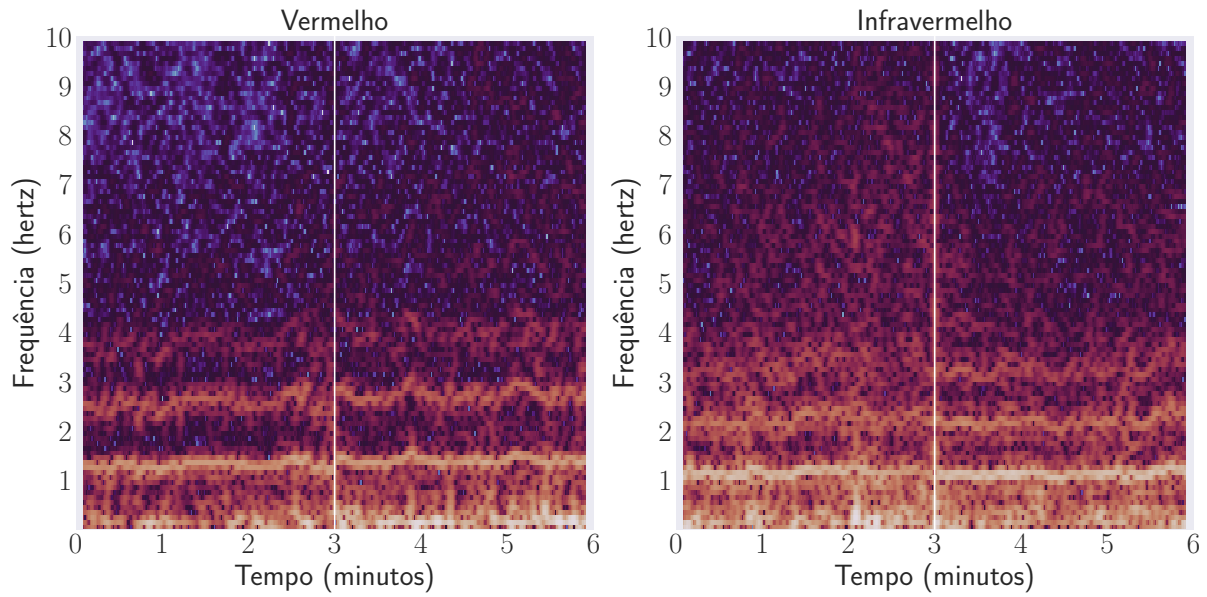


Figura 4.7. Espectrograma dos sinais coletados com o participante B. A linha branca em cada imagem separa os casos de repouso (esquerda) dos casos com movimento (direita). Cada coluna desse espectrograma é considerado como um exemplo para o classificador.

As métricas médias de desempenho obtidas no processo de classificação dos sinais coletados com o participante B são apresentadas na Tabela 4.3. Observa-se que os índices de desempenho foram levemente inferiores aos do participante A no comprimento de onda infravermelho, com acurácia por volta de 91% na base de teste. Entretanto, para a fonte de luz vermelha é possível diferenciar, com acurácia média de 96%, os estados de movimento e de repouso.

Tabela 4.3. Média e desvio padrão das métricas de desempenho de classificação dos sinais coletados com o participante B, considerando apenas uma única fonte de luz com um fotodetector.

Métricas	Canais			
	Vermelho		Infravermelho	
	Treino	Teste	Treino	Teste
Acurácia	98.1 ± 0.4 %	96.6 ± 1.9 %	96.8 ± 0.8 %	91.7 ± 2.6 %
Precisão	96.5 ± 0.4 %	94.6 ± 2.8 %	97.9 ± 0.6 %	93.7 ± 5.6 %
Revocação	99.7 ± 0.6 %	98.8 ± 2.3 %	95.6 ± 1.4 %	90.2 ± 3.5 %
Medida-F	98.1 ± 0.4 %	97.8 ± 1.3 %	96.7 ± 0.8 %	91.7 ± 1.9 %

4.4 DETECÇÃO DE MOVIMENTO UTILIZANDO UM FOTODETECTOR E DOIS COMPRIMENTOS DE ONDA DISTINTOS

Após a análise de classificação com apenas uma fonte de luz, foi realizada uma análise multicanal, com dois comprimentos de onda distintos e um fotodetector, utilizando os sinais coletados com os participantes A e B no experimento anterior.

A geração da base de dados seguiu o mesmo procedimento descrito no caso anterior, com a segmentação dos sinais em janelas de 10 segundos e sobreposição de 50% das janelas anteriores. Entretanto, nesse caso, cada exemplo possui o dobro de atributos descritivos devido a presença de duas fontes de luz.

O conjunto de dados gerado, para cada participante, possui 350 exemplos de dimensão igual a 208, igualmente balanceado entre as classes de repouso e de movimento. E assim como no caso descrito anteriormente, as métricas de desempenho foram estimadas pela técnica de K-Fold, com 5 folds, e utilizando os mesmos parâmetros para o modelo de classificação SVM.

A Tabela 4.4 apresenta as métricas estimadas para o processo de classificação dos participantes A e B. É possível notar que, para ambos participantes, as métricas médias apresentaram um aumento em relação ao experimento de classificação com apenas um comprimento de onda. Para o participante A, todas as métricas ficaram superior a 97% na base de teste, enquanto que para o participante B, praticamente todos os sinais foram classificados corretamente, com índices superiores a 99%. Esses resultados corroboram a análise descrita no caso anterior, indicando que é possível discernir estados de movimento *finger-tapping* de estados de repouso com a metodologia implementada.

Tabela 4.4. Média e desvio padrão das métricas de desempenho de classificação dos sinais coletados com os participante A e B, considerando duas fontes de luz.

Métricas	Participante A		Participante B	
	Treino	Teste	Treino	Teste
Acurácia	99.4 ± 0.6 %	98.4 ± 0.6 %	99.8 ± 0.2 %	99.7 ± 0.6 %
Precisão	98.8 ± 0.4 %	97.6 ± 0.4 %	100.0 ± 0.0 %	100.0 ± 0.0 %
Revocação	100.0 ± 0.0 %	100.0 ± 0.0 %	99.6 ± 0.3 %	99.4 ± 1.2 %
Medida-F	99.4 ± 0.6 %	99.2 ± 0.6 %	99.7 ± 0.1 %	99.8 ± 0.2 %

4.5 DETECÇÃO DE MOVIMENTO UTILIZANDO CINCO FOTODETECTORES E DOIS COMPRIMENTOS DE ONDA DISTINTOS

Um outro experimento de classificação foi realizado, porém visando explorar o potencial de aquisição do hardware implementado. Foram coletados sinais de 3 participantes – identificados aqui como C, D e E –, utilizando duas fontes de luz com comprimento de onda distintos e os cinco fotodetectores presentes na placa sensora (Figura 3.24b), gerando um total de 10 canais independentes.

A metodologia de aquisição aqui foi a mesma dos casos anteriores: 3 minutos em repouso seguidos de 3 minutos em estado de *finger-tapping*, para cada participante, gerando classes igualmente balanceadas. A única diferença no conjunto de dados gerado, para esse caso, é que cada exemplo da base possui dimensão igual a 1040, obtido por meio da concatenação dos 104 atributos de cada canal separado. A taxa de amostragem para cada canal foi de 450 Hz.

A Figura 4.8 mostra o comportamento temporal de dois sinais obtidos de um mesmo fotodetector com comprimentos de onda distintos para o participante C. Nesse gráfico, é possível observar que há uma certa diferença entre os dois estados monitorados, em particular na amplitude dos sinais em cada atividade. Os espectrogramas desses mesmos sinais, mostrados na Figura 4.8c, também corroboram essa análise, sendo possível distinguir visualmente os dois estados monitorados. As Figuras 4.9 e 4.10 apresentam os mesmos gráficos para os participantes D e E, respectivamente.

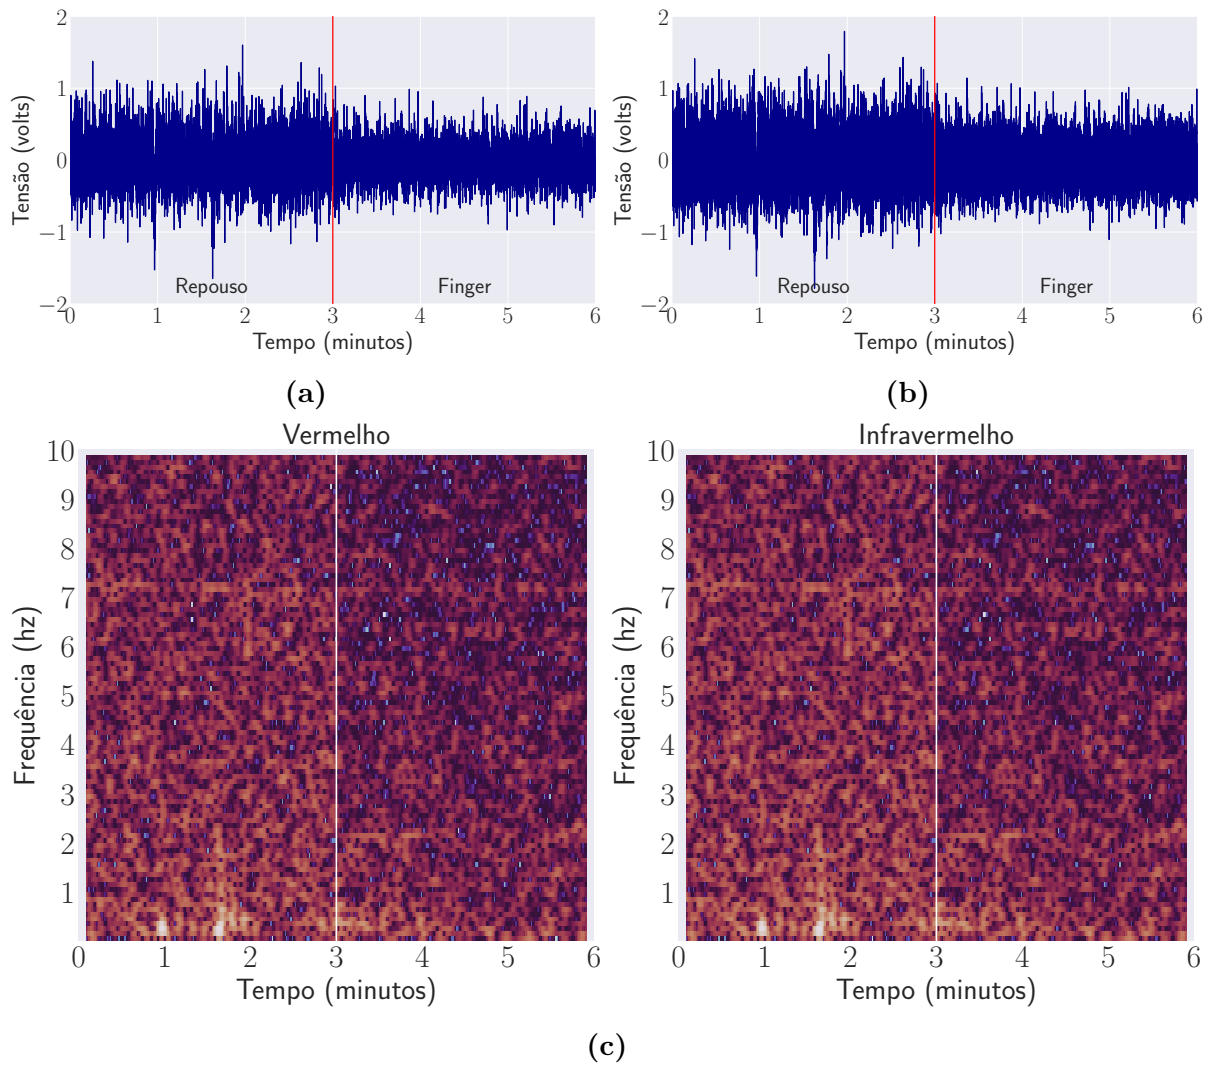


Figura 4.8. Sinais coletados com o participante C, provenientes de um dos cinco fotodetectores para dois comprimentos de onda distintos. Em (4.8a) é apresentado o sinal coletado sobre a luz vermelha, e em (4.8b) sobre a luz infravermelha. Em (4.8c) é apresentado os espectrogramas dos sinais anteriores.




Figura 4.9. Sinais coletados com o participante D, provenientes de um dos cinco fotodetectores para dois comprimentos de onda distintos. Em (4.8a) é apresentado o sinal coletado sobre a luz vermelha, e em (4.9b) sobre a luz infravermelha. Em (4.8c) é apresentado os espectrogramas dos sinais anteriores.

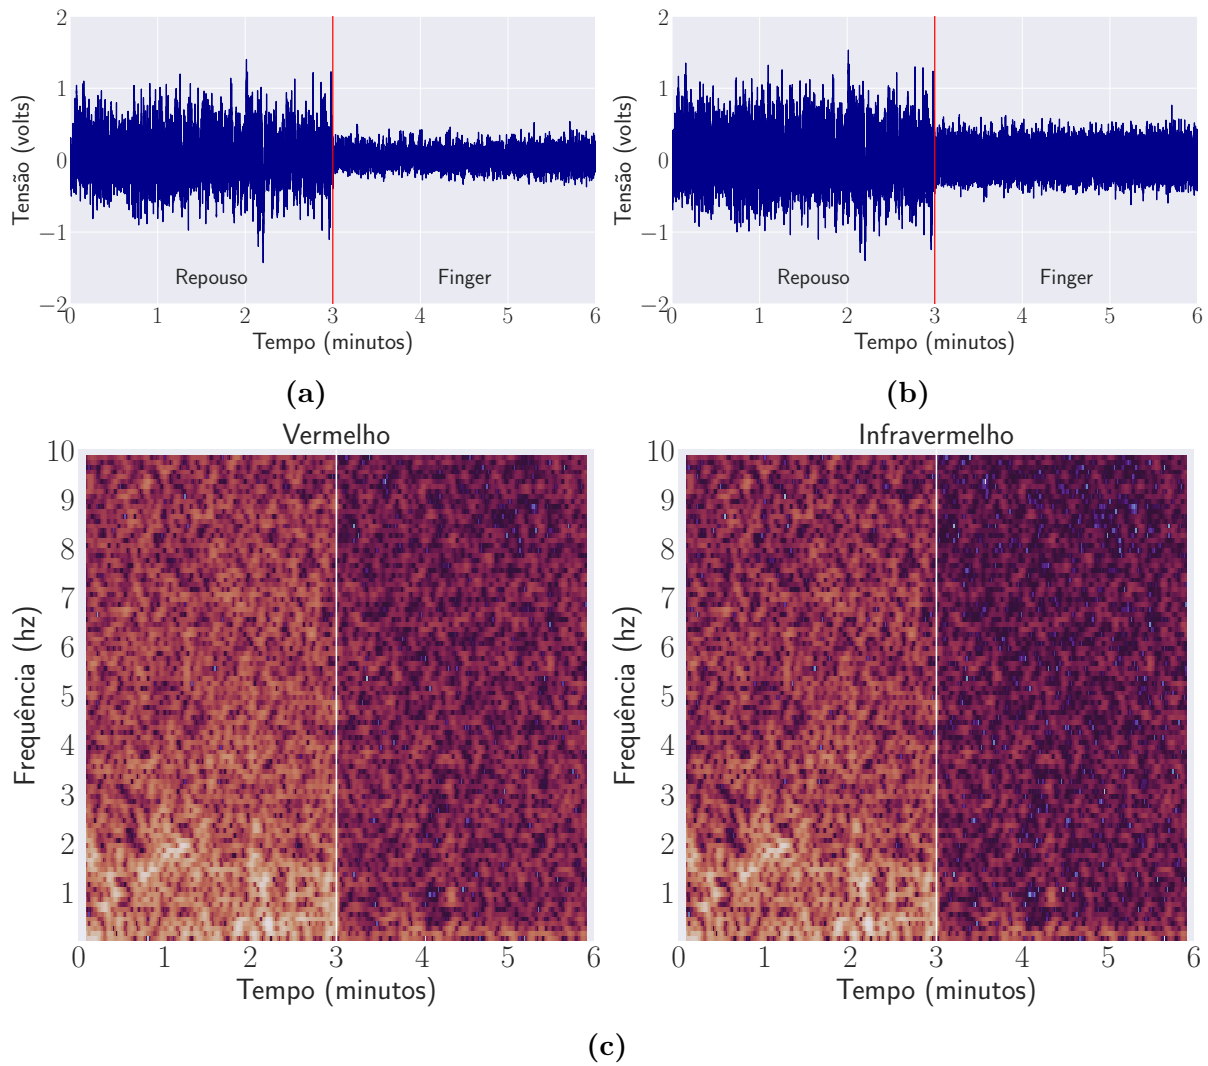


Figura 4.10. Sinais coletados com o participante E, provenientes de um dos cinco fotodetectores para dois comprimentos de onda distintos. Em (4.8a) é apresentado o sinal coletado sobre a luz vermelha, e em (4.10b) sobre a luz infravermelha. Em (4.8c) é apresentado os espectrogramas dos sinais anteriores.

A Tabela 4.5 apresenta as métricas de desempenho para a classificação dos sinais coletados com os três participantes. Assim como no caso da classificação com dois canais, os resultados obtidos com a aquisição multicanal – nesse caso com 10 canais –, indicam que é possível discernir bem os estados monitorados.

As métricas de desempenho da classificação dos sinais coletados com os participantes C e E mostram que o modelo acertou praticamente todos os casos nas respectivas bases de teste. Cabe destacar aqui que as métricas médias na base de treino do participante D foram inferiores aos demais, possivelmente devido a um artefato causado durante a aquisição no intervalo entre 4 e 5 minutos, conforme pode ser visto na Figura 4.9.

Tabela 4.5. Média e desvio padrão das métricas de desempenho de classificação dos sinais coletados com os participante C, D e E, considerando um total de 10 canais independentes.

Métricas	Participante C		Participante D		Participante E	
	Treino	Teste	Treino	Teste	Treino	Teste
Acurácia	99.9 ± 0.0 %	99.1 ± 0.1 %	99.0 ± 0.1 %	97.9 ± 0.3 %	100.0 ± 0.0 %	99.7 ± 0.0 %
Precisão	100.0 ± 0.0 %	98.9 ± 0.1 %	98.9 ± 0.1 %	97.8 ± 0.3 %	100.0 ± 0.0 %	100.0 ± 0.0 %
Revocação	99.9 ± 0.0 %	99.4 ± 0.1 %	99.0 ± 0.1 %	98.1 ± 0.2 %	100.0 ± 0.0 %	99.4 ± 0.0 %
Medida-F	99.9 ± 0.0 %	99.1 ± 0.1 %	98.9 ± 0.1 %	98.0 ± 0.3 %	100.0 ± 0.0 %	99.7 ± 0.1 %

4.6 AVALIAÇÃO DE DESEMPENHO DE CLASSIFICAÇÃO USANDO BASES DE TREINAMENTO E DE TESTE COLETADAS EM DIAS DISTINTOS

O último experimento realizado consistiu de repetir as sessões de coleta com os participantes C, D e E, com um intervalo de 2 dias de diferença em relação às primeiras sessões. Os modelos foram treinados com os dados coletados na primeira sessão, e avaliados com os dados da segunda. O motivo da realização desse experimento foi verificar o impacto na classificação de sinais coletados em dias diferentes dos sinais utilizados para treinamento dos modelos preditivos. Em outras palavras, avaliar a capacidade de generalização do modelo implementado em classificar sinais coletados em diferentes condições e que não foram utilizados no processo de treinamento do modelo.

A Tabela 4.6 apresenta os resultados obtidos nesse experimento. Observa-se que os índices ficaram bem abaixo dos índices dos experimentos anteriores. Em particular, pode-se destacar que a medida-F – uma média harmônica entre a precisão e a revocação – obtida, no caso dos três participantes, indica que o modelo não consegue distinguir bem os estados avaliados quando as condições de coleta são alteradas para um mesmo participante.

Tabela 4.6. Métricas de desempenho de classificação avaliadas em base de sinais coletados em dias distintos, para os participantes C, D e E.

Métricas	Participante C	Participante D	Participante E
Acurácia	68.7 %	85.7 %	72.3 %
Precisão	80.0 %	100.0 %	82.0 %
Revocação	55.4 %	71.4 %	60.1 %
Medida-F	65.5 %	83.3 %	69.4 %

Uma possível abordagem que poderia melhorar as métricas de desempenho de classificação, seria realizar sessões de coleta, para cada participante, em diversos dias distintos, sob diferentes condições de coleta. Ao treinar um modelo com sinais coletados em várias

condições, é provável que ele consiga obter uma capacidade melhor de generalização, e conseqüentemente ter uma acurácia maior na distinção dos estados de movimento do de não-movimento.

5 CONCLUSÃO

O objetivo principal da pesquisa foi desenvolver um sistema eletrônico de aquisição multicanal de sinais de espectroscopia funcional de infravermelho próximo, capaz de coletar canais independentes a uma taxa de amostragem constante e com alta resolução de quantização. O hardware de aquisição implementado atendeu aos requisitos específicos impostos, sendo possível coletar sinais de até 20 fotodetectores, além de controlar independentemente até 26 fontes de emissão com comprimento de onda distintos. A validação do equipamento construído foi realizada por meio de uma série de experimentos, cujos objetivos eram discernir a presença de movimento, em sinais reais adquiridos com seres humanos. Ao todo, cinco voluntários participaram desses experimentos. A classificação dos sinais coletados, em todos os experimentos, foi realizada com um modelo de predição SVM com kernel gaussiano.

No primeiro experimento, foi avaliado um cenário de classificação da presença ou ausência de movimentos utilizando uma topologia simples de aquisição, consistindo de uma fonte de emissão e um fotodetector. Nesse experimento foram realizadas duas sessões de coletas, com dois voluntários, em um mesmo dia. Na primeira sessão, os sinais foram adquiridos utilizando uma fonte de luz vermelha, enquanto que na segunda foi utilizada uma fonte de luz infravermelha. As métricas de desempenho de classificação para esse cenário foram satisfatórias, com índices médios de acurácia acima de 90% para os dois participantes, indicando que, para esse caso, a metodologia proposta consegue diferenciar bem as duas classes avaliadas. Também foi avaliado um cenário de classificação utilizando a concatenação desses sinais coletados. As acurácias médias, nesse novo cenário, ficaram acima de 98% para cada participante, indicando que, em uma aquisição multicanal, existe uma chance maior de discernir as duas classes avaliadas.

Um novo cenário de classificação foi realizado, dessa vez com aquisição multicanal, visando observar o desempenho do equipamento nessa condição. Foram utilizados duas fontes de emissão em conjunto com cinco fotodetectores. Nesse experimento realizou-se duas sessões de coletas, em dias diferentes e condições de iluminação distintas, com três novos voluntários. Primeiramente, foi analisado a classificação utilizando os sinais coletados apenas do primeiro dia. As métricas obtidas foram similares às do caso anterior, para os três participantes.

Com o objetivo de verificar a capacidade de generalização do modelo preditivo, foi implementado um cenário de classificação, onde o modelo SVM foi treinado com os sinais do primeiro dia de coleta, e a inferência feita com os sinais do segundo dia. Nesse cenário, as métricas de desempenho ficaram bem abaixo dos resultados obtidos nos casos anteriores, para os três voluntários. O motivo dessa queda acentuada de desempenho foi devida ao fato de que, em condições distintas de aquisição, ocorre uma grande variação nos sinais coletados de cada participante. E como o modelo não fora treinado com esses novos sinais, ele não é capaz de discernir as classes presentes com boa acurácia.

Os resultados obtidos com esses experimentos vão de encontro com os trabalhos da literatura levantada, validando o modelo de instrumentação proposto, com aquisições multicanal em alta resolução de quantização. Ressalta-se também que os cenários de classificação multicanal, de sinais coletados sob mesmas condições, apresentaram métricas ligeiramente superiores aos trabalhos levantados que abordam exclusivamente fNIRS para esse tipo de problema. Para o caso de aquisição com 10 canais – não encontrado na literatura levantada –, foi obtida uma acurácia média de 98%, superando o índice de 87% obtido em [7], onde também é utilizado um classificador SVM, porém com a aquisição dois canais apenas.

TRABALHOS FUTUROS

Uma próxima etapa de continuação desse trabalho é a tentativa de diferenciar, não apenas a presença ou não de movimentos, mas as intenções de movimento de um usuário, adentrando na temática de imagética motora. Para tal, é necessário realizar aquisições com um número maior de participantes, sob diversas condições de coleta, e com novo protocolo experimental.

Uma outra abordagem possível, e ainda pouco explorada, é utilizar a instrumentação construída para reconstruir imagens tridimensionais do córtex cerebral, por meio da técnica de tomografia por difusão ótica. Essas imagens tridimensionais poderiam ser utilizadas para classificar intenções de movimento, abrindo espaço também para o uso de diferentes modelos de aprendizagem de máquina.

LISTA DE REFERÊNCIAS

- [1] S. M. Alessio. *Digital signal processing and spectral analysis for scientists: concepts and applications*. Springer, 2015.
- [2] C. A. S. Anjos. Análise da aplicabilidade da técnica nirs ao estudo da atividade cerebral sob três condições distintas: estimulação visual, realização de exercícios físicos e apneia induzida em pacientes com estenose carotídea. 2014.
- [3] A. L. Bastos, G. G. L. Souza, et al. Simulação mental de movimentos. *Revista Neurociências*, 21(4):604–619, 2013.
- [4] D. Bäumer, K. Talbot, et al. Advances in motor neurone disease. *Journal of the Royal Society of Medicine*, 107(1):14–21, 2014.
- [5] BeagleBone. *BeagleBone System Reference Manual*. BeagleBone, 2013. Rev. C.
- [6] Y. Bengio e Y. Grandvalet. No unbiased estimator of the variance of k-fold cross-validation. *Journal of machine learning research*, 5(Sep):1089–1105, 2004.
- [7] M. R. Bhutta e K. Hong. Classification of fNIRS signals for deception decoding using LDA and SVM. In *Control, Automation and Systems (ICCAS), 2013 13th International Conference on*, páginas 1776–1780. IEEE, 2013.
- [8] N. Birbaumer. Breaking the silence: brain-computer interfaces (BCI) for communication and motor control. *Psychophysiology*, 43(6):517–532, 2006.
- [9] C. M. Bishop. *Pattern recognition and machine learning*. Springer, 2006.
- [10] E. Bor-Seng-Shu, W. S. Kita, et al. Cerebral hemodynamics: concepts of clinical importance. *Arquivos de neuro-psiquiatria*, 70(5):352–356, 2012.
- [11] B. E. Boser, I. M. Guyon, et al. A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory*, páginas 144–152. ACM, 1992.
- [12] A. P. Buccino, H. O. Keles, et al. Hybrid EEG-fNIRS asynchronous brain-computer interface for multiple motor tasks. *PloS one*, 11(1):e0146610, 2016.

- [13] S. C. Bunce, M. Izzetoglu, et al. Functional near-infrared spectroscopy. *IEEE engineering in medicine and biology magazine*, 25(4):54–62, 2006.
- [14] C. Canning e M. Scheutz. Functional near-infrared spectroscopy in human-robot interaction. *Journal of Human-Robot Interaction*, 2(3):62–84, 2013.
- [15] U. Chaudhary, B. Xia, et al. Brain-computer interface-based communication in the completely locked-in state. *PLoS biology*, 15(1):e1002593, 2017.
- [16] L. Cohens. The generalization of the wiener-khinchin theorem. In *Proceedings of the 1998 IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP'98 (Cat. No. 98CH36181)*, volume 3, páginas 1577–1580. IEEE, 1998.
- [17] C. Cortes e V. Vapnik. Support-vector networks. *Machine learning*, 20(3):273–297, 1995.
- [18] M. Cutler. Transillumination as an aid in the diagnosis of breast lesions. *Surgery, gynecology and obstetrics*, 48:721–729, 1929.
- [19] J. Decety. The neurophysiological basis of motor imagery. *Behavioural brain research*, 77(1-2):45–52, 1996.
- [20] D. T. Delpy, M. Cope, et al. Estimation of optical pathlength through tissue from direct time of flight measurement. *Physics in Medicine & Biology*, 33(12):1433, 1988.
- [21] P. S. R. Diniz, E. A. B. Da Silva, et al. *Digital signal processing: system analysis and design*. Cambridge University Press, 2010.
- [22] T. Fawcett. An introduction to roc analysis. *Pattern recognition letters*, 27(8):861–874, 2006.
- [23] M. Ferrari e V. Quaresima. A brief review on the history of human functional near-infrared spectroscopy (fNIRS) development and fields of application. *Neuroimage*, 63(2):921–935, 2012.
- [24] M. A. Franceschini, D. K. Joseph, et al. Diffuse optical imaging of the whole head. *Journal of biomedical optics*, 11(5):054007–054007, 2006.
- [25] J. Frey, C. Mühl, et al. Review of the use of electroencephalography as an evaluation method for human-computer interaction. *arXiv preprint arXiv:1311.2222*, 2013.
- [26] G. Gallegos-Ayala, A. Furdea, et al. Brain communication in a completely locked-in patient using bedside near-infrared spectroscopy. *Neurology*, 82(21):1930–1932, 2014.

- [27] L. George e A. Lecuyer. An overview of research on passive brain-computer interfaces for implicit human-computer interaction. In *International Conference on Applied Bionics and Biomechanics ICABB 2010-Workshop W1 Brain-Computer Interfacing and Virtual Reality*, 2010.
- [28] S. Golovynskyi, I. Golovynska, et al. Optical windows for head tissues in near-infrared and short-wave infrared regions: Approaching transcranial light applications. *Journal of biophotonics*, 11(12):e201800141, 2018.
- [29] A. C. Guyton e J. E. Hall. *Tratado de fisiologia médica*. Elsevier Brasil, 2006.
- [30] K. Hong, M J. Khan, et al. Feature extraction and classification methods for hybrid fnirs-eeG brain-computer interfaces. *Frontiers in human neuroscience*, 12, 2018.
- [31] K. Hong e H. Santosa. Decoding four different sound-categories in the auditory cortex using functional near-infrared spectroscopy. *Hearing research*, 333:157–166, 2016.
- [32] Y. Hoshi. Towards the next generation of near-infrared spectroscopy. *Phil. Trans. R. Soc. A*, 369(1955):4425–4439, 2011.
- [33] M. Hossin e M. N. Sulaiman. A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process*, 5(2):1, 2015.
- [34] X. Hu, K. Hong, et al. fNIRS-based online deception decoding. *Journal of Neural Engineering*, 9(2):026012, 2012.
- [35] T. J. Huppert, M. A. Franceschini, et al. Noninvasive imaging of cerebral activation with diffuse optical tomography. 2009.
- [36] H. Hwang, H. Choi, et al. Toward more intuitive brain–computer interfacing: classification of binary covert intentions using functional near-infrared spectroscopy. *Journal of biomedical optics*, 21(9):091303, 2016.
- [37] F. F. Jobsis. Noninvasive, infrared monitoring of cerebral and myocardial oxygen sufficiency and circulatory parameters. *Science*, 198(4323):1264–1267, 1977.
- [38] D. K. Joseph, T. J. Huppert, et al. Diffuse optical tomography system to image brain activation with improved spatial resolution and validation with functional magnetic resonance imaging. *Applied optics*, 45(31):8142–8151, 2006.
- [39] E. Kandel, J. Schwartz, et al. *Princípios de Neurociências-5*. AMGH Editora, 2014.

- [40] L. Kocsis, P. Herman, e others. The modified beer–lambert law revisited. *Physics in Medicine & Biology*, 51(5):N91, 2006.
- [41] R. Kohavi et al. A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Ijcai*, volume 14, páginas 1137–1145. Montreal, Canada, 1995.
- [42] C. Krebs, E. J. Akesson, et al. *Lippincott’s Illustrated Reviews: Neuroscience*. Wolters Kluwer/Lippincott Williams & Wilkins Health, 2012.
- [43] T. Li, F. Zhong, e others. A brief review of opt101 sensor application in near-infrared spectroscopy instrumentation for intensive care unit clinics. *Sensors*, 17(8):1701, 2017.
- [44] A. Lima e J. Bakker. Espectroscopia no infravermelho próximo para a monitorização da perfusão tecidual. *Rev Bras Ter Intensiva*, 23(3):341–51, 2011.
- [45] F. Lotte, M. Congedo, et al. A review of classification algorithms for EEG-based brain–computer interfaces. *Journal of neural engineering*, 4(2):R1, 2007.
- [46] M. Lotze e U. Halsband. Motor imagery. *Journal of Physiology-paris*, 99(4-6):386–395, 2006.
- [47] E. N. Marieb e K. Hoehn. *Anatomia e fisiologia*. Artmed Editora, 2014.
- [48] E. B. Merrick e T. J. Hayes. Continuous, non-invasive measurements of arterial blood oxygen levels. *Hewlett-packard J*, 28(2):2–9, 1976.
- [49] Microchip. *1 MHz, Low-Power Op Amp*. Microchip, 2009. Rev. 1.
- [50] Microchip. *MCP6S28 Single-Ended, Rail-to-Rail I/O, Low Gain PGA*. Microchip, 2012. Rev. 1.
- [51] T. M. Mitchell. *Machine learning*. McGraw hill, 1997.
- [52] N. Naseer e K. Hong. Decoding answers to four-choice questions using functional near infrared spectroscopy. *Journal of Near Infrared Spectroscopy*, 23(1):23–31, 2015.
- [53] N. Naseer e K. Hong. fnirs-based brain-computer interfaces: a review. 9:3, 2015.
- [54] L. F. Nicolas-Alonso e J. Gomez-Gil. Brain computer interfaces, a review. *Sensors*, 12(2):1211–1279, 2012.
- [55] S. Nioka, M. Shnall, et al. Breast cancer detection of large size to dcis by hypoxia and angiogenesis using nirs. In *Oxygen Transport to Tissue XXXV*, páginas 211–219. Springer, 2013.

- [56] J. Nolte. *The Human Brain E-Book: An Introduction to its Functional Anatomy With STUDENT CONSULT Online Access*. Elsevier Health Sciences, 2008.
- [57] R. A. Ramadan, S. Refat, et al. Basics of brain computer interface. In *Brain-Computer Interfaces*, páginas 31–50. Springer, 2015.
- [58] N. Robinson, A. D. Zaidi, et al. Real-time subject-independent pattern classification of overt and covert movements from fnirs signals. *PloS one*, 11(7):e0159959, 2016.
- [59] E. A. B. Santos. Sistema de espectroscopia funcional em infravermelho próximo (fnirs) para aplicação em interface cérebro-computador (bci). 2019.
- [60] R. Schaumann, H. Xiao, et al. *Design of Analog Filters 2nd Edition*. Oxford University Press, Inc., 2009.
- [61] L. Scherer, K. Kahlaoui, et al. Espectrografia funcional de infravermelho próximo (fnirs): a técnica e sua aplicação em estudos da linguagem pp. 57-62. *Neuropsicologia Latinoamericana*, 1(1), 2009.
- [62] F. Scholkmann, S. Kleiser, et al. A review on continuous wave functional near-infrared spectroscopy and imaging instrumentation and methodology. *Neuroimage*, 85:6–27, 2014.
- [63] J. W. Severinghaus. Takuo aoyagi: discovery of pulse oximetry. *Anesthesia & Analgesia*, 105(6):S1–S4, 2007.
- [64] J. W. Severinghaus e P. B. Astrup. History of blood gas analysis. vi. oximetry. *Journal of clinical monitoring*, 2(4):270–288, 1986.
- [65] D. A. Skoog, F. J. Holler, et al. *Principles of instrumental analysis*. Cengage learning, 2017.
- [66] A. M. Smith, M. C. Mancini, et al. Bioimaging: second window for in vivo imaging. *Nature nanotechnology*, 4(11):710, 2009.
- [67] M. Stangl, G. Bauernfeind, et al. A haemodynamic brain–computer interface based on real-time classification of near infrared spectroscopy signals during motor imagery and mental arithmetic. *Journal of near infrared spectroscopy*, 21(3):157–171, 2013.
- [68] L. Stankovic, M. Dakovic, et al. *Time-frequency signal analysis with applications*. Artech house, 2014.
- [69] M. V. Stecklow, A. F. Infantosi, et al. Alterações na banda alfa do eletrencefalograma durante imagética motora visual e cinestésica. *Arq Neuropsiquiatr*, 65(4-A):1084–8, 2007.

- [70] I. Steinwart e A. Christmann. *Support vector machines*. Springer Science & Business Media, 2008.
- [71] M. Strait e M. Scheutz. What we can and cannot (yet) do with functional near infrared spectroscopy. *Frontiers in neuroscience*, 8, 2014.
- [72] G. Strangman, D. A. Boas, et al. Non-invasive neuroimaging using near-infrared light. *Biological psychiatry*, 52(7):679–693, 2002.
- [73] J. Taelman, J. Vanderhaegen, et al. Estimation of muscle fatigue using surface electromyography and near-infrared spectroscopy. In *Oxygen Transport to Tissue XXXII*, páginas 353–359. Springer, 2011.
- [74] TI. *ADS1256 Very Low Noise, 24-Bit Analog-to-Digital Converter*. Texas Instruments, September 2013. Rev. B.
- [75] TI. *OPT101 Monolithic Photodiode and Single-Supply Transimpedance Amplifier*. Texas Instruments, June 2015. Rev. B.
- [76] M. J. Vansteensel, E. Pels, et al. Fully implanted brain–computer interface in a locked-in patient with ALS. *N Engl J Med*, 2016(375):2060–2066, 2016.
- [77] V. N. Vapnik. *The nature of statistical learning theory*. Springer science & business media, 2013.
- [78] A. von Luhmann. Design and evaluation of a system for mobile brain activity measurements using functional near-infrared spectroscopy. *Inst. Biomed. Eng. Karlsruhe Inst. Technol.*, 2014.
- [79] A. von Lühmann, C. Herff, et al. Toward a wireless open source instrument: functional near-infrared spectroscopy in mobile neuroergonomics and bci applications. *Frontiers in human neuroscience*, 9:617, 2015.
- [80] S. Weyand, K. Takehara-Nishiuchi, et al. Exploring methodological frameworks for a mental task-based near-infrared spectroscopy brain–computer interface. *Journal of neuroscience methods*, 254:36–45, 2015.
- [81] A. Zafar e K. Hong. Detection and classification of three-class initial dips from prefrontal cortex. *Biomedical optics express*, 8(1):367–383, 2017.
- [82] Z. Zhou. *Ensemble methods: foundations and algorithms*. CRC press, 2012.

A LEIAUTES

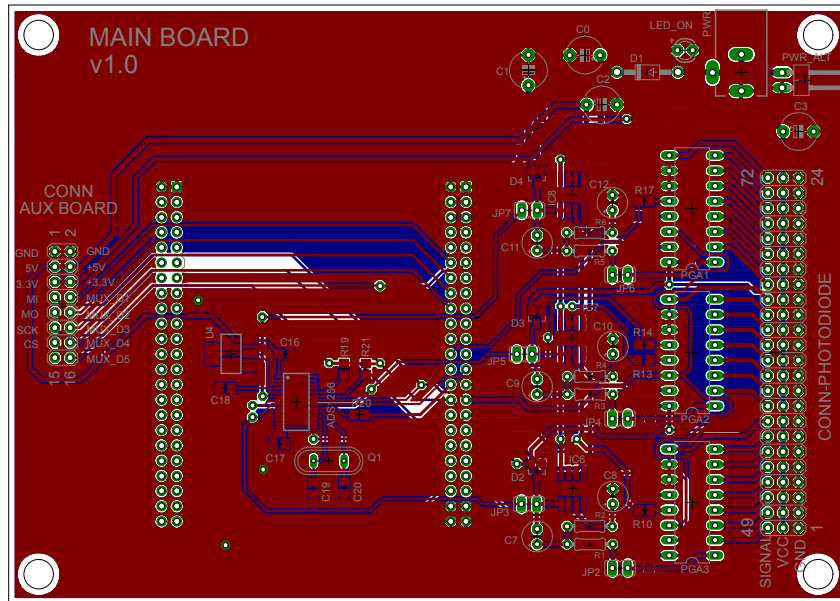


Figura A.1. Placa Principal




Figura A.2. Placa Chaveamento LEDs


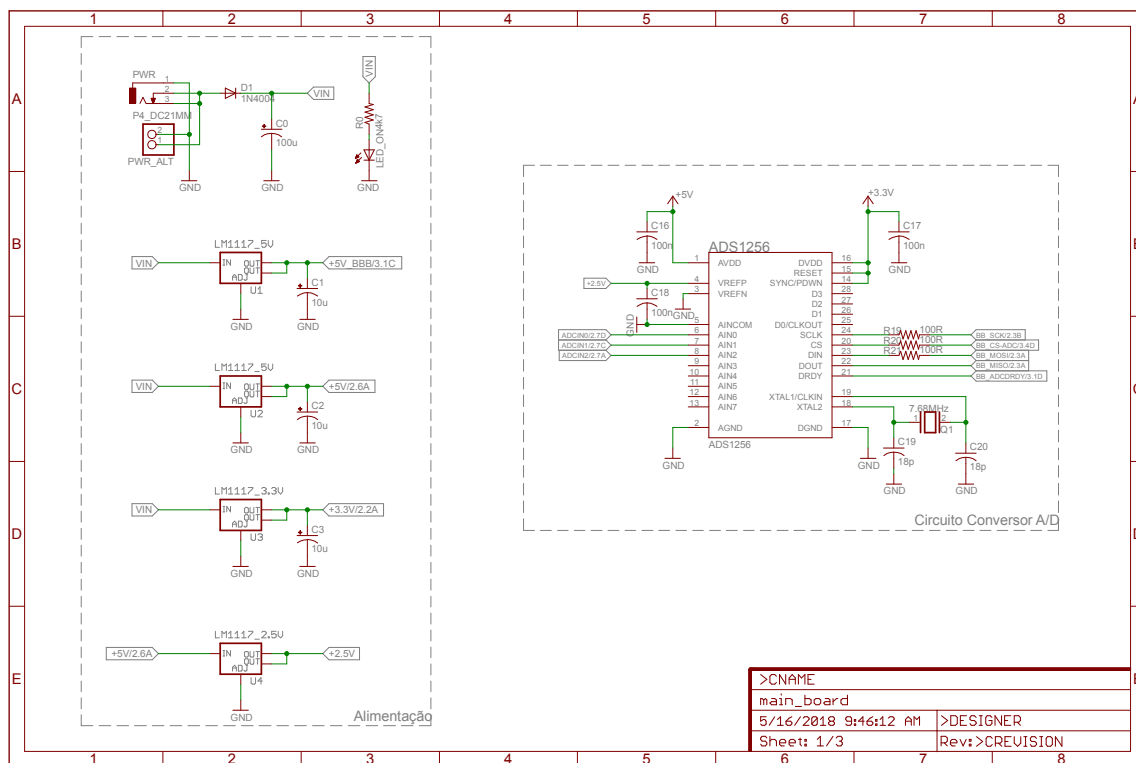
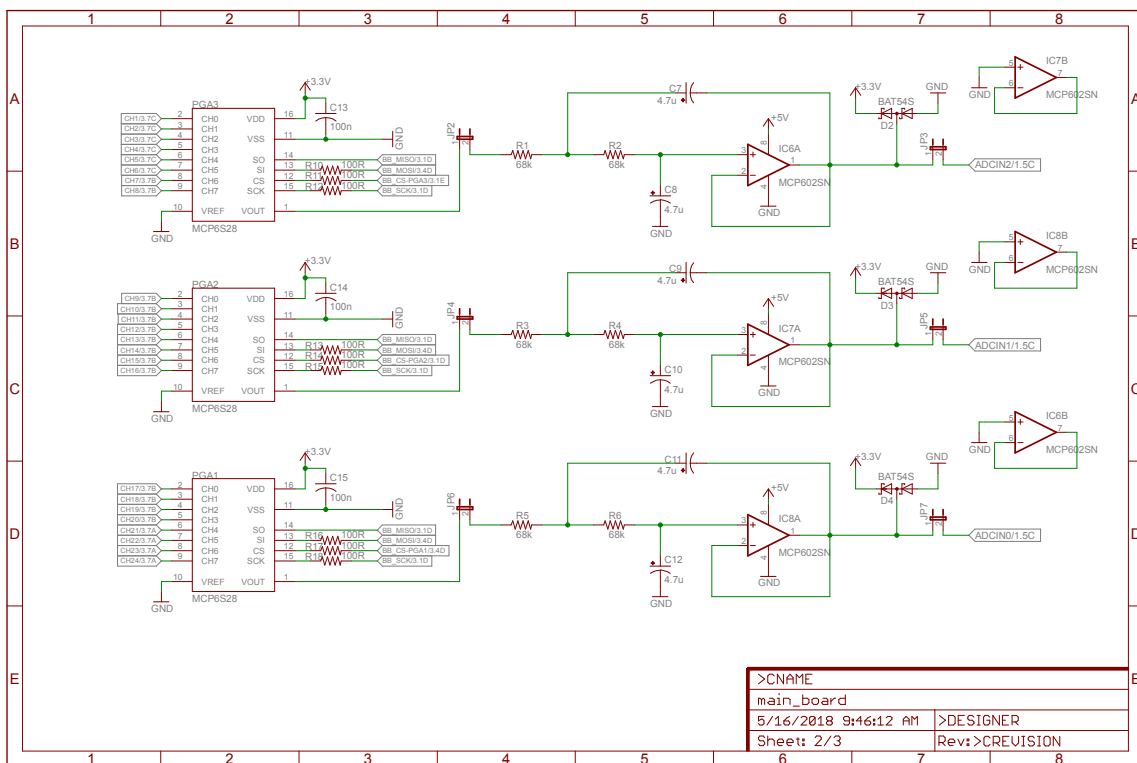
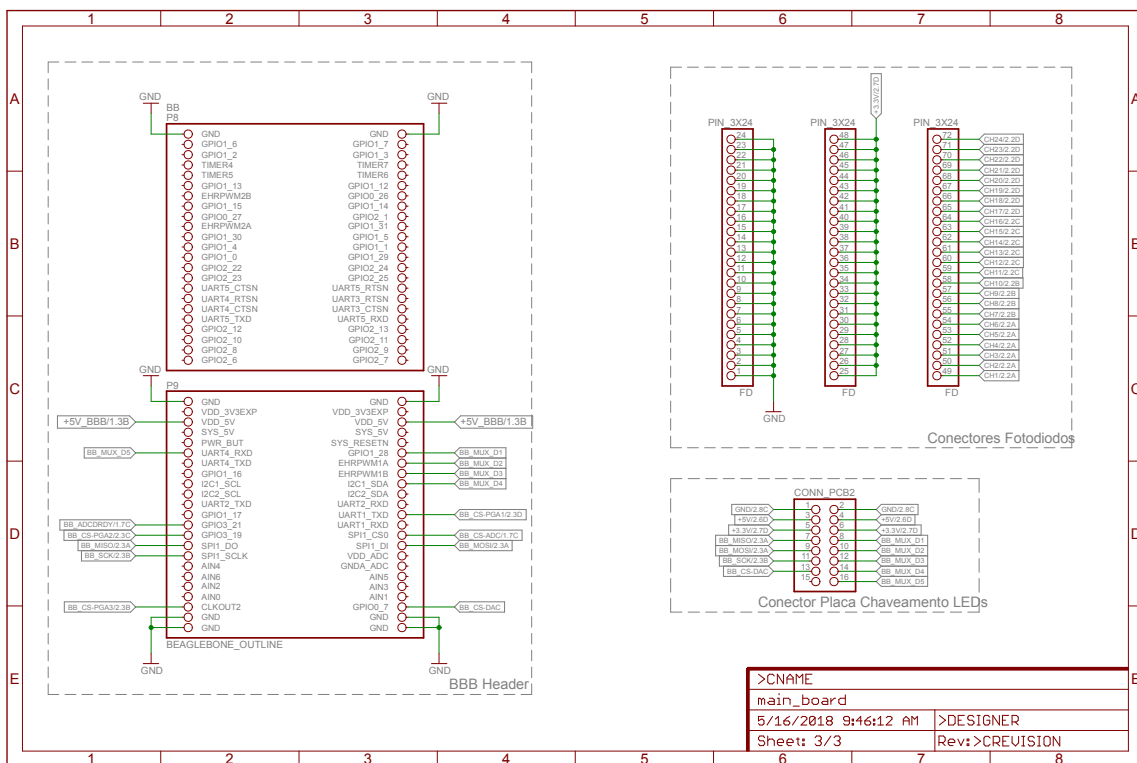


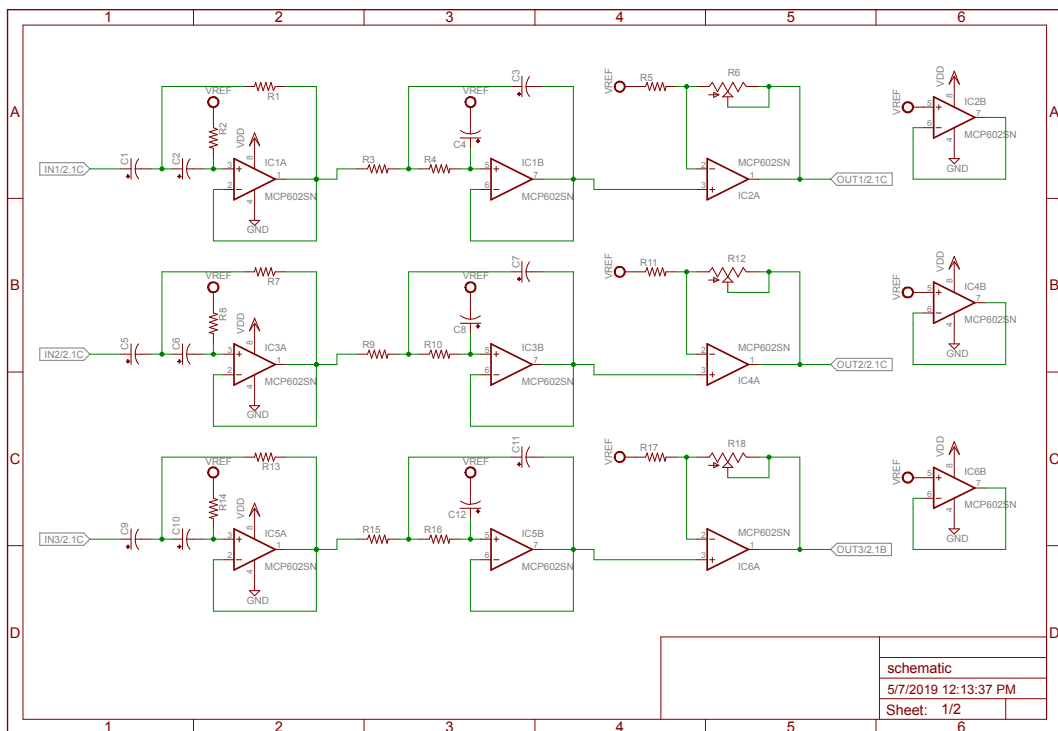
Figura A.3. Placa Sensores

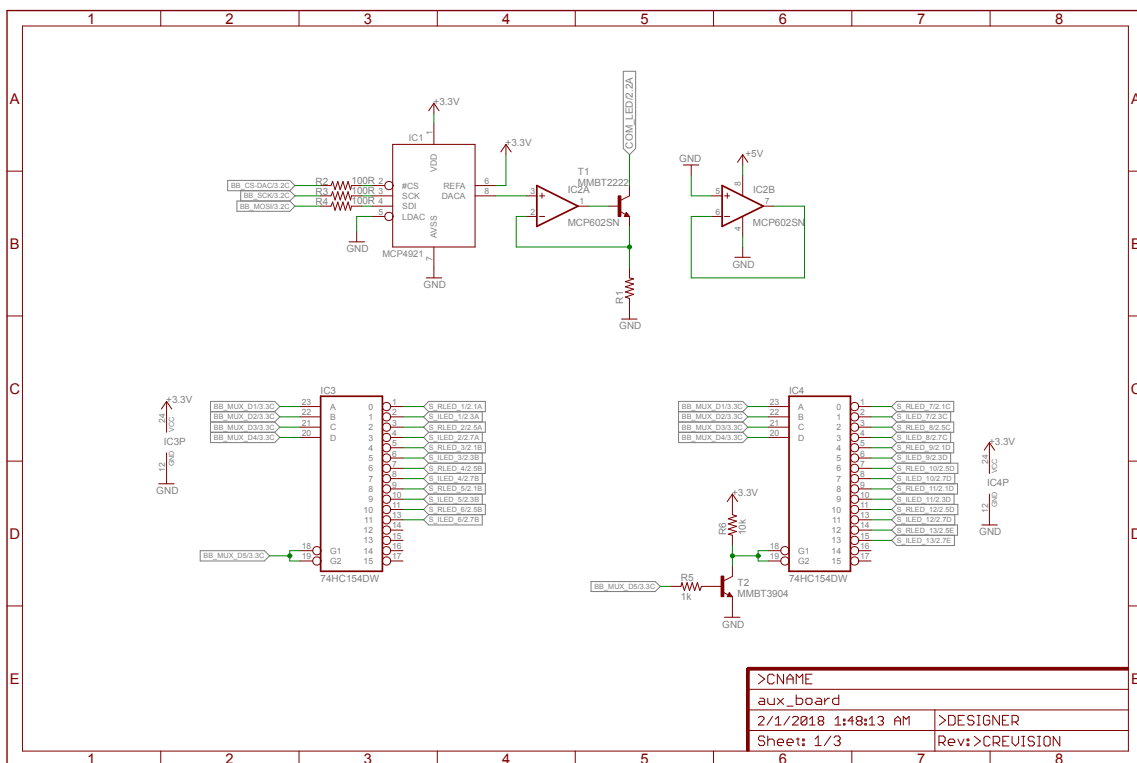
B ESQUEMÁTICOS











>CNAME	
aux_board	
2/1/2018 1:48:13 AM	>DESIGNER
Sheet: 1/3	Rev:>CREVISION

