



Universidade de Brasília
Faculdade de Tecnologia

**Desenvolvimento e Avaliação de um Sistema de
Aquisição de Sinais de Pletismografia Remota, com
Estimação sem Contato de Frequência Cardíaca e
Respiratória**

Gabriel da Conceição Miranda
Gustavo Policena Vitena

PROJETO FINAL DE CURSO
ENGENHARIA DE CONTROLE E AUTOMAÇÃO

Brasília
2025

Universidade de Brasília
Faculdade de Tecnologia

**Desenvolvimento e Avaliação de um Sistema de
Aquisição de Sinais de Pletismografia Remota, com
Estimação sem Contato de Frequência Cardíaca e
Respiratória**

Gabriel da Conceição Miranda
Gustavo Policena Vitena

Projeto Final de Curso submetido como requisito parcial para obtenção do grau de Engenheiro de Controle e Automação.

Orientador: Prof. Dr. Adson Ferreira da Rocha
Coorientador: Prof. Dr. Fernando Merege

Brasília
2025

FICHA CATALOGRÁFICA

Conceição Miranda, Gabriel da.

Desenvolvimento e Avaliação de um Sistema de Aquisição de Sinais de Pletismografia Remota, com Estimção sem Contato de Frequência Cardíaca e Respiratória / Gabriel da Conceição Miranda; Gustavo Policena Vitena; orientador Adson Ferreira da Rocha; coorientador Fernando Merege. -- Brasília, 2025.

151 p.

Projeto Final de Curso (Engenharia de Controle e Automação) -- Universidade de Brasília, 2025.

1. rPPG. 2. Frequência cardíaca. 3. Frequência respiratória. 4. Não invasivo. 5. Visão Computacional. I. Policena Vitena, Gustavo. II. Ferreira da Rocha, Adson, orient. III. Merege, Fernando, coorient. IV. Título.

**Universidade de Brasília
Faculdade de Tecnologia**

Desenvolvimento e Avaliação de um Sistema de Aquisição de Sinais de Pletismografia Remota, com Estimação sem Contato de Frequência Cardíaca e Respiratória

Gabriel da Conceição Miranda
Gustavo Policena Vitena

Projeto Final de Curso submetido como requisito parcial para obtenção do grau de Engenheiro de Controle e Automação.

Trabalho aprovado. Brasília, 20 de fevereiro de 2025:

Prof. Dr. Adson Ferreira da Rocha,
UnB/FT/ENE
Orientador

Prof. Dr. Marcelo Lopes Pereira Júnior,
UnB/FT/ENE
Examinador externo

Prof. Dr. Walter de Britto Vidal Filho,
UnB/FT/ENM
Examinador externo

Prof. Dr. Cristiano Jacques Miosso,
UnB/FCTE/FGA
Examinador interno

*Este trabalho é dedicado às crianças adultas que,
quando pequenas, sonharam em se tornar cientistas.*

Gabriel da Conceição Miranda

*Dedico este trabalho àqueles que, como Sócrates, acreditam que a verdadeira sabedoria está
em reconhecer a própria ignorância e nunca cessar na busca pelo conhecimento. Que este
trabalho seja um pequeno passo nessa contínua jornada de aprendizado.*

Gustavo Policena Vitena

Agradecimentos

Primeiramente, agradeço a Deus, pois sem Sua graça, força e sabedoria, nada disso seria possível. É Ele que guia meus passos e me dá forças para superar todos os desafios.

Agradeço, também, à minha família, que sempre esteve ao meu lado, me apoiando incondicionalmente em todos os momentos. Em especial, agradeço à minha irmã, cuja presença foi fundamental durante essa jornada.

Meus amigos, que me acompanharam e me deram forças nos momentos difíceis, também merecem um agradecimento especial. A amizade e o apoio de vocês foram essenciais para a realização deste trabalho.

A todos, meu mais sincero e profundo agradecimento.

Gabriel da Conceição Miranda

Primeiramente, agradeço a Deus, por me abençoar com as oportunidades e me guiar em cada passo dessa jornada. Sua graça e sabedoria foram fundamentais para enfrentar os desafios e alcançar este momento tão importante.

Agradeço também à minha família, que esteve ao meu lado em todos os momentos, oferecendo amor, apoio e compreensão. Cada palavra de incentivo e cada gesto de carinho fizeram toda a diferença. Em especial, agradeço à minha namorada, que sempre esteve comigo, acreditando em mim e me incentivando a seguir em frente.

Por fim, gostaria de expressar minha gratidão aos meus amigos, que compartilharam essa caminhada comigo. Sua amizade, apoio e presença constante foram essenciais para tornar essa jornada mais leve e cheia de bons momentos. A todos vocês, meu mais sincero e profundo agradecimento.

Gustavo Policena Vitena

*“If you find that you’re spending almost all your time on theory,
start turning some attention to practical things;
it will improve your theories.
If you find that you’re spending almost all your time on practice,
start turning some attention to theoretical things;
it will improve your practice.”
(Donald Knuth)*

Resumo

A fotopletismografia remota (rPPG) tem se destacado como uma técnica promissora para a medição não invasiva de sinais fisiológicos, com potencial de aplicação em diversas áreas, incluindo saúde e segurança pública. No entanto, sua implementação ainda enfrenta desafios relacionados a interferências externas, como variações de iluminação e movimentos involuntários. Diante disso, este trabalho tem como objetivo o desenvolvimento de um protótipo de rPPG de baixo custo e portátil, capaz de capturar sinais fisiológicos com maior confiabilidade, além de propor um método de estimação eficiente e acessível. O sistema foi projetado para ser uma alternativa a soluções comerciais de hardware e software fechados, oferecendo maior transparência e flexibilidade para pesquisas futuras e aplicações práticas.

Para atingir esse objetivo, foram analisados dez algoritmos de conversão de sinais RGB em sinais de rPPG, avaliando seu desempenho em 27 regiões faciais distintas. O estudo buscou identificar quais combinações entre regiões faciais e algoritmos produziam os melhores resultados em diferentes condições experimentais. Os testes demonstraram que o desempenho ideal varia conforme o experimento, o que motivou o desenvolvimento de um indicador de qualidade capaz de prever quais combinações seriam menos ruidosas e proporcionariam aferições mais precisas. Esse indicador mostrou-se eficaz na seleção de amostras de sinal com menor interferência. Os experimentos foram conduzidos sob condições controladas de iluminação e ruído de movimento, evidenciando a necessidade de aprimoramento do dispositivo para aplicações em ambientes mais adversos.

Os resultados obtidos demonstram que a abordagem proposta é viável e que o uso do indicador de qualidade pode contribuir para melhorar a precisão da rPPG em diferentes cenários. Além disso, a construção de um protótipo portátil e acessível possibilita novas investigações e aplicações práticas, especialmente em situações que demandam monitoramento rápido e não invasivo. Como perspectiva futura, sugere-se o aprimoramento do hardware e a adaptação do sistema para ambientes com maior variabilidade luminosa e de movimento, ampliando sua aplicabilidade no monitoramento fisiológico remoto.

Palavras-chave: rPPG. Frequência cardíaca. Frequência respiratória. Não invasivo. Visão Computacional.

Abstract

Remote photoplethysmography (rPPG) has emerged as a promising technique for non-invasive physiological signal measurement, with potential applications in various fields, including healthcare and public safety. However, its implementation still faces challenges related to external interferences, such as variations in lighting and involuntary movements. In this context, this work aims to develop a low-cost, portable rPPG prototype capable of capturing physiological signals with greater reliability, as well as proposing an efficient and accessible estimation method. The system was designed as an alternative to commercial hardware and software solutions, which are often closed-source, offering greater transparency and flexibility for future research and practical applications.

To achieve this goal, ten algorithms for converting RGB signals into rPPG signals were analyzed, evaluating their performance across 27 distinct facial regions. The study aimed to identify the best combinations of facial regions and algorithms for different experimental conditions. The tests showed that the optimal performance varied depending on the experiment, which led to the development of a quality indicator capable of predicting which combinations would be less noisy and provide more accurate measurements. This indicator proved to be effective in selecting signal samples with lower interference. The experiments were conducted under controlled lighting and motion noise conditions, highlighting the need for further improvements to the device for applications in more challenging environments.

The results demonstrate that the proposed approach is viable and that the use of the quality indicator can help improve rPPG accuracy in different scenarios. Furthermore, the development of a portable and accessible prototype enables new investigations and practical applications, especially in situations requiring fast and non-invasive monitoring. As a future perspective, it is suggested that the hardware be enhanced and the system adapted for environments with greater lighting and movement variability, expanding its applicability in remote physiological monitoring.

Keywords: rPPG. Heart rate. Respiratory rate. Non-invasive. Computer Vision.

Lista de figuras

Figura 1.1	Mortes no trânsito relacionadas a drogas em todo o mundo.	19
Figura 1.2	Maneiras como diversas drogas afetam o funcionamento do cérebro. . .	19
Figura 2.1	Modos de operação da fotopletismografia com contato.	25
Figura 2.2	Princípio físico da obtenção do sinal PPG de maneira remota.	26
Figura 2.3	Profundidade máxima aproximada de penetração para comprimentos no espectro da luz visível e em sua vizinhança.	27
Figura 2.4	Coefficientes de absorção de luz dos compostos biológicos presentes nas pele.	28
Figura 2.5	Anatomia do coração humano.	31
Figura 2.6	Forma de uma onda PPG típica e sua relação com as fases do ciclo cardíaco e elementos do corpo humano.	33
Figura 2.7	Variações da forma da onda PPG, do tempo de propagação de pulso e da rigidez arterial de acordo com a idade.	35
Figura 2.8	Variações induzidas pela respiração no sinal PPG.	37
Figura 2.9	Absorvância da bilirrubina e de diversos tipos de hemoglobina na região da luz visível.	39
Figura 2.10	Diferenciação entre as interferências causadas por movimentos rígidos e não rígidos na fotopletismografia remota.	46
Figura 2.11	Pipeline de funcionamento do modelo de detecção e rastreamento facial MediaPipe.	48
Figura 2.12	A estrutura Mask R-CNN para segmentação de instância.	49
Figura 2.13	Fluxograma do método proposto.	52
Figura 2.14	Processo de obtenção de estimativas de frequência cardíaca utilizando o pipeline do framework pyVHR.	53
Figura 3.1	Disposição dos elementos de hardware no dispositivo Raspberry Pi 4. . .	58
Figura 3.2	Arquitetura do sistema de captura de quadros do hardware utilizado no desenvolvimento do dispositivo.	60
Figura 3.3	Mapeamento completo de pontos de referência faciais do recurso MediaPipe Face Mesh.	64
Figura 3.4	Processo de extração dos sinais a partir dos quadros capturados pela câmera.	67
Figura 3.5	Primeiro dispositivo de teste desenvolvido, versão desktop.	70
Figura 3.6	Segundo dispositivo de teste desenvolvido, versão portátil.	71
Figura 3.7	Erros encontrados durante testes com a bateria externa.	72
Figura 3.8	Primeira interface gráfica desenvolvida.	73
Figura 3.9	Janela principal da interface gráfica.	74

Figura 3.10	Janela de foco da interface gráfica.	76
Figura 3.11	Janela de configurações da interface gráfica.	77
Figura 3.12	Janela de configurações avançadas da interface gráfica.	78
Figura 3.13	Janela de resultados da interface gráfica.	80
Figura 3.14	Comparação entre ao espectro de frequência da curva PPG de referência, do banco de dados UBFC-Phys e aferida em contato com a pele, e a curva PPG extraída dos vídeos pelo algoritmo desenvolvido - vídeo 12 parte 3.	82
Figura 3.15	Comparação entre ao espectro de frequência da curva PPG de referência, do banco de dados UBFC-Phys e aferida em contato com a pele, e a curva PPG extraída dos vídeos pelo algoritmo desenvolvido - vídeo 12 parte 4.	83
Figura 3.16	Comparação entre ao espectro de frequência da curva PPG de referência, do banco de dados UBFC-Phys e aferida em contato com a pele, e a curva PPG extraída dos vídeos pelo algoritmo desenvolvido - vídeo 2 parte 2. .	84
Figura 3.17	Comparação entre ao espectro de frequência da curva PPG de referência, do banco de dados UBFC-Phys e aferida em contato com a pele, e a curva PPG extraída dos vídeos pelo algoritmo desenvolvido - vídeo 2 parte 2. .	85
Figura 3.18	Comparação entre os valores de frequência cardíaca estimados a partir do sinal PPG de referência e do sinal de fotopletimografia remota obtido por meio dos algoritmos desenvolvidos. Cada cor representa um vídeo diferente e cada ponto representa uma estimativa feita em uma determinado intervalo de tempo dentro do vídeo.	86
Figura 3.19	Sinal bruto PPG de baixa qualidade extraído um dos vídeos gravados pelo notebook.	86
Figura 3.20	Sinal bruto PPG de alta qualidade extraído um dos vídeos gravados pelo notebook.	87
Figura 3.21	Espectro de frequência de um sinal de PPG de baixa qualidade extraído um dos vídeos gravados pelo notebook. A amplitude no gráfico é o valor do módulo das amplitudes resultantes da FFT.	88
Figura 3.22	Espectro de frequência de um sinal de PPG de alta qualidade extraído um dos vídeos gravados pelo notebook. A amplitude no gráfico é o valor do módulo das amplitudes resultantes da FFT.	88
Figura 3.23	Espectro de frequência de um sinal de PPG de alta qualidade obtido por meio da primeira versão do protótipo.	90
Figura 3.24	Espectro de frequência de um sinal de PPG de baixa qualidade obtido por meio da primeira versão do protótipo.	91
Figura 3.25	Análise da amostragem, visualização da curva PPG bruta e seu respectivo espectro de frequência durante a realização dos testes.	94
Figura 3.26	Localização dos pinos do Módulo ECG AD8232.	95
Figura 3.27	Interface do módulo de ECG AD8232 com o Arduino.	96

Figura 3.28	Módulo MPS20N0040D utilizado para a aferição da pressão no cateter nasal.	97
Figura 3.29	Módulo MPS20N0040D ligação com o arduino.	97
Figura 3.30	Gráficos com a queda da mudança de iluminação.	99
Figura 3.31	Ambiente de realização dos testes.	100
Figura 4.1	Erro médio absoluto da frequência cardíaca em função de cada patch para o vídeo 6 do Grupo 2.	104
Figura 4.2	Erro absoluto médio da frequência cardíaca em função de cada patch para os Grupos 3, 4, 5 e 6.	108
Figura 4.3	Erro absoluto médio da frequência respiratória em função de cada patch para os Grupos 3, 4, 5 e 6.	109
Figura 4.4	Distribuição do erro absoluto da frequência respiratória das amostras do Indicador SQI1 e SQI2.	115
Figura 4.5	Distribuição do erro absoluto das amostras de acordo com o indicador SQI1 para vídeos do grupo 3.	116
Figura 4.6	Distribuição do erro absoluto das amostras de acordo com o indicador SQI2 para vídeos do grupo 3.	117
Figura 4.7	Distribuição do erro absoluto das amostras de acordo com o indicador SQI3 para vídeos do grupo 3.	118
Figura 4.8	Distribuição do erro absoluto das amostras de acordo com o indicador SQI4 para vídeos do grupo 4.	119
Figura 4.9	Variação do erro absoluto médio para todos os vídeos dos grupos 3, 4, 5 e 6 utilizando o SQI1 como limiar. O número em cada ponto indica a quantidade de amostras consideradas a partir do seu respectivo limiar. .	120
Figura 4.10	Variação do erro absoluto médio para todos os vídeos dos grupos 3, 4, 5 e 6 utilizando o SQI2 como limiar. O número em cada ponto indica a quantidade de amostras consideradas a partir do seu respectivo limiar. .	121
Figura 4.11	Variação do erro absoluto médio para todos os vídeos dos grupos 3, 4, 5 e 6 utilizando o SQI3 como limiar. O número em cada ponto indica a quantidade de amostras consideradas a partir do seu respectivo limiar. .	122
Figura 4.12	Variação do erro absoluto médio para todos os vídeos dos grupos 3, 4, 5 e 6 utilizando o SQI4 como limiar. O número em cada ponto indica a quantidade de amostras consideradas a partir do seu respectivo limiar. .	123
Figura 4.13	Variação do erro médio da frequência cardíaca, sem considerar amostras repetidas para um mesmo vídeo, de acordo com o limiar SQI1.	124
Figura 4.14	Comparação da sincronia entre a curva ECG e as curvas PPG obtidas por diferentes patches.	126
Figura 4.15	Comparação da sincronia entre a curva ECG e as curvas PPG obtidas por diferentes métodos utilizando o mesmo patch.	127

Figura 4.16 Sobreposição das curvas ECG e PPG para análise detalhada da sincronia.

A curva PPG foi obtida utilizando o patch 10 e o método GREEN. . . . 127

Lista de tabelas

Tabela 1.1	Alterações fisiológicas ocasionadas por sete categorias de drogas.	20
Tabela 4.1	Divisão por grupos dos testes realizados.	101
Tabela 4.2	Erro absoluto médio, para a frequência cardíaca, do método SSR para cada vídeo do Grupo 2.	103
Tabela 4.3	Erro absoluto médio para diferentes métodos no vídeo 6 do Grupo 2. . .	104
Tabela 4.4	Erros absolutos médios da frequência cardíaca para as 3 melhores regiões faciais de cada grupo analisado.	110
Tabela 4.5	Erros absolutos médios da frequência respiratória para as 3 melhores regiões faciais de cada grupo analisado.	110
Tabela 4.6	Amostras com o menor erro absoluto da frequência cardíaca para 5 vídeos de cada grupo.	111
Tabela 4.7	Amostras com o menor erro absoluto da frequência respiratória para 5 vídeos de cada grupo.	112
Tabela 4.8	Erro absoluto da frequência cardíaca das melhores combinações de patch e método.	113
Tabela 4.9	Erros absolutos médios e seus desvios padrão para diferentes limiares de SQI1 para os vídeos do grupo 3.	120
Tabela 4.10	Erros absolutos médios e seus desvios padrão para diferentes limiares de SQI1 para os vídeos do grupo 4.	121
Tabela A.1	Resultados dos testes no primeiro protótipo para cada combinação de parâmetros.	150
Tabela A.2	Melhores combinações de Patch e Método para os 51 vídeos dos grupos 3, 4, 5 e 6	151

Lista de abreviaturas e siglas

AC	Alternating Current
API	Application Programming Interface
AV	Atrioventriculares
BSS	Blind Separation of Sources
BVP	Blood Volume Pulse
CCD	Charge-Coupled Device
CHROM	Chrominance Model
COHb	Carboxihemoglobina
COMPAS	Perfil de Gerenciamento Corretivo de Infratores para Sanções Alternativas
CTB	Código de Trânsito Brasileiro
DC	Direct Current
ECG	Eletrocardiograma
EVM	Eulerian Video Magnification
FC	Frequência Cardíaca
FFT	Fast Fourier Transform
FPS	Frames Per Second
FR	Frequência Respiratória
GPU	Graphics Processing Unit
Hb	Hemoglobina Desoxigenada
HbO ₂	Hemoglobina Oxigenada
HRV	Heart Rate Variability
ICA	Independent Component Analysis
IMC	Índice de Massa Corporal
IR	Infrared
JBSS	Joint Blind Source Separation
LE	Laplacian Eigenmap
LEDs	Light-Emitting Diode
LGI	Local Group Invariance
MetHb	Metaemoglobina
mmHg	Milímetro de Mercúrio
MPFM	Mediapipe Face Mesh
MTCNN	Multi-Task Cascaded Convolutional Neural Networks
NIR	Near-infrared
nm	Nanômetro
PCA	Principal Component Analysis

PDs	Photodetector
POS	Plane Orthogonal to the Skin
PPG	Photoplethysmography
R-CNN	Regions with Convolutional Neural Networks
RAM	Random Access Memory
RGB	Red, Green and Blue
RIAV	Respiratory-Induced Amplitude Variation
RIFV	Respiratory-Induced Frequency Variation
RIIV	Respiratory-Induced Intensity Variation
ROI	Region Of Interest
RPN	Region Proposal Network
rPPG	Remote Photoplethysmography
SNA	Sistema Nervoso Autônomo
SNR	Signal-to-Noise Ratio
SpO	Saturação de Oxigênio do Sangue
SSA	Singular Spectrum Analysis
SSR	Subspace Rotation
UTIs	Unidades de Terapia Intensiva
VFC	Variabilidade da Frequência Cardíaca
YOLO	You Only Look Once

Sumário

1	Introdução	18
1.1	Contexto do Trabalho	18
1.2	Frequência Cardíaca	21
1.3	Frequência Respiratória	22
1.4	Objetivos	22
1.5	Estrutura do Texto	23
2	Fundamentação Teórica	24
2.1	Fotopletismografia Tradicional e Remota	24
2.1.1	Princípio de Funcionamento	24
2.1.2	Medição da Frequência Cardíaca	30
2.1.3	Medição da Frequência Respiratória	36
2.1.4	Outras Aplicações da Fotopletismografia	38
2.1.5	Vantagens da Fotopletismografia Remota	39
2.1.6	Desafios da Fotopletismografia Remota	40
2.2	Visão Computacional	47
2.2.1	Detecção e Rastreamento Facial	49
2.3	Região de Interesse	50
2.4	Implementações de Fotopletismografia Remota	51
3	Desenvolvimento	58
3.1	Seleção do Hardware e Software	58
3.1.1	Hardware	58
3.1.2	Software	61
3.2	Montagem e Implementação do Protótipo	69
3.2.1	Primeiro Protótipo	69
3.2.2	Segundo Protótipo	70
3.3	Interface gráfica	73
3.3.1	Janela Principal	74
3.3.2	Janela de Foco	75
3.3.3	Janela de Configuração	76
3.3.4	Janela de Configurações Avançadas	77
3.3.5	Janela de Resultados	79
3.4	Testes e Avaliação Inicial	81
3.4.1	Teste no banco de dados UBFC-Phys	81
3.4.2	Teste no notebook de desenvolvimento	85
3.4.3	Teste no dispositivo desktop	88

3.4.4	Teste da taxa de amostragem	92
3.5	Preparação para o Teste de Acurácia	94
4	Resultados	101
4.1	Visão geral	101
4.2	Grupos 1 e 2	102
4.3	Grupos 3, 4, 5 e 6	106
4.4	Sincronia ECG-PPG	123
5	Conclusão	128
5.1	Ilação do trabalho	128
5.2	Perspectivas futuras	130
5.2.1	Hardware	130
5.2.2	Software	132
	Referências	133
	Apêndices	148
	Apêndice A Tabelas grandes	149

1 Introdução

1.1 Contexto do Trabalho

Este trabalho de graduação contribui com um projeto multidisciplinar que visa possibilitar uma alternativa objetiva para as abordagens policiais no que se refere à avaliação da capacidade psicomotora em condutores de veículos automotivos (Merege *et al.*, 2024).

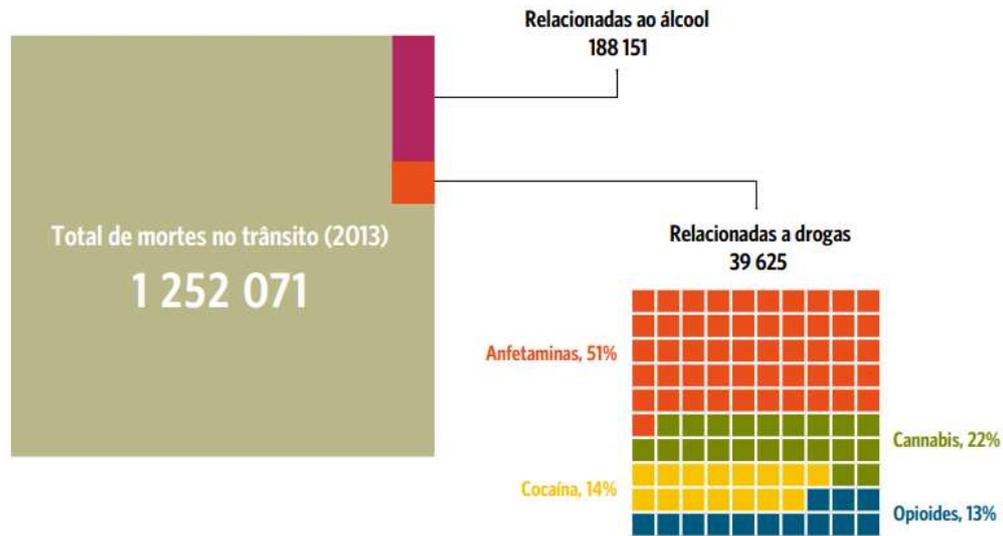
A problemática do uso de substâncias que alteram a capacidade psicomotora por condutores já é bastante conhecida nos dias modernos. O consumo de bebidas alcoólicas por motoristas, por exemplo, é um tema bastante discutido e atacado nas últimas décadas. Segundo um estudo da FIOCRUZ de 2017, cerca de 16% dos brasileiros praticam a ingestão excessiva de álcool ao conduzirem veículos automotivos (Bastos *et al.*, 2017). Outro estudo mais recente aponta que, em 2019, no Brasil, cerca de 20,5% dos condutores homens e 7,2% dos condutores mulheres apresentam o hábito de beber e dirigir (Ribeiro *et al.*, 2023).

Além do álcool, outras substâncias também requerem atenção especial quanto à ingestão por condutores. Como aponta a Organização Pan-Americana da Saúde, o número de mortes no trânsito associadas ao consumo de drogas no ano de 2013 foi de pouco mais de 39,6 mil em todo o mundo (vale ressaltar que o termo “droga” utilizado aqui refere-se a uma substância com a capacidade de afetar processos mentais como a consciência, o humor ou o pensamento do usuário. Além disso, o álcool foi excluído da abrangência desse termo) (World Health Organization, 2016; Organização Pan-Americana da Saúde, 2018). Neste levantamento foram levados em conta tanto substâncias ilícitas, sob controle internacional, como cocaína, heroína, metanfetamina e cannabis, quanto medicamentos vendidos sob prescrição, como antidepressivos, benzodiazepínicos, analgésicos opióides. Também foram consideradas novas substâncias psicoativas, produzidas e usadas de forma recreativa com a expectativa de efeitos semelhantes às drogas ilícitas conhecidas (Organização Pan-Americana da Saúde, 2018). A figura 1.1 detalha melhor a quantidade de mortes do levantamento associadas ao uso de drogas em comparação com as associadas ao consumo de álcool e ao total.

Cada tipo de droga compromete diferentes funções cerebrais do usuário, cada uma com sua significância em relação à alteração da capacidade psicomotora. A figura 1.2 detalha melhor os campos comprometidos em função dos tipos de drogas.

Na legislação brasileira, o Código de Trânsito Brasileiro (CTB) estabelece que o uso de álcool e/ou drogas ilícitas por condutores pode ser tipificado como crime ou como infração administrativa a depender das características de ocorrência. O artigo 165 do CTB define como infração o ato de dirigir sob a influência de álcool ou de qualquer substância psicoativa que determine dependência, enquanto que o artigo 306 do mesmo código estabelece como

Figura 1.1 – Mortes no trânsito relacionadas a drogas em todo o mundo.



Fonte: (Organização Pan-Americana da Saúde, 2018)

Figura 1.2 – Maneiras como diversas drogas afetam o funcionamento do cérebro.

Categoria da droga	Droga	Comprometimento						
		Sonolência	Funções cognitivas	Funções motoras	Humor	Controle lateral do veículo	Estimativa de tempo	Equilíbrio
Drogas ilícitas	canabis							
	Cannabis	•	•	•	•	•	•	•
	Cocaína	—	•	•	•	—	—	—
	Anfetaminas	—	•	•	•	—	•	•
	MDAa	—	•	—	•	—	—	•
Medicamentos vendido sob prescrição	Alucinógenos	—	•	•	•	—	•	•
	Benzodiazepínicos	•	•	•	—	•	—	•
	Opioides	•	•	•	•	•	—	•
Novas drogas	Outros depressivos	•	•	•	•	•	—	•
	Canabinoides sintéticos	•	•	•	•	•	•	•
	Catinonas sintéticas	—	•	•	•	•	—	—

• a droga psicoativa tem efeito de comprometimento
 — a droga psicoativa não tem nenhum efeito de comprometimento.

Fonte: (Organização Pan-Americana da Saúde, 2018)

crime o ato de conduzir veículo automotor com capacidade psicomotora alterada em razão da influência de álcool ou de outra substância psicoativa que determine dependência (Brasil, 1997). Nota-se que a diferença entre o crime e a infração está no fato do condutor ter ou não sua capacidade psicomotora alterada. Acontece que essa diferenciação se torna um problema quando se leva em conta que a Resolução 432 do Conselho Nacional de Trânsito (CONTRAN,

2013), que estabelece os procedimentos a serem seguidos pelos agentes de trânsito neste contexto, caracteriza como sinais de alteração da capacidade psicomotora itens subjetivos como desordem nas vestes, agressividade, arrogância, exaltação e ironia, sendo que apenas dois indicativos (dificuldade no equilíbrio e fala alterada) estão diretamente relacionados com a condição de alteração. Essa subjetividade acaba por deixar as abordagens à mercê da interpretação do agente de trânsito, o que muitas vezes é associado ao abuso de autoridade, acarretando em complicações jurídicas.

O projeto em questão busca encontrar maneiras alternativas para a avaliação da capacidade psicomotora do condutor, utilizando para isso técnicas objetivas e não invasivas que sejam possíveis de se implementar nas abordagens rotineiras realizadas pelos agentes de trânsito. A metodologia é baseada nos diferentes efeitos causados por substâncias psicoativas sobre o corpo humano.

Tabela 1.1 – Alterações fisiológicas ocasionadas por sete categorias de drogas.

Droga	Frequência cardíaca	Pressão	Temperatura
Depressora	Baixa	Baixa	Normal
Inalante	Alta	Baixa	Variável
Fenciclidina	Alta	Alta	Alta
Canabis	Alta	Alta	Normal
Estimulante	Alta	Alta	Alta
Alucinogênica	Alta	Alta	Alta
Narcótico	Baixa	Baixa	Baixa

Fonte: (Merege *et al.*, 2024)

Como ilustrado na Tabela 1.1, diferentes tipos de substâncias provocam variações distintas nas características fisiológicas do usuário, além das três variáveis apresentadas na tabela, outras também podem ser afetadas. A proposta deste trabalho é o desenvolvimento de um dispositivo capaz de indicar, de forma preliminar e não invasiva, possíveis anormalidades nesses parâmetros, justificando, quando necessário, a realização de análises mais invasivas. Na sequência dessas análises, caso seja detectada alguma anormalidade, seriam realizados testes já consolidados em outros países, como o Nystagmus e o Walk-and-Turn (Buddy, 2023), porém com o auxílio de dispositivos desenvolvidos no âmbito deste projeto, visando tornar a análise mais objetiva e ágil.

Este trabalho busca, portanto, desenvolver uma metodologia de aferição das frequências respiratória e cardíaca que dispense o contato direto entre o condutor, o agente de trânsito e os dispositivos de análise.

Foi orientado que o uso de inteligência artificial (IA) na análise e obtenção das medidas fosse estritamente limitado, devido aos questionamentos levantados sobre os vieses inerentes a tais tecnologias. Um exemplo emblemático é o algoritmo COMPAS (Perfil de Gerenciamento Corretivo de Infratores para Sanções Alternativas), utilizado para estimar

a probabilidade de reincidência de prisioneiros. Esse algoritmo teve seu uso contestado após a constatação de que apresentava vieses raciais (Vieira, 2019). No campo jurídico, diversos estudos têm apontado os riscos que algoritmos de IA podem representar aos direitos individuais e coletivos garantidos pela legislação, incluindo a possibilidade de discriminação contra grupos sociais ou indivíduos (Cezare; Tárzis, 2020).

Dessa forma, para minimizar tanto as dificuldades de implementação quanto os potenciais riscos éticos, este trabalho limitou o uso da IA a funcionalidades consolidadas, especificamente na identificação de regiões e pontos faciais.

Embora o contexto do trânsito tenha sido o principal motivador deste estudo, os métodos desenvolvidos possuem aplicações mais amplas. A detecção não invasiva das frequências cardíaca e respiratória apresenta grande potencial no campo da saúde. A técnica utilizada, a fotopletismografia, é promissora e possui aplicações diversificadas na área médica, conforme será detalhado na Seção 2.1.

1.2 Frequência Cardíaca

A frequência cardíaca (FC) está diretamente relacionada ao controle neural do sistema cardiovascular, mediado em grande parte pelo sistema nervoso autônomo (SNA). O SNA fornece nervos aferentes e eferentes ao coração, com terminações simpáticas distribuídas por todo o miocárdio e terminações parassimpáticas direcionadas ao nódulo sinusal, miocárdio atrial e nódulo atrioventricular.

A partir das informações aferentes, respostas das vias simpática e parassimpática são formuladas, alterando a FC. O aumento da frequência cardíaca é resultado de uma maior ativação da via simpática e de uma menor atividade parassimpática, caracterizada pela inibição vagal. Em contrapartida, a redução da FC depende predominantemente do predomínio da atividade vagal (Vanderlei *et al.*, 2009).

A variabilidade da frequência cardíaca (VFC) é normal e esperada, e indica a capacidade do coração em responder aos múltiplos estímulos fisiológicos e ambientais, dentre eles, respiração, exercício físico, estresse mental, alterações hemodinâmicas e metabólicas, sono e ortostatismo, bem como em compensar desordens induzidas por doenças (Vanderlei *et al.*, 2009).

Desse modo, uma frequência cardíaca complexa e em constante mudança é um indicador de sistemas regulatórios saudáveis que podem se adaptar efetivamente a desafios ambientais e psicológicos repentinos. Assim, a redução da VFC não só pode ser associada a maus resultados de saúde cardiovascular e a uma série de doenças vasculares, mas também a diferentes transtornos mentais e deficiências cognitivas (Pham *et al.*, 2021).

Os índices de VFC têm sido utilizados para compreensão de diversas condições, como: doença arterial coronariana, miocardiopatia, hipertensão arterial, infarto do miocárdio,

morte súbita, doença pulmonar obstrutiva crônica, insuficiência renal, insuficiência cardíaca, diabetes, acidente vascular cerebral, doença de Alzheimer, leucemia, apneia obstrutiva do sono, epilepsia, enxaqueca, entre outras (Vanderlei *et al.*, 2009).

1.3 Frequência Respiratória

A frequência respiratória (FR) é um parâmetro fundamental que reflete o processo de respiração, o qual envolve tanto aspectos anatômicos quanto fisiológicos do sistema respiratório. Para compreendê-la, é necessário entender a anatomia do tórax e a fisiologia da respiração.

O processo respiratório possui dois componentes essenciais: a ventilação e a troca gasosa. A ventilação refere-se ao movimento físico do ar para dentro e para fora dos pulmões, enquanto a troca gasosa diz respeito à absorção de oxigênio (O_2) pelo organismo e à eliminação de dióxido de carbono (CO_2). Durante a respiração normal, a inspiração ocorre pela contração e achatamento do diafragma, assim como pela contração dos músculos intercostais externos, resultando em um movimento ascendente e externo da caixa torácica. Por outro lado, a expiração em repouso é predominantemente um processo passivo, caracterizado pelo relaxamento dos músculos inspiratórios e pelo recuo elástico dos pulmões, que restaura o equilíbrio de pressão antes do início de um novo ciclo respiratório (Hartley, 2018).

A movimentação da parede torácica observada durante a medição da FR reflete esses processos. Portanto, a FR é definida pelo número de ciclos de inspiração e expiração que ocorrem durante o processo respiratório.

A FR é um sinal vital chave que tem muitos usos clínicos. Isso inclui obter uma linha de base para comparação ou monitoramento pós-operatório, identificar transfusões de sangue ou reações medicamentosas e detectar compensação de anormalidades ácido-base (Elliott, 2016). Além disso, a aferição da FR pode indicar doenças como eventos cardíacos adversos, apneia, pneumonia, dispneia e até como indicador de nível de dor e estresse emocional (Nicolo *et al.*, 2020).

Apesar disso, muitos estudos têm destacado que a FR é frequentemente negligenciada, e apenas três estudos exploraram as razões para isso. E essas razões estão relacionadas principalmente à falta de compreensão sobre a importância da frequência respiratória como um sinal vital (Elliott, 2016).

1.4 Objetivos

O avanço da fotopleetismografia remota tem impulsionado o desenvolvimento de novas tecnologias para a captação de sinais fisiológicos de forma não invasiva. No entanto, muitas soluções atuais apresentam desafios significativos, como a necessidade de alto poder

computacional ou restrições impostas por sistemas de código e hardware fechados. Além disso, há uma lacuna na disponibilidade de dispositivos acessíveis e portáteis que possam ser utilizados em cenários específicos, como abordagens policiais, onde a rápida obtenção de sinais fisiológicos pode ser crucial. Dessa forma, este trabalho propõe o desenvolvimento de um novo hardware que atenda a essas necessidades, permitindo uma operação mais prática e acessível para a captação de sinais fisiológicos.

Além do hardware, o projeto também busca aprimorar os métodos de estimação da frequência cardíaca e respiratória. Embora a fotopletismografia remota seja um campo em expansão, ainda há desafios técnicos que precisam ser superados, incluindo a dependência de recursos computacionais intensivos e a falta de transparência tecnológica em muitas soluções disponíveis. A proposta deste trabalho é desenvolver um sistema de estimação que seja eficiente, aberto e acessível, contribuindo para a democratização da tecnologia.

Diante desse contexto, o objetivo geral deste trabalho é desenvolver um protótipo de fotopletismografia remota que seja de baixo custo, portátil e adequado para aplicações experimentais e futuras adaptações para uso em campo. Além disso, pretende-se validar o dispositivo por meio de testes em condições experimentais controladas, garantindo sua eficácia na captação e análise dos sinais fisiológicos. Para complementar o sistema, será desenvolvida uma interface gráfica compatível com o hardware, permitindo a comparação dos resultados obtidos por diferentes métodos de fotopletismografia aplicados a distintas regiões faciais.

1.5 Estrutura do Texto

A estrutura inicial deste trabalho de graduação está organizada da seguinte forma: primeiramente, será apresentada a metodologia da Fotopletismografia Tradicional e Remota, com destaque para seus princípios de funcionamento. Em seguida, serão discutidos estudos relacionados à medição da frequência cardíaca e respiratória, além de outras aplicações da fotopletismografia, suas vantagens e os desafios associados à sua implementação remota.

Posteriormente, será explorado o campo da Visão Computacional, abordando alguns dos algoritmos mais utilizados nessa área, bem como estudos e pesquisas que apontam os algoritmos mais eficazes para detecção e rastreamento facial. Além disso, será introduzido o conceito de região de interesse, fundamental para a análise subsequente. Por fim, a seção se encerra com a implementação em hardware, que dá suporte ao desenvolvimento da segunda parte deste trabalho de graduação.

2 Fundamentação Teórica

2.1 Fotopletismografia Tradicional e Remota

A palavra fotopletismografia é composta de três radicais: "Foto"que significa luz, "Pletismo"que significa volume e "Grafia"que significa gravação (Alnaeb *et al.*, 2007). Tendo seu significado evidenciado pela própria morfologia da palavra, a fotopletismografia remota (rPPG, do inglês "remote photoplethysmography") é uma técnica utilizada para medir alterações no volume sanguíneo em um leito microvascular da pele por meio de ondas eletromagnéticas com frequências pertencentes, ou próximas, ao espectro de luz visível. Diferente da fotopletismografia tradicional, ou simplesmente fotopletismografia (PPG), que requer contato direto com a pele por meio de sensores, a fotopletismografia remota pode ser realizada a distância, tipicamente usando câmeras, incluindo câmeras comuns em dispositivos móveis. Ambas possuem o mesmo princípio de funcionamento, que baseia-se em propriedades ópticas, como propriedades de absorção, espalhamento e transmissão da composição do corpo humano sob um determinado comprimento de onda (Pirzada; Wilde; Harris-Birtill, 2024).

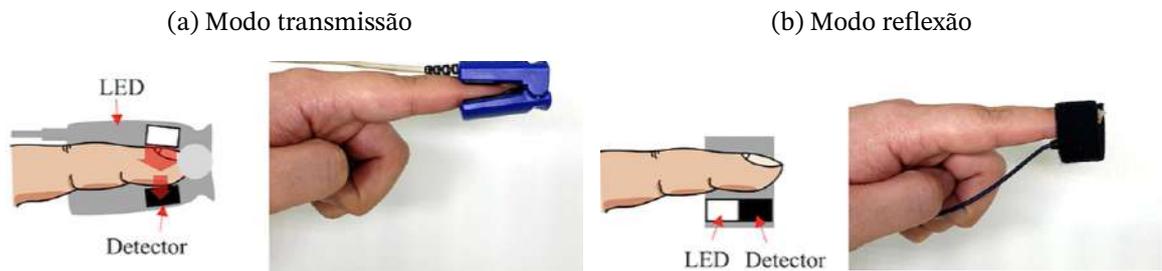
2.1.1 Princípio de Funcionamento

O conceito por trás da fotopletismografia é bem simples. Basicamente, o processo de aferição de um sinal PPG consiste em medir a luminosidade captada da pele por meio de sensores ópticos. As tecnologias modernas permitem que esse processo seja realizado de maneira bastante prática. Os dispositivos PPG convencionais possuem dois componentes principais: fotodetectores (PDs) e diodos emissores de luz (LEDs). A luz emitida pelos LEDs interage de diferentes maneiras com a estrutura do corpo humano. A luminosidade captada pelos PDs varia tanto com a localidade da pele sobre a qual é realizada a medição quanto com o momento no tempo em que esta é obtida. As flutuações de luminosidade observadas podem ser associadas a diferentes fatores fisiológicos, que serão evidenciados mais a frente.

A fotopletismografia, quando implementada em contato com a pele, possui dois modos de funcionamento, transmissão e reflexão (Ray *et al.*, 2023). A figura 2.1a mostra a configuração no modo transmissão. Nesse modo, a luz detectada é a luz emitida pelo LED que foi transmitida através do meio (tecido, osso e/ou vasos sanguíneos), enquanto que o restante da luz emitida pelo LED é refletida ou absorvida. Os LEDs e PDs estão localizados em extremidades diferentes da região analisada. Devido à transiluminação confinada, os locais em que essa configuração pode ser usada são limitados, pois é necessário que uma quantidade significativa de luz consiga ser captada pelo fotodetector (Zehava *et al.*, 2016).

Isso faz com que apenas extremidades do corpo que permitam uma maior transmissão de luz sejam utilizadas como regiões de análise, por exemplo, dedos, lóbulos das orelhas e pés neonatais (Lee *et al.*, 2021). A figura 2.1b mostra a configuração no modo reflexão, em que o emissor de luz é localizado no mesmo plano dos fotodetectores. Nesse modo, a luz detectada é a luz emitida pelo LED que foi refletida, dessa forma, os pontos em que essa configuração pode ser utilizada não são tão limitados como no modo transmissão. Pulso, testa e tronco são exemplos de locais comumente utilizados nessa configuração (Ghamari; Nazeran; Soltanpur, 2018).

Figura 2.1 – Modos de operação da fotopletismografia com contato.



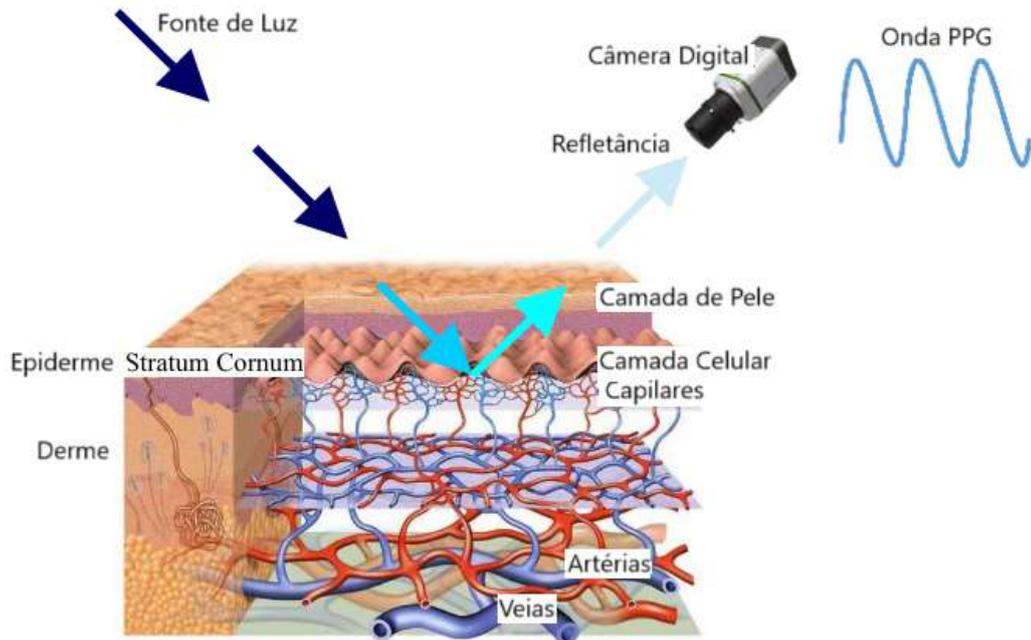
Fonte: (Park *et al.*, 2022)

O funcionamento da fotopletismografia remota é muito semelhante ao da PPG com contato. A diferença básica é que a fonte de luz e o detector de luminosidade não ficam em contato com a pele. É possível que a fonte luminosa seja a mesma do ambiente, ou seja, a própria iluminação de uma sala ou a luz do dia podem ser utilizadas como fonte de luz, também é possível uma configuração mista, em que uma fonte de luz artificial é utilizada em conjunto com a iluminação ambiente. Quanto aos detectores de luminosidade, muitos estudos demonstram que câmeras RGB comuns podem ser usadas, mesmo em ambientes escuros (Chen *et al.*, 2019). Também é possível combinar o uso de câmeras térmicas/infravermelha, com câmeras insensíveis à iluminância escura (câmeras RGB comuns), o que permite aferições mais robustas em ambientes com pouca luminosidade (Gastel; Stuijk; Haan, 2015; Zhao *et al.*, 2013).

A figura 2.2 mostra o esquema de funcionamento da fotopletismografia remota. Ao ser iluminada pela fonte de luz, a superfície da pele analisada apresenta variações mínimas em sua coloração (Hassan *et al.*, 2017). Tais variações são imperceptíveis a olho nu, mas podem ser detectadas medindo a refletância da luz durante um período de tempo a partir da intensidade de pixels da pele capturados pela câmera (Pirzada; Wilde; Harris-Birtill, 2024). Essas pequenas mudanças na luminosidade podem ser detectadas a vários metros de distância, o que permite uma alta versatilidade nas implementações da fotopletismografia de maneira remota (Rouast *et al.*, 2018).

A pele humana é a chave para associar as variações de luminosidade captadas na rPPG a fenômenos fisiológicos. Ela é bastante heterogênea e dividida em três partes principais:

Figura 2.2 – Princípio físico da obtenção do sinal PPG de maneira remota.



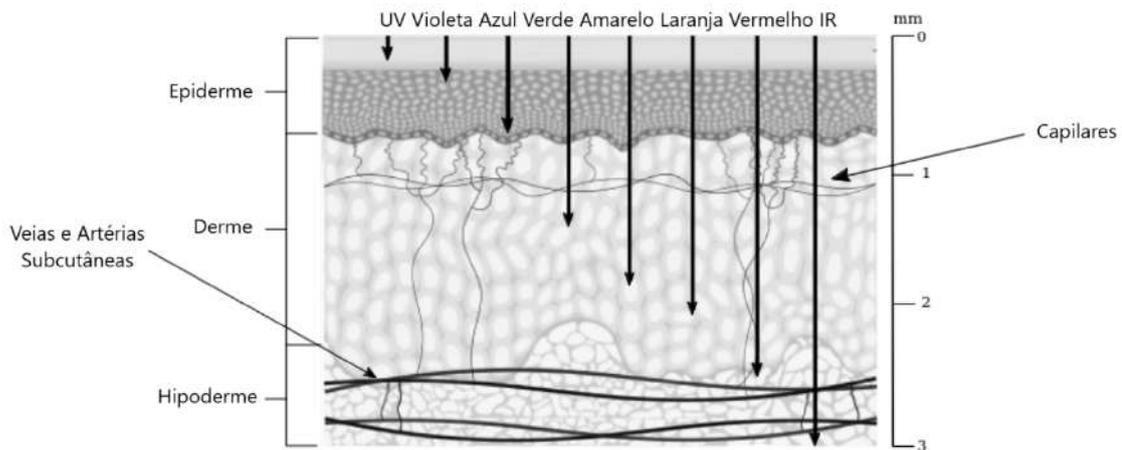
Fonte: Adaptado de Hassan *et al.* (2017)

epiderme, derme e hipoderme. Diferenças como espessura variam não só entre uma parte e outra mas também entre localidades do corpo. A hipoderme, também conhecida como tecido subcutâneo, é a camada mais profunda, ela contém vasos sanguíneos, artérias e veias de grandes espessuras, sua funcionalidade consiste principalmente em armazenar gordura. A derme é a parte intermediária, subdividida em derme papilar, composta de tecido conjuntivo frouxo vascularizado por redes de capilares, e em derme reticular, também um tecido conjuntivo, porém mais denso, e que detém folículos capilares, glândulas, nervos e vasos um pouco maiores. A camada mais superficial da pele é a epiderme, que apresenta quase nenhum fluxo sanguíneo e é composta de células escamosas mortas e células vivas, onde estão presentes os compostos responsáveis pela pigmentação da pele (Montagna; Kligman; Carlisle, 1992).

Os comprimentos de onda da luz interagem com a pele e o sangue de diferentes formas por causa dessa sua natureza heterogênea. A figura 2.3 ilustra a estrutura da pele supracitada. Nela é possível notar que os comprimentos de onda mais curtos penetram na pele em menor grau do que os comprimentos de onda mais longos. Isso indica que os comprimentos de onda mais longos estão sujeitos aos processos ópticos que ocorrem nos tecidos mais profundos (Ray *et al.*, 2023).

A profundidade de penetração na pele não é o único fator relevante a se observar sobre os comprimentos de onda. Um fator muito importante, e que está essencialmente ligado às utilidades da rPPG, é a capacidade de absorção dos diferentes componentes da pele

Figura 2.3 – Profundidade máxima aproximada de penetração para comprimentos no espectro da luz visível e em sua vizinhança.



Fonte: Adaptado de [Ray et al. \(2023\)](#)

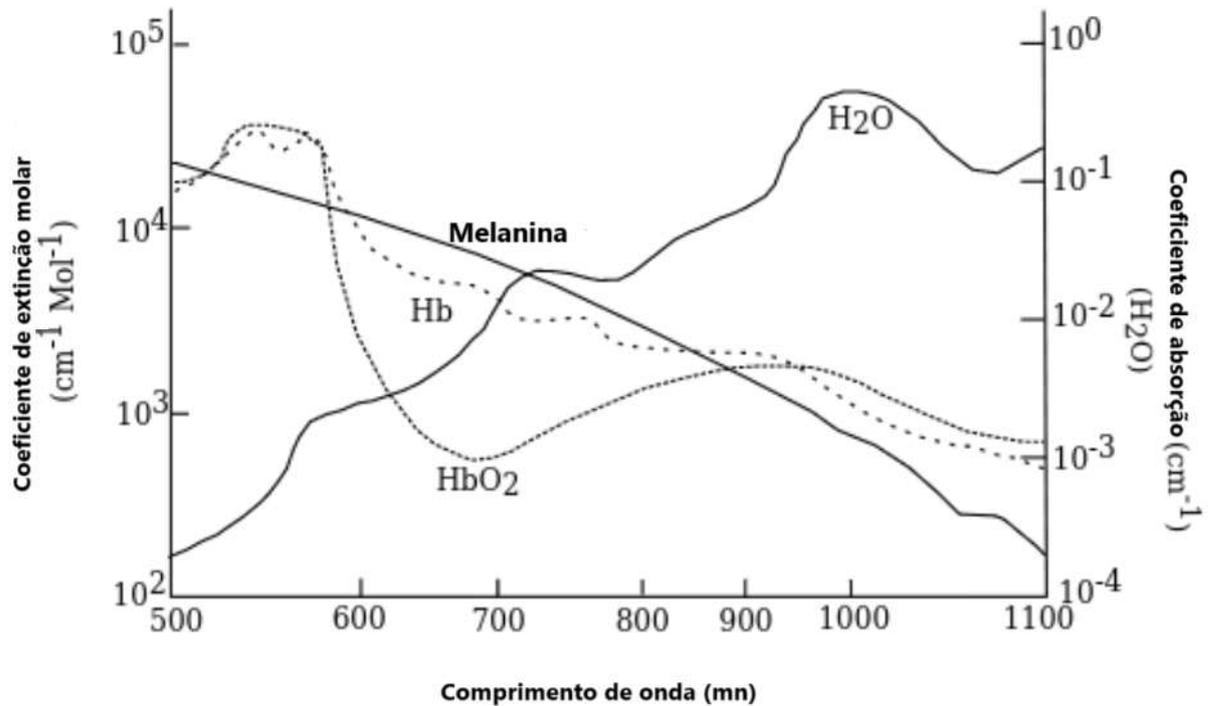
em relação aos variados comprimentos de onda. Os três principais elementos absorventes são ([Ray et al., 2023](#)):

- **Melanina:** Produzida por células da camada basal da epiderme, atua na proteção da pele contra a radiação ultravioleta (100-390 nm) e absorve eficientemente o espectro que vai desde o ultravioleta até a luz amarela (200-600 nm). No entanto, sua capacidade de absorção diminui à medida que o comprimento de onda aumenta.
- **Água:** Sendo o principal componente da pele, a água quase não absorve luz no espectro visível (390-780 nm), mas possui um alto índice de absorção na faixa da radiação infravermelha (900-1100 nm).
- **Hemoglobina:** Esta proteína, presente nos glóbulos vermelhos, é responsável pelo transporte de oxigênio no corpo. Suas propriedades de absorção variam conforme está ligada ou não ao oxigênio. A hemoglobina oxigenada (HbO_2) tem uma capacidade de absorção significativamente menor na faixa de (570-700 nm) em comparação com a hemoglobina desoxigenada (Hb). No entanto, para comprimentos de onda maiores, a oxi-hemoglobina demonstra uma capacidade de absorção mais elevada.

Para entender melhor como a fotopletiografia funciona, vale fazer menção de sua aplicação na medição dos níveis de saturação de oxigênio no sangue. A oximetria de pulso é uma técnica que relaciona bem os conceitos supracitados com um exemplo concreto e quantitativo de aferição. A implementação mais comum desta técnica é baseada em contato, sendo que a realização no modo remoto ainda é pouco estudada ([Pirzada; Wilde; Harris-Birtill, 2024](#)).

A saturação de oxigênio do sangue (SpO_2) pode ser expressa como a quantidade de hemoglobina oxigenada em relação à quantidade total de hemoglobina. A equação 2.1

Figura 2.4 – Coeficientes de absorção de luz dos compostos biológicos presentes nas pele.



Fonte: Adaptado de Ray *et al.* (2023)

detalha como a saturação é obtida a partir dos valores de concentração de hemoglobina oxigenada (C_{HbO_2}) e concentração de hemoglobina desoxigenada (C_{Hb}) (Yuan *et al.*, 2014).

$$SpO_2 = \frac{C_{HbO_2}}{C_{HbO_2} + C_{Hb}} \times 100\% \quad (2.1)$$

Na oximetria, é comum o uso de diodos emissores de luz nos comprimentos de onda vermelho e infravermelho (IR) (Lee *et al.*, 2021). A justificativa para a escolha desses comprimentos de onda está diretamente relacionada às propriedades ópticas mencionadas anteriormente. Como ilustrado na Figura 2.4, a hemoglobina desoxigenada apresenta uma absorção significativamente maior de ondas na faixa do vermelho (625–740 nm), enquanto no espectro do infravermelho, a hemoglobina oxigenada demonstra uma maior absorção (Pirzada *et al.*, 2023). De acordo com a Lei de Beer, a quantidade de luz absorvida é proporcional à concentração do material absorvente. Essa relação permite estimar as concentrações relativas dos dois tipos de hemoglobina a partir do sinal captado pelos fotodetectores (Webster, 1997).

Adicionalmente, os comprimentos de onda vermelho e infravermelho possuem boa capacidade de penetração na pele, permitindo uma interação óptica mais profunda. Essa característica é um dos motivos pelos quais implementações comerciais frequentemente

utilizam o modo transmissão, como exemplificado na Figura 2.1a. Nesse método, os fotodetectores captam a luz que é transmitida através da região analisada. Na prática, o que se mede é a luminosidade que não foi absorvida ou refletida durante o trajeto da luz emitida pelos LEDs e pelo ambiente até os fotodetectores.

Após o processamento inicial do sinal captado, os resultados correspondem a duas ondas distintas, cada uma representando a luz absorvida pelos componentes da pele para os respectivos comprimentos de onda emitidos. Essas ondas assemelham-se à curva ilustrada na Figura 2.6. O formato e as características dessas ondas serão abordados com maior detalhe na subseção 2.1.2. Neste momento, é importante destacar que essas ondas possuem duas componentes principais: uma componente oscilatória (AC), que está relacionada ao ciclo cardíaco e às alterações volumétricas do sangue arterial; e uma componente não oscilatória (DC), resultante da absorção de luz pelo sangue arterial não pulsante e da dispersão nos tecidos (Lee *et al.*, 2021).

A partir dessas componentes, é possível calcular uma razão fundamental para a determinação da oximetria. Como descrito na Equação 2.2, as amplitudes das componentes oscilatórias no espectro vermelho ($A_{\text{red, AC}}$) e no infravermelho ($A_{\text{IR, AC}}$), bem como as amplitudes das componentes não oscilatórias correspondentes ($A_{\text{red, DC}}$ e $A_{\text{IR, DC}}$), são utilizadas no cálculo da chamada razão R . Vale ressaltar que as amplitudes das componentes AC são normalizadas pelas respectivas componentes DC.

$$R = \frac{\left(\frac{A_{\text{red, AC}}}{A_{\text{red, DC}}} \right)}{\left(\frac{A_{\text{IR, AC}}}{A_{\text{IR, DC}}} \right)} \quad (2.2)$$

Quando há uma elevada concentração de Hb, e os níveis de saturação de oxigênio arterial estão baixos, a mudança relativa na amplitude da absorbância da luz vermelha devido ao ciclo cardíaco é maior do que na absorbância do IR, ou seja, $A_{\text{red, AC}}$ cresce em comparação com $A_{\text{IR, AC}}$, resultando em um aumento de R . Em contrapartida, em altos níveis de oxigenação, o inverso acontece e $A_{\text{IR, AC}}$ cresce em comparação com $A_{\text{red, AC}}$, diminuindo o valor de R . Os valores de SpO_2 podem ser determinados com base em uma curva de calibração, previamente obtida de maneira empírica, que associa diferentes níveis de saturação aos valores de R calculados (Chan; Chan; Chan, 2013).

O exemplo da oximetria de pulso demonstra a relevância da fotopletismografia no desenvolvimento de uma técnica de aferição que revolucionou a medicina moderna, graças à sua capacidade de monitoramento contínuo, transcutâneo e de baixo custo. Por conta disso, a oximetria tornou-se tão difundida que é frequentemente considerada como o quinto sinal vital (Chan; Chan; Chan, 2013; Bal, 2014). A aplicabilidade dessa técnica é ampla, já que a saturação de oxigênio no sangue (SpO_2) está relacionada a diversas condições médicas, como asma (Plüddemann *et al.*, 2011), hipóxia (Kiyatkin, 2019), doenças cardíacas (Govindaswami;

Jegatheesan; Song, 2012), pneumonia (Majumdar *et al.*, 2011) e doença pulmonar obstrutiva crônica (Kim *et al.*, 2008).

Os conceitos ópticos associados ao funcionamento da fotopletismografia são intrinsecamente relacionados às suas múltiplas aplicações. Uma análise mais detalhada do sinal PPG obtido permite correlacioná-lo com outros importantes parâmetros fisiológicos, como a frequência cardíaca e respiratória.

2.1.2 Medição da Frequência Cardíaca

A medição da frequência cardíaca é um dos principais aspectos abordados neste trabalho, exigindo especial atenção aos métodos baseados na fotopletismografia. Assim como ocorre na medição da saturação de oxigênio, a frequência cardíaca pode ser aferida tanto por meio de dispositivos em contato direto com a pele quanto de forma remota (Balaraman; Claret, 2023). Embora os métodos de contato sejam amplamente utilizados em ambientes clínicos, sistemas de fotopletismografia remota (rPPG) ainda não possuem validação clínica ampla e comercial. Apesar disso, a rPPG vem ganhando crescente atenção na pesquisa, especialmente para o monitoramento da frequência cardíaca (Pirzada; Wilde; Harris-Birtill, 2024; Chen *et al.*, 2019).

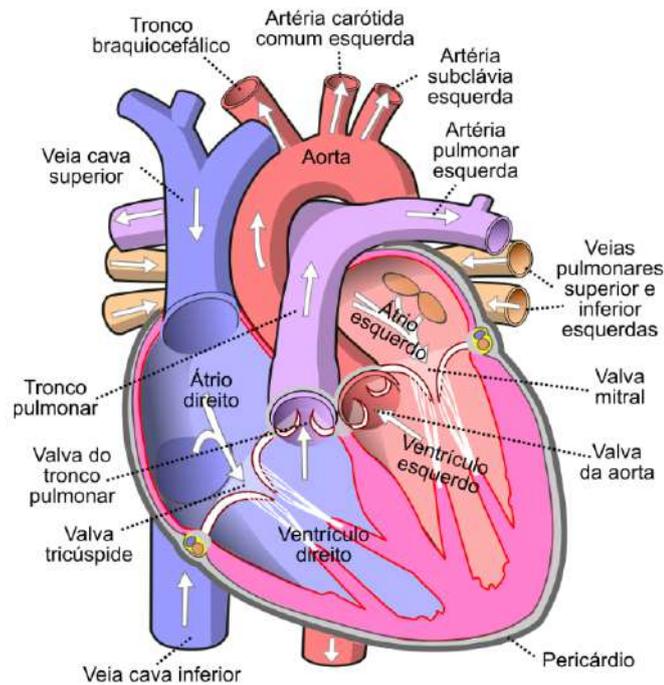
Dada a íntima relação entre a fotopletismografia e o sistema cardiovascular, uma compreensão detalhada do ciclo cardíaco e da dinâmica circulatória é essencial para elucidar os fundamentos da medição da frequência cardíaca.

Os principais elementos anatômicos do ciclo cardíaco incluem átrios, ventrículos, válvulas cardíacas, artérias e veias, conforme ilustrado na Figura 2.5. O átrio direito recebe sangue com baixo teor de oxigênio das veias cava superior e inferior, encaminhando-o para o ventrículo direito. De forma análoga, o átrio esquerdo recebe sangue oxigenado das veias pulmonares e o direciona ao ventrículo esquerdo. O ventrículo direito bombeia sangue para a artéria pulmonar, onde ocorre a oxigenação nos pulmões, enquanto o ventrículo esquerdo distribui sangue oxigenado para todo o corpo através da aorta. As válvulas cardíacas desempenham um papel crucial, impedindo o fluxo retrógrado de sangue. As válvulas tricúspide e mitral evitam o refluxo aos átrios durante a contração ventricular, enquanto as válvulas da aorta e do tronco pulmonar impedem o retorno de sangue aos ventrículos após a ejeção (Mulai, 2019; Aires, 2018).

O ciclo cardíaco é composto por movimentos de contração (sístoles) e relaxamento (diástoles) realizados pelos átrios e ventrículos. Geralmente, os termos sístole e diástole referem-se aos movimentos ventriculares, salvo especificação em contrário. A seguir, as etapas da sístole ventricular são descritas (Aires, 2018; Wikipedia contributors, 2024):

- **Contração Isovolumétrica:** O ventrículo, cheio de sangue, começa a contrair-se. A pressão ventricular supera a pressão auricular, resultando no fechamento das valvas atrioventriculares (AV).

Figura 2.5 – Anatomia do coração humano.



Fonte: (Commons, 2023)

- **Expulsão Rápida:** A pressão no ventrículo esquerdo excede a pressão aórtica, abrindo a valva aórtica. Paralelamente, o ventrículo direito supera a pressão da artéria pulmonar, abrindo a valva pulmonar. O sangue é ejetado rapidamente.
- **Expulsão Lenta:** O aumento da pressão na aorta devido ao sangue injetado causa sua distensão. As pressões nos ventrículos e na aorta tornam-se próximas, diminuindo a velocidade da ejeção sanguínea.
- **Protodiástole:** Fase de transição para a diástole, quando a pressão aórtica iguala-se à pressão ventricular, interrompendo a ejeção.

A diástole ventricular também é dividida em quatro etapas (Aires, 2018; Wikipedia contributors, 2024):

- **Relaxamento Isovolumétrico:** A pressão ventricular permanece maior que a atrial, mantendo as valvas AV fechadas. Simultaneamente, as valvas aórtica e pulmonar também estão fechadas, sem variação no volume de sangue ventricular.
- **Enchimento Rápido:** Com a pressão atrial em seu pico, as valvas AV se abrem, permitindo um fluxo sanguíneo significativo dos átrios para os ventrículos, preenchendo cerca de 70% do volume ventricular.
- **Enchimento Lento (Diástase):** O relaxamento do músculo cardíaco reduz as diferenças de pressão entre átrios e ventrículos, diminuindo o fluxo sanguíneo.

- **Sístole Atrial:** No final da diástole ventricular, ocorre a contração dos átrios, completando o enchimento ventricular. O ciclo cardíaco reinicia-se na fase de sístole.

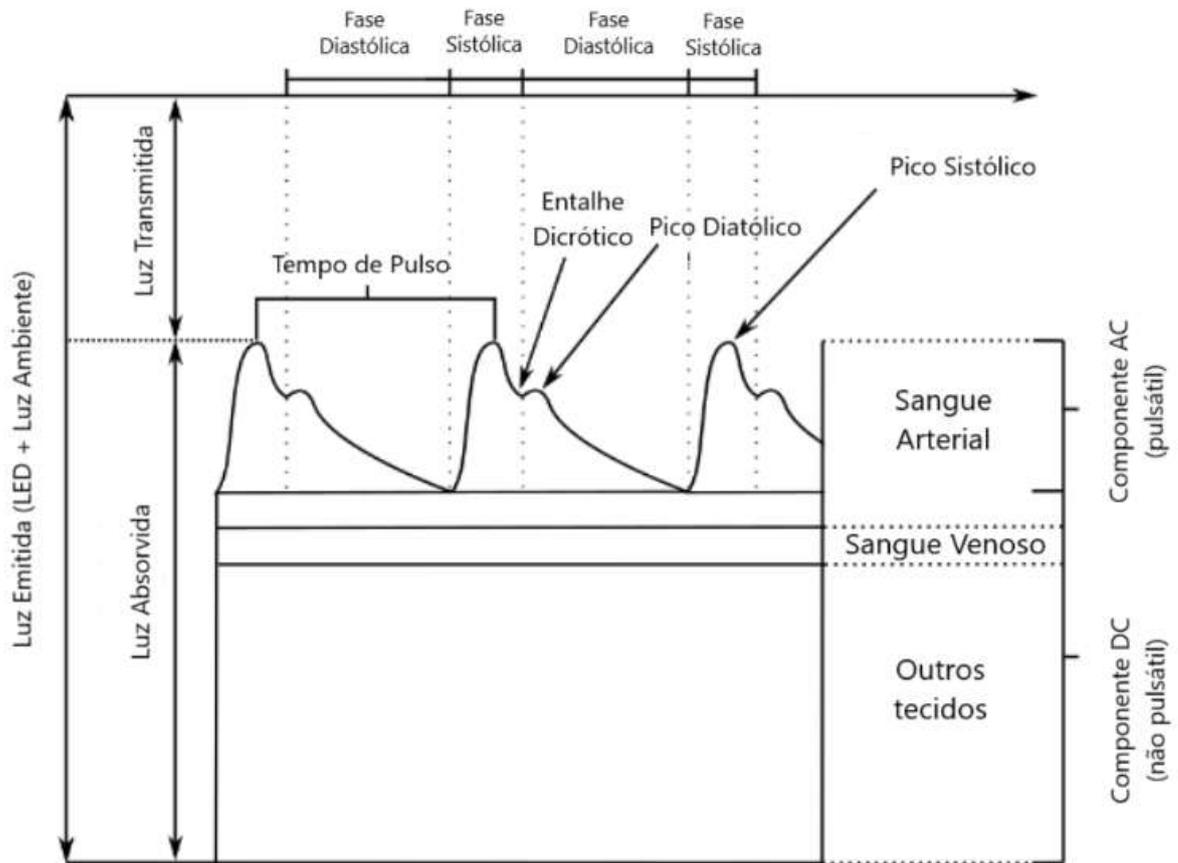
Agora que se tem em mente as etapas e os elementos anatômicos do ciclo cardíaco, pode-se associá-lo ao sinal obtido por meio da fotopletismografia. A ideia de relacionar a luminosidade captada após a irradiação de luz na pele com a atividade cardíaca já existe desde 1937, onde foi proposto que a fotopletismografia seria uma técnica utilizada para medir variações volumétricas do sangue em uma determinada região do corpo (Hertzman, 1937).

No organismo, existem diversos elementos que interagem com a luz de diferentes maneiras. O volume sanguíneo presente no local da medição, a concentração de hemoglobina e o diâmetro das artérias são exemplos de fatores que interferem na luminosidade detectada (Trafford; Lafferty, 1984; Kamal *et al.*, 1989). Em uma região de aferição da fotopletismografia é possível encontrar osso, melanina, água, células mortas, células vivas, vasos sanguíneos, dentre outros (Montagna; Kligman; Carlisle, 1992; Lee *et al.*, 2021). Enquanto grande parte desses elementos são relativamente estáticos, no sentido de que não provocam alterações significativas no caminho óptico da PPG no decorrer do tempo, a variação do volume do sangue arterial gera mudanças na luminosidade detectada de forma síncrona com o ciclo cardíaco (Alnaeb *et al.*, 2007).

A figura 2.6 mostra um caso típico do sinal obtido em uma medição PPG no modo de transmissão. A onda ilustrada refere-se à parte da luminosidade emitida pela fonte de luz e pelo ambiente que foi absorvida durante o caminho até o fotodetector. O sinal é normalmente dividido em duas componentes, a componente pulsátil (AC) e a componente não pulsátil (DC). A componente AC remete às oscilações volumétricas do sangue arterial, enquanto a componente DC está relacionada com a parte não pulsante do sangue arterial, com o sangue venoso e com todos os outros elementos presentes no caminho óptico que não possuem variações significativas nas propriedades de absorção no decorrer do tempo (Park *et al.*, 2022). Pesquisadores descobriram que, no caso da rPPG, o canal verde das câmeras fornece uma melhor componente pulsátil em comparação com os canais azul e vermelho (Guler *et al.*, 2022; Hammer *et al.*, 2022; Sinhal; Singh; Gupta, 2021). Isso reforça mais ainda a ligação da componente AC com as variações volumétricas do sangue, quando se leva em conta que a hemoglobina oxigenada absorve melhor ondas no espectro do verde em comparação com o do vermelho e do azul (Chen *et al.*, 2019; Rodrigues; Pereira; Pádua, 2016).

O contorno da onda PPG é resultado de uma interação complexa entre o ventrículo esquerdo e a circulação sistêmica (Millasseau *et al.*, 2002). Foi demonstrada uma forte ligação entre o pulso de pressão radial e o sinal da fotopletismografia, implicando que os determinantes fisiológicos do pulso PPG são semelhantes àqueles do pulso de pressão radial (Millasseau *et al.*, 2001).

Figura 2.6 – Forma de uma onda PPG típica e sua relação com as fases do ciclo cardíaco e elementos do corpo humano.



Fonte: Adaptado de Ray *et al.* (2023)

Primeiramente, a contração do ventrículo esquerdo e a consequente injeção de volume sanguíneo na aorta, geram uma onda de pressão que avança até a região onde a PPG está sendo medida, isso acaba por aumentar o volume sanguíneo no leito vascular do local. O aumento no volume do sangue faz com que uma maior quantidade de luz seja absorvida antes de chegar ao fotodetector. Essa fase é conhecida como fase sistólica, em referência à sístole ventricular que ocorre no coração. O pico sistólico marca o ponto em que a quantidade de sangue presente no leito vascular da medição é máxima (Park *et al.*, 2022). A segunda fase, denominada fase diastólica, que faz referência à diástole ventricular, marca o período onde o fluxo reverso de sangue arterial para as câmaras cardíacas reduz o volume sanguíneo no local de detecção, resultando em uma queda na quantidade de luz absorvida (Lochner *et al.*, 2014). O pico da fase diastólica é gerado por uma onda de pressão transmitida ao longo da aorta até as pequenas artérias na parte inferior do corpo, local onde é refletida de volta pela aorta, viajando até alcançar a região de medição (que neste caso está localizada na parte superior do corpo) (Millasseau *et al.*, 2002). Ao chegar na região de aferição, essa onda de pressão gera um momentâneo aumento no volume sanguíneo do leito vascular, ocasionando

em um pico de absorção denominado pico diastólico.

O tempo entre o pico diastólico e o pico sistólico (que por sua vez está relacionado com a pressão transmitida por um caminho direto do ventrículo esquerdo até a região de aferição) pode ser usado para inferir a rapidez com que o pulso de pressão se propaga pelos vasos (Shi *et al.*, 2009a). Isso é particularmente importante na avaliação da rigidez arterial, tendo em vista que é amplamente aceito que as ondas de pressão viajam mais lentamente através de vasos mais flexíveis (Eliakim; Sapoznikov; Weinman, 1971).

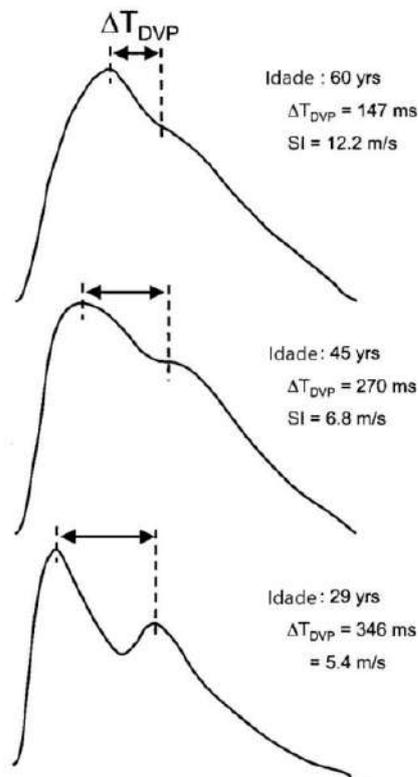
A relação entre a fotopletismografia e as fases do ciclo cardíaco é mais profunda que a simples associação com as fases de sístole e diástole. Entre o pico sistólico e o pico diastólico há um mínimo local denominado incisura dicrótica, esse ponto da curva PPG marca o fechamento das valvas aórticas (Ray *et al.*, 2023). Além disso, o fim da fase diastólica indica o fechamento da valva mitral (Pereira *et al.*, 2020).

Um fator importante a se ressaltar é que a onda PPG tem uma unidade arbitrária, já que sua medição depende das condições experimentais, como a intensidade da luz emitida pela fonte (Park *et al.*, 2022; Li *et al.*, 2014; Xu; Cheng; Chen, 2016). Além disso, as características físicas das quais o sinal PPG depende, como a capacidade de transportar oxigênio, cor da pele, distribuição dos vasos sanguíneos, tamanho ósseo, complacência vascular e débito cardíaco variam de acordo com a pessoa (Zhang *et al.*, 2001; Valencell, 2023; Krishnaswamy; Baranoski, 2004).

Como consequência dessa diversidade de variáveis que podem mudar dependendo da pessoa, o formato da curva obtida nem sempre é como visto na figura 2.6. A figura 2.7 mostra diferentes formatos de onda capturados em pessoas de idades diferentes. Cada curva apresenta 3 valores numéricos, são esses: a idade da pessoa da qual o sinal foi obtido, o tempo em milissegundos entre o pico sistólico e o pico diastólico e um índice que pode ser associado à rigidez arterial proposto pelo estudo que realizou tais medições (Millasseau *et al.*, 2002). Nota-se que nem sempre é possível identificar claramente o pico diastólico. Nesse caso, após o pico sistólico, quando não há um máximo local, o ponto de onde a derivada da curva atinge seu valor mínimo é considerado como o pico diastólico.

Alguns fatores influenciam o sinal PPG de maneira não necessariamente periódica. Variáveis fisiológicas, como respiração, termorregulação, complacência vascular, tônus vascular, dor e uso de medicamentos, causam variações na linha de base do sinal PPG (Ghamari; Nazeran; Soltanpur, 2018; Nitzan *et al.*, 2000; Shelley *et al.*, 2006; Shelley, 2008). Essas variações refletem alterações na amplitude do sinal que não estão diretamente relacionadas ao ciclo cardíaco. Por exemplo, quando a temperatura da pele está baixa, o sistema nervoso autônomo contrai os vasos sanguíneos na derme para conservar o calor corporal, reduzindo significativamente a perfusão no leito vascular (Jeong *et al.*, 2014; Budidha, 2018). Isso demonstra que o volume sanguíneo no local da medição, e conseqüentemente a leitura obtida, podem ser afetados por fatores distintos do ciclo cardíaco. Felizmente, as oscilações

Figura 2.7 – Variações da forma da onda PPG, do tempo de propagação de pulso e da rigidez arterial de acordo com a idade.



Fonte: Adaptado de Millasseau *et al.* (2002)

associadas aos batimentos cardíacos são bastante características e podem ser isoladas do restante do sinal, desde que os níveis de ruído sejam baixos.

Compreendido o padrão característico da fotopletismografia e sua relação com o ciclo cardíaco, a obtenção dos valores de frequência cardíaca torna-se relativamente simples. Existem duas abordagens básicas para aferir a frequência cardíaca a partir de um sinal PPG. A primeira baseia-se em algoritmos de detecção de picos, que identificam a periodicidade da curva obtida. Considerando a taxa de amostragem e a repetição do sinal ao longo do tempo, é possível calcular uma estimativa da frequência cardíaca. Por ser periódico e sincronizado ao ciclo cardíaco, o valor da frequência pode ser derivado diretamente da periodicidade do sinal PPG. A segunda abordagem utiliza a análise espectral, aplicando a transformada de Fourier ao sinal. Nesse caso, a frequência cardíaca corresponde à componente do espectro de frequências com maior amplitude.

Ambas as técnicas são de fácil implementação, e algoritmos eficientes já foram desenvolvidos para essas tarefas. O maior desafio, contudo, não está em calcular a frequência cardíaca, mas em obter um sinal de alta qualidade, livre de ruídos. As técnicas assumem que o sinal PPG foi previamente filtrado e processado, com minimização de ruídos, como aqueles causados por iluminação ou movimento, e sem variações na linha de base. Há, portanto,

uma etapa preliminar de tratamento do sinal, para a qual diversas soluções foram propostas na literatura. O foco aqui é entender como extrair a frequência cardíaca do sinal PPG. Vale ressaltar que, embora essas sejam as principais técnicas, outras abordagens também existem. Métodos baseados em aprendizado de máquina, por exemplo, podem determinar diretamente a frequência cardíaca sem seguir essas etapas tradicionais.

2.1.3 Medição da Frequência Respiratória

Assim como a frequência cardíaca, a frequência respiratória é essencial neste trabalho e exige uma análise detalhada do método de medição pela fotopletismografia. Inicialmente, é importante compreender como a respiração impacta o sistema cardíaco. Conforme discutido na Seção 2.1.2, o sangue desoxigenado retorna ao lado direito do coração pelo sistema venoso periférico e central, sendo então bombeado do ventrículo direito para os pulmões através da artéria pulmonar, onde ocorre a oxigenação. Durante a diástole, o sangue oxigenado retorna ao lado esquerdo do coração, reiniciando o ciclo pela aorta durante a sístole seguinte.

De acordo com (Iqbal *et al.*, 2022), o processo de inspiração e expiração pode alterar o volume de sangue no corpo, permitindo a medição da frequência respiratória por meio dos batimentos cardíacos ou do fluxo sanguíneo. A pressão venosa periférica, que varia entre 8 e 10 mmHg, é maior que a pressão no átrio direito, geralmente entre 0 e 4 mmHg. Essa diferença de pressão assegura o retorno venoso contínuo da circulação periférica para o coração. Durante a inspiração, o retorno venoso aumenta de duas maneiras (Meredith *et al.*, 2011):

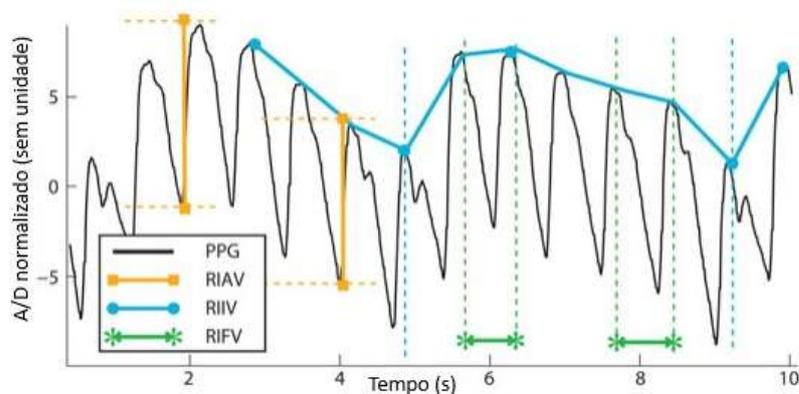
1. A expansão da parede torácica causa uma tração radial nos órgãos torácicos e uma redução na pressão dentro do coração e dos vasos sanguíneos externos ao pulmões. Dessa forma, a pressão do átrio direito pode diminuir para -2 mmHg em média, aumentando a diferença de pressão entre a pressão venosa periférica e o átrio direito, o que resulta em um aumento do fluxo sanguíneo das periferias para o tórax.
2. A descida do diafragma aumenta a pressão externa as veias intra-abdominais, o que aumenta o fluxo sanguíneo de retorno ao coração, aumentando a pressão nos vasos abdominais.

Visto como a respiração pode afetar o fluxo sanguíneo, e como na seção 2.1 é mostrado que a fotopletismografia consiste em aferir a luminosidade que interage com a pele e o sangue, e o sinal captado é composto por duas componentes de corrente contínua (DC) e corrente alternada (AC). Como ressaltado na seção 2.1.2, a componente AC mostra as alterações no volume sanguíneo que ocorrem na fase sistólica e diastólica do ciclo cardíaco. Já a componente DC corresponde ao sinal óptico transmitido ou refletido detectado do tecido e depende da estrutura do tecido e do volume sanguíneo médio de sangue arterial e venoso (Tamura *et al.*, 2014), como mostrado na figura 2.6.

Vários fatores podem afetar a morfologia do sinal PPG, o qual é diretamente influenciado pelo coração e pela circulação. Além disso, o sinal também é impactado por processos fisiológicos adicionais, como a respiração e o sistema nervoso autônomo, que podem ser alterados pelo estresse (Mejía-Mejía *et al.*, 2022). Esses fatores geram diversos tipos de ruídos aditivos presentes no sinal PPG. A respiração, por sua vez, pode induzir variações no sinal de três maneiras (Dehkordi *et al.*, 2018):

1. Variação de intensidade induzida pela respiração (do inglês Respiratory-Induced Intensity Variations - RIIV): As alterações no retorno venoso devido a mudanças na pressão intratorácica ao longo do ciclo respiratório causam uma modulação basal do sinal PPG. Durante a inspiração, a diminuição da pressão intratorácica resulta em uma pequena diminuição da pressão venosa central, aumentando o retorno venoso. O oposto ocorre durante a expiração. À medida que o leito venoso no local da sondagem se enche e drena ciclicamente, a linha de base é modulada de acordo;
2. Variação da amplitude induzida pela respiração (do inglês Respiratory-Induced Amplitude Variations - RIAV): Durante a inspiração, o volume sistólico do ventrículo esquerdo diminui devido a alterações na pressão intratorácica, levando à diminuição da amplitude do pulso. O oposto acontece durante a expiração;
3. Variação de Frequência Induzida pela Respiração (do inglês Respiratory-Induced Frequency Variations - RIFV): A frequência cardíaca varia ao longo do ciclo respiratório, onde aumenta durante a inspiração e diminui durante a expiração. Esse fenômeno, conhecido como arritmia sinusal respiratória, deve-se principalmente à regulação autônoma da frequência cardíaca durante a respiração.

Figura 2.8 – Variações induzidas pela respiração no sinal PPG.



Fonte: Adaptado de Karlen *et al.* (2013)

Na figura 2.8, é ilustrado as três maneiras em que a respiração pode alterar o sinal PPG. A RIIV é a variação da linha de base de perfusão, a RIAV é a mudança na força do

pulso e a RIFV é uma sincronização do batimento cardíaco com a frequência respiratória (Karlen *et al.*, 2013).

Após encontrar os sinais RIIV, RIAV e RIFV, é possível estimar a frequência respiratória a partir de cada sinal no domínio do tempo, calculando a diferença de tempo entre dois picos, ou no domínio da frequência, fazendo uma Transformada Rápida de Fourier (do inglês Fast Fourier Transform - FFT) e, consecutivamente, encontrando a componente de frequência cuja amplitude é máxima (Fikriastuti; Muhaimin, 2021). Também é possível estimar o valor da frequência respiratória aplicando a FFT diretamente no sinal PPG e identificando as frequências dominantes dentro do espectro aceitável para seres humanos (Filho *et al.*, 2023).

2.1.4 Outras Aplicações da Fotopletismografia

Como visto, o sinal PPG é composto de uma série de elementos importantes (pico sistólico, pico diastólico, incisura dicrótica, linha de base) que estão relacionados com os fenômenos fisiológicos do corpo humano. Enquanto algumas aplicações são quase que imediatas, como a medição da frequência cardíaca, outras não apresentam uma associação tão óbvia, como a frequência respiratória.

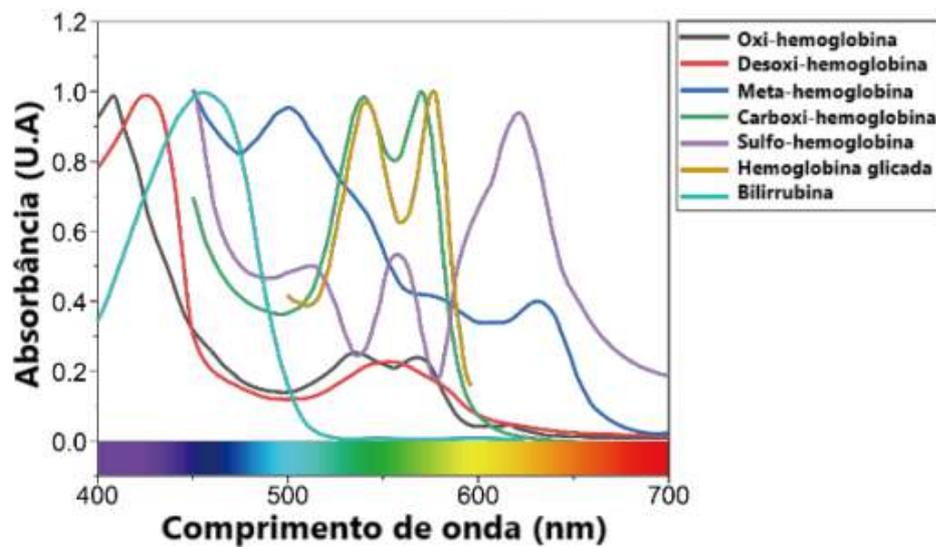
Diversas associações podem ser feitas entre características da onda PPG e variáveis fisiológicas. A amplitude do pico sistólico, por exemplo, tem uma correlação significativa com a expansão microvascular e é proporcional ao débito cardíaco (Dorlas; Nijboer, 1985; Murray; Foster, 1996). Ademais, estudos mostram que quando a vasculatura periférica está dilatada, a amplitude do pico sistólico é maior, enquanto que, quando o contrário acontece, o pico sistólico é menor (Park *et al.*, 2022). Outra descoberta é que o tônus vascular e a complacência vascular interferem no ponto de ocorrência da incisura dicrótica. Quando o tônus vascular aumenta, a ocorrência da incisura é avançada (Shi *et al.*, 2009b). A diferença temporal entre os picos sistólico e diastólicos diminui com o envelhecimento (Qawqzeh; Reaz; Ali, 2012). As associações não se limitam apenas à curva PPG e podem ser expandidas para sua primeira e segunda derivadas (Park *et al.*, 2022).

Essa análise detalhada e atenciosa do sinal PPG possibilita o uso da fotopletismografia em várias aplicações clínicas, como na estimativa da pressão arterial, monitoramento de crises epiléticas, avaliação do envelhecimento vascular, previsão de fibrilação atrial, previsão de diabetes, avaliação de doença vascular periférica, avaliação da dor cirúrgica e pós-operatória, reconstrução de bio-sinais, estimativa de parâmetros hemodinâmicos, como débito cardíaco e volume sistólico, monitoramento do sono, incluindo detecção de apneia e hipopneia, e reconhecimento emocional (Park *et al.*, 2022; Rukasha *et al.*, 2020).

O uso de múltiplos comprimentos de onda pode expandir ainda mais as aplicações da fotopletismografia. O caso já citado da oximetria de pulso, uma aplicação baseada nas diferentes propriedades de absorção da oxihemoglobina e desoxihemoglobina, demonstra bem isso. O mesmo princípio da oximetria pode ser utilizado para analisar outros elementos

absorventes de luz presentes no sangue. A figura 2.9 mostra, além da hemoglobina oxigenada e desoxigenada, outros estados menos comuns da hemoglobina e os seus níveis de absorvância na região da luz visível.

Figura 2.9 – Absorvância da bilirrubina e de diversos tipos de hemoglobina na região da luz visível.



Fonte: Adaptado de Lister, Wright e Chappell (2012), Baranoski *et al.* (2012), Jo, Mun e Kim (2016)

Estudos mostram a importância de se monitorar continuamente os níveis de Metaemoglobina (MetHb) e Carboxihemoglobina (COHb) para identificar pacientes com intoxicação por monóxido de carbono em triagens de hospitais (Suner *et al.*, 2008; Chee *et al.*, 2008; Coulangue *et al.*, 2008). A absorvância dessas substâncias são representadas pelas curvas azul e verde no gráfico da figura 2.9. A diferença no comportamento abre margem para o uso da fotopletismografia na identificação de suas concentrações. Outras substâncias como a hemoglobina glicada e a bilirrubina também apresentam benefícios em seu monitoramento. A fotopletismografia é um método que demonstra potencial para preencher uma lacuna no que se refere a uma metodologia de detecção dessas substâncias que seja rápida, barata, confiável, não invasiva e de monitoramento contínuo (Lee *et al.*, 2021).

2.1.5 Vantagens da Fotopletismografia Remota

Apesar de ainda não existirem dispositivos comerciais baseados em fotopletismografia remota, essa técnica possui contextos de aplicação em que seu uso supera as soluções já existentes (Pirzada; Wilde; Harris-Birtill, 2024).

Primeiramente, é importante destacar que a fotopletismografia remota, devido à natureza de sua aferição à distância, apresenta desafios adicionais relacionados à minimização de ruídos quando comparada com a PPG de contato. Tendo isso em vista, o campo de pesquisa

da fotopleletismografia remota concentra-se principalmente na determinação da frequência cardíaca. Comparando a aferição da FC usando fotopleletismografia remota com a PPG de contato e o ECG, é possível identificar situações em que o uso da primeira é vantajoso.

O eletrocardiograma, embora considerado o padrão ouro de aferição, apresenta falta de portabilidade e conveniência. Os bioeletrodos são intrusivos, não podem ser molhados e precisam estar conectados ao dispositivo de gravação e processamento. Além disso, o contato com a pele pode causar desconforto e irritação. Outro fator a considerar é o custo elevado de aquisição e manutenção do equipamento, o que pode ser proibitivo para pequenos consultórios médicos ou para uso domiciliar (Ghamari; Nazeran; Soltanpur, 2018; Balaraman; Claret, 2023).

Quanto à PPG de contato, embora seja um método preciso e eficiente, em algumas situações ela não é tão viável, como em vítimas de queimaduras, recém-nascidos prematuros e idosos com pele frágil, quando o contato pode causar complicações. O monitoramento contínuo da frequência cardíaca, utilizado na descoberta precoce de doenças cardíacas, aumenta a probabilidade de reações alérgicas e irritação na pele (Rodrigues; Pereira; Pádua, 2016).

É nesse contexto que a rPPG surge como uma forma econômica, confortável e conveniente de medir a frequência cardíaca, apresentando um grande potencial em situações de aferição contínua onde o contato físico não é preferível. Exemplos incluem o monitoramento em UTIs neonatais, monitoramento de longo prazo, pacientes queimados ou traumatizados, análise do estado afetivo e avaliação do estado do motorista (Chen *et al.*, 2019). Esse último, como foi detalhado na seção 1.1, foi um dos principais motivadores para este trabalho.

2.1.6 Desafios da Fotopleletismografia Remota

Apesar de apresentar vantagens em comparação com outros métodos de aferição de sinais fisiológicos, a fotopleletismografia remota encontra algumas dificuldades que ainda impedem sua implementação em larga escala. A tecnologia é afetada principalmente por quatro fatores: variações de iluminação, artefatos de movimento, qualidade do sinal captado e limitações de hardware (Li *et al.*, 2014; Lam; Kuno, 2015; Wang; Stuijk; Haan, 2015a; Pirzada; Wilde; Harris-Birtill, 2024). Muitos estudos têm sido realizados visando solucionar as interferências desses fatores. A significância de cada uma dessas quatro variáveis acaba por depender das condições de implementação do sistema, isso faz com que as soluções propostas tenham desempenhos diferentes de acordo com o ambiente e as condições experimentais. Por exemplo, a quantidade de pessoas monitoradas, a quantidade de câmeras utilizadas, as condições de iluminação no local de aferição são todos parâmetros que deixam em aberto qual seria a melhor abordagem para obter um sinal de boa qualidade. Algumas abordagens para solução dessas interferências fazem inferências acerca das condições do ambiente, limitando suas eficiências a condições específicas, outras tentam ser versáteis e ter um bom

funcionamento nas mais variadas situações (Chen *et al.*, 2019).

A qualidade do sinal é uma característica crucial que permite garantir a utilidade da curva PPG. Um sinal com um ruído relativamente alto tira a confiabilidade das informações obtidas a partir dele. Por ser ainda uma técnica recente, há divergências na literatura sobre o que afeta ou não a qualidade do sinal PPG. Isso ocorre principalmente pela falta de banco de dados abrangentes que permitam testar os algoritmos desenvolvidos nas mais variadas condições e em grupos demográficos amplos, com uma gama diversificada de participantes (Pirzada; Wilde; Harris-Birtill, 2024). Um exemplo de característica física que ainda apresenta divergências quanto a sua influência no sinal captado é a cor da pele. Alguns estudos afirmam que um maior teor de melanina pode influenciar no desempenho e precisão do sistema PPG, em contrapartida, outros autores afirmam que trata-se de uma questão mais profunda. A parte pulsátil da PPG advém das interações ópticas com a derme e hipoderme. A melanina concentra-se na epiderme e absorve uma quantidade constante da luz irradiada, ou seja, não afeta diretamente a componente pulsátil do sinal, isso sugere que um maior teor de melanina apenas enfraquece o sinal (uma pele mais escura absorve mais a luz emitida, o que faz a amplitude da componente do sinal não pulsátil aumentar em relação à amplitude do pulsátil), dessa forma, um aumento na quantidade de luz emitida poderia compensar o efeito (Premkumar; Hemanth, 2022; Ray *et al.*, 2023). Muitos bancos de dados públicos são compostos, em sua maioria, por indivíduos de pele clara, o que levanta questionamentos acerca da generalidade dos métodos desenvolvidos (Pirzada; Wilde; Harris-Birtill, 2024).

Além da diversidade nos grupos raciais, outros fatores também carecem de atenção. Por ser uma região de relativamente pouca movimentação e por quase nunca estar encoberta, o rosto é a localidade do corpo mais visada para a aferição da rPPG. A presença de pelos na face, como barba e franja, o uso de produtos estéticos como, cremes faciais, batons, base e maquiagem no geral, são todos pontos importantes que levantam questionamentos sobre o quanto afetam os métodos PPG desenvolvidos (Pirzada *et al.*, 2022; Wang; Shan, 2020). É de se esperar que os pelos faciais inviabilizem a aferição nas regiões onde esses se concentram densamente, já que a visibilidade da pele se torna quase inexistente. Esse problema pode ser contornado utilizando técnicas de visão computacional para selecionar regiões da face mais viáveis para aquisição do sinal, cada uma dessas regiões é conhecida como região de interesse (ROI). Enquanto alguns trabalhos não implementam mecanismos modernos de visão computacional que permitam atacar esses problemas, outros usam desse recurso para segmentar a face detectada em vários patches (pedaços), o que permite implementar algoritmos que escolham quais dessas regiões podem ser consideradas para a obtenção de um sinal de melhor qualidade. Essa problemática será detalhada melhor na seção 2.3. Quanto ao uso de maquiagem, há muito pouca atenção a este tema. Um estudo analisou a interferência de um tipo de maquiagem em específico, uma base protetora de pele (Wang; Shan, 2020). Foi constatada uma influência negativa que reduz a força relativa (AC/DC) do sinal, semelhante ao efeito observado em uma pele mais escura. Isso acaba por tornar difícil a extração de um

sinal de alta qualidade e inviabiliza a medição dos níveis de saturação de oxigênio, já que as proporções de absorção de luz dos diferentes comprimentos de onda utilizados também são alteradas. Ademais, há uma gama de produtos estéticos, com diferentes composições químicas e utilizados em diferentes regiões do rosto que ainda não foram analisados quanto a suas interferências na fotopletoislografia remota.

A intensidade do sinal também pode ser afetada por parâmetros fisiológicos. Hipotermia, vasoconstrição, diminuição do débito cardíaco, diminuição da pressão arterial média e hipovolemia são exemplos de variáveis que causam baixa perfusão, ou seja, podem enfraquecer as alterações volumétricas do sangue nos vasos (Alnaeb *et al.*, 2007). Quando a temperatura da pele diminui, o sistema nervoso autônomo contrai os vasos sanguíneos na derme, com o objetivo de conservar a temperatura do corpo, isso ocorre em maior grau nas regiões periféricas, ocasionando em hipoperfusão (Jeong *et al.*, 2014; Budidha, 2018). É plausível supor que a qualidade do sinal PPG pode ser afetada pela diminuição das alterações volumétricas do sangue, já que essas alterações são justamente o objeto de análise do método. A escassez de dados e estudos permanece no tocante a essas variáveis fisiológicas. Os estudos de fotopletoislografia **com contato**, apesar de concordarem que a variação da temperatura influencia na aferição, divergem quanto ao grau de interferência dessa variável (RALSTON; WEBB; RUNCIMAN, 1991; Budidha, 2018). Dada a similaridade metodológica entre a fotopletoislografia com contato e a rPPG, algumas outras variáveis, bem poucas ou não estudadas na categoria remota, mas que foram observadas na fotopletoislografia com contato, merecem atenção com relação a possibilidade de interferência, é o caso do índice de massa corporal (IMC), da atividade do sistema nervoso simpático e da obesidade (Shcherbina *et al.*, 2017; Fine *et al.*, 2021; Gillinov *et al.*, 2017; Wang *et al.*, 2016).

Uma outra categoria de fatores que representam desafios para a fotopletoislografia remota são as limitações de hardware. Já foram desenvolvidos experimentos rPPG utilizando uma alta variedade de dispositivos, como smartphones, webcams de laptops, drones com câmeras e Kinect. Cada um desses dispositivos possui atributos próprios, como poder de processamento, tipo de dados coletados, valor monetário, resolução e dimensões (Pirzada; Wilde; Harris-Birtill, 2024).

A capacidade de processamento é um parâmetro muito importante, vários experimentos exigem requisitos de hardware específicos para atingir um bom desempenho, como grandes memórias de acesso aleatório (RAM) e unidades de processamento gráfico (GPU). Ter uma boa capacidade de processamento é crucial para garantir um tempo de execução hábil, tendo em vista que o processamento de imagens, uma etapa muito importante do processo de aferição, é uma tarefa que exige um alto poder computacional, ainda mais se as imagens obtidas forem de alta qualidade. Garantir um tempo de execução menor é importante para permitir o uso do sistema em situações de emergência ou em tempo real. Outro fator importante a ser garantido é a taxa de amostragem dos frames capturados (FPS), garantir uma taxa de aquisição constante é crucial para uma aferição correta das caracte-

rísticas fisiológicas, uma vez que variáveis como frequência cardíaca e respiratória estão intrinsecamente atreladas à dimensão temporal. Essas necessidades podem ser supridas fornecendo os requisitos necessários, todavia garanti-los fora do ambiente experimental, seja para implementação em larga escala ou para uso pessoal de pessoas de baixa ou média renda, pode ser um desafio no que se refere ao alto custo monetário (Pirzada; Wilde; Harris-Birtill, 2024).

Além da unidade de processamento, as metodologias desenvolvidas também contam com hardware dedicado à aquisição dos dados e iluminação artificial. Normalmente são utilizadas câmeras digitais RGB para a aquisição das imagens, mas algumas implementações fazem uso de câmeras térmicas e dispositivos de carga acoplada (CCD) (Waqar, 2019; Gatto, 2009; Kvišis-Kipge; Rubīns, 2020; Wang *et al.*, 2017b; Selvaraju *et al.*, 2022). As vantagens adquiridas nessas realizações alternativas podem não ser de fácil implementação devido ao custo proibitivo desses equipamentos. A título de exemplo, câmeras térmicas/infravermelhas podem ser usadas juntamente com câmeras RGB para melhorar a aquisição de dados em ambientes de baixa luminosidade (Gastel; Stuijk; Haan, 2015; Zhao *et al.*, 2013). Além disso, o uso dessas câmeras também pode ser eficaz para contornar outros problemas associados a variações de iluminação, sendo possível estimar a frequência cardíaca sob condições de luz altamente dinâmicas (Jeanne *et al.*, 2013). Ademais, a aquisição feita com comprimentos de onda próximos do infravermelho (NIR) demonstrou-se menos suscetível a interferências causadas pelo uso de maquiagem (Wang; Shan, 2020). Quanto ao tempo de exposição utilizado nas câmeras, foi desenvolvido um algoritmo que busca controlá-lo para melhorar a relação relação sinal-ruído (SNR) (Laurie *et al.*, 2020).

Novamente, por ser um campo de estudo relativamente novo, não existem muitos estudos sobre como esses parâmetros associados à forma de implementação podem afetar os resultados. O impacto da quantidade de bits utilizada para cada canal RGB ou da resolução das imagens capturadas não é bem conhecido. É de se esperar que uma profundidade de bits maior poderia produzir um sinal mais limpos, entretanto, não se tem muito conteúdo a respeito para uma conclusão (Pirzada; Wilde; Harris-Birtill, 2024).

Ademais, a maioria dos métodos de fotoplethismografia remota desenvolvidos utiliza base de dados com vídeos não compactados. A não compactação implica em dificuldade de armazenamento, exigindo grandes quantidades de memória. Além disso, por terem muitos dados, os vídeos são de difícil compartilhamento online, tendo em vista as limitações quanto à taxa de transmissão das redes de telecomunicações atuais, o que pode inviabilizar implementações que necessitem de comunicação via rede. Felizmente, estudos demonstram que o desempenho de alguns sistemas rPPG para vídeos compactados é próximo em relação aos não compactados, indicando que essa preocupação pode não ser tão alarmante (Chen *et al.*, 2019).

A iluminação é um fator intrinsecamente relacionado ao princípio de funcionamento

da rPPG e possui grande influência sobre os métodos desenvolvidos. A intensidade da luz e seus comprimentos de onda são fatores importantíssimos que interferem na aferição. O comprimento de onda verde captado em câmeras RGB, por exemplo, mostra-se como aquele que produz uma melhor componente pulsátil (Guler *et al.*, 2022; Hammer *et al.*, 2022; Sinhal; Singh; Gupta, 2021). Por conta disso, alguns métodos consideram apenas as informações do canal verde. Outros utilizam as informações de múltiplos canais de cores em suas análises, visando obter um sinal menos ruidoso. Caso haja uma variação de luminosidade no ambiente, seja ela uma alteração na composição espectral da luz, ou uma mudança de intensidade luminosa, a informação captada pelas câmeras registra esse evento como um ruído, que pode comprometer a informação útil do sinal, tendo em vista que as variações de luminosidade devido à pulsação sanguínea possuem uma amplitude comparavelmente baixa.

Uma situação típica em que isso pode ocorrer é uma pessoa assistindo a um filme na frente de um laptop em uma câmara escura. A variação de luz da tela causa o ruído de iluminação no rosto, onde está sendo feita a extração do sinal. Uma forma de tratar esse tipo de ruído é fazer suposições a respeito dessas interferências luminosas. Uma solução para minimizar o ruído nesse caso do filme no laptop foi subtrair artefatos de iluminação do canal verde do sinal rPPG considerando os sinais de variação de brilho extraídos dos pixels da tela. Os resultados mostraram que a raiz do erro quadrático médio diminuiu (Lee *et al.*, 2015). Em algumas situações, quando ocorre a variação de luminosidade, a região do fundo e a face sofrem de interferências semelhantes. Nesse caso, é possível implementar uma outra abordagem, que consiste em mitigar o ruído luminoso usando a região de fundo como referência de ruído. Vários métodos implementam esse tipo de tratamento (Li *et al.*, 2014; Cheng *et al.*, 2017). O problema dessas metodologias é que elas dependem de suposições acerca do ambiente, que nem sempre são verdadeiras. O conhecimento prévio das variações de brilho do filme e o grau de similaridade das interferências luminosas sobre a face e o fundo são determinantes para esses exemplos. Situações como vultos, faróis de carros, cintilações na mesma faixa de frequência dos batimentos cardíacos aferidos podem ser graves empecilhos.

Como foi dito no tópico anterior, alternativas de hardware, com câmeras infravermelhas/térmicas e dispositivos de carga acoplada, também podem ser utilizados para performar melhor em ambientes escuros ou com iluminação dinâmica (Haan; Jeanne, 2013; Jeanne *et al.*, 2013; Gastel; Stuijk; Haan, 2015; Zhao *et al.*, 2013; Wang; Shan, 2020).

Existem outras metodologias que buscam minimizar os ruídos gerados pela iluminação e suas eficiências estão atreladas às condições ambientais e experimentais. O problema da variação de iluminação ainda é um grande obstáculo a ser ultrapassado.

Os artefatos de movimento são um dos maiores desafios a serem superados no desenvolvimento da fotopletiografia remota, sendo alvo crescente de trabalhos que tentam minimizar os impactos desse tipo de interferência (Chen *et al.*, 2019). Esse problema surge dos movimentos realizados pela pessoa sobre a qual se está realizando a medição do sinal.

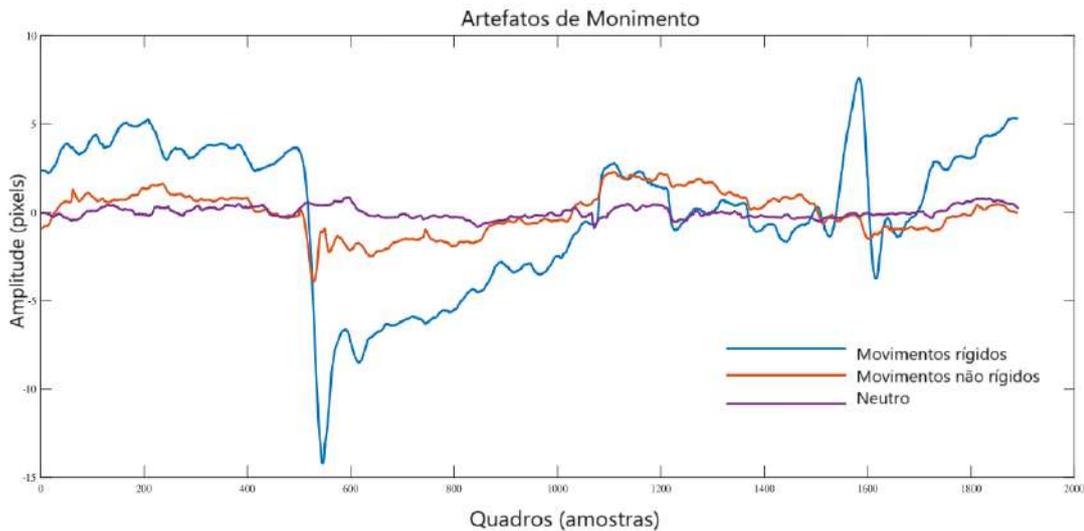
Ainda que as variáveis correspondentes a iluminação sejam constantes, o ruído luminoso pode ocorrer devido a movimentos musculares da face e/ou pelo movimento da postura corporal. A título de exemplo, estando a face da pessoa em uma região escura de um determinado ambiente e fazendo essa pessoa uma movimentação que leve seu rosto para uma região mais luminosa, haverá, em consequência disso, um desvio nos valores de intensidade dos pixels dos frames capturados pela câmera, o que contamina as informações encontradas no sinal (Hassan *et al.*, 2017). Dessa forma, ações como, falar, sorrir, caminhar e virar o rosto podem impactar na confiabilidade dos dados vitais obtidos. Um exemplo de interferência é a saturação de cores que pode ocorrer devido ao movimento dos participantes do teste do algoritmo de controle de exposição supracitado (Laurie *et al.*, 2020). Outros casos incluem a redução na precisão da medição da FC por um robô equipado com câmera de vídeo, cujo objetivo era monitorar os sinais vitais de idosos (Stricker; Müller; Gross, 2014), e a dificuldade em diferenciar arritmias cardíacas de ruídos provenientes dos movimentos dos pacientes, devido à similaridade entre os sinais (van Esch *et al.*, 2023).

Os artefatos de movimento são categorizados em dois tipos: movimentos rígidos e movimentos não rígidos. Os movimentos rígidos são ocasionados por mudanças de postura do corpo e qualquer outro tipo de movimento corporal que ocasione na translação e/ou rotação da cabeça, enquanto que os movimentos não rígidos são aqueles que causam deformação na face analisada, como sorrir, falar, bocejar, piscar os olhos, e expressões faciais no geral (Hassan *et al.*, 2017; Chen *et al.*, 2019). Para facilitar o entendimento, vale adiantar aqui um conceito muito importante no contexto da rPPG, mas que será abordado melhor na seção 2.3, a região de interesse. Essa região é a localidade da pele, normalmente na face da pessoa, em que é extraído o sinal PPG, como por exemplo: testa, queixo, bochechas e nariz. Devido aos artefatos de movimento, o ROI está suscetível à deformação e até mesmo oclusão, causando flutuações nas intensidades dos pixels durante a aferição. Essas flutuações possuem características diferentes para movimentos rígidos e não rígidos como mostra a figura 2.10. Os desvios na magnitude do sinal, de diferentes intensidades para cada caso, ressaltam a necessidade de tratamento desse problema.

Muitos estudos contornam o problema posicionando as pessoas na frente de uma câmera estática e as orientando a não realizar nenhum movimento durante a aquisição dos dados (Pirzada; Wilde; Harris-Birtill, 2024). Em primeira instância, para casos de movimentos mínimos, uma seleção manual da região de interesse pode ser realizada em cada quadro capturado (Verkruyse; Svaasand; Nelson, 2008; Balakrishnan; Durand; Guttag, 2013; Lewandowska *et al.*, 2011a). Essa situação é inviável para ser reproduzida em um ambiente real, onde há fala, expressões faciais, movimento da cabeça e outros gestos que são fonte de ruídos, podendo invalidar as aferições feitas por esses métodos. Além disso, a seleção manual do ROI tira a eficiência temporal e automática da metodologia, acarretando em outros problemas de implementação.

Uma maneira simples de reduzir o ruído do movimento é utilizando a detecção e

Figura 2.10 – Diferenciação entre as interferências causadas por movimentos rígidos e não rígidos na fotopletismografia remota.



Fonte: Adaptado de Hassan *et al.* (2017)

rastreamento confiável da ROI em cada quadro. Com o avanço da visão computacional nos últimos anos, técnicas cada vez mais precisas garantem confiabilidade na implementação dessa vertente metodológica, superando até mesmo a necessidade da orientação frontal da face (Asthana *et al.*, 2014). Essa abordagem pode ser considerada como uma forma de compensação de movimentos rígidos (Cheng *et al.*, 2017; Li *et al.*, 2014; Feng *et al.*, 2015). Quanto aos movimentos não rígidos, cada ROI possui uma propensão diferente a realizá-los. Enquanto regiões como olhos e bocas são mais propensas ao movimento, testa e bochechas são relativamente estacionárias (Chen *et al.*, 2019; Shan; Yu, 2013). Dessa forma, uma maneira de usar a detecção e rastreamento facial para diminuir a interferência dos movimentos não rígidos é selecionar para a análise e extração do sinal PPG apenas as regiões relativamente mais estáticas da face (Poh; McDuff; Picard, 2010; Li *et al.*, 2014). Como será visto na seção 2.3, a problemática de qual região da face fornece um sinal de melhor qualidade já é objeto de estudo em algumas pesquisas.

A abordagem da detecção e seleção do ROI é um tratamento simples para os artefatos de movimento, mas está longe de garantir bons resultados individualmente. Métodos baseados em modelo ou em separação cega de fontes são as principais formas de se tentar minimizar efetivamente os ruídos de movimento e podem inclusive ser utilizados juntamente com a detecção do ROI (Chen *et al.*, 2019). A título de exemplo, baseado na ideia de que a proporção de dois canais de cor normalizados não seria afetada pelo movimento da luz porque intensidades diferentes afetariam todos os canais igualmente, pesquisadores desenvolveram uma forma de relacionar linearmente os canais RGB denominada chrominance

model (CHROM). Uma comparação experimental com métodos de separação cega de fontes, Análise de Componentes Independentes (ICA) e Análise de Componentes Principais (PCA), mostrou superioridade do CHROM para movimentos de exercício (Haan; Jeanne, 2013). Várias variações metodológicas são possíveis, pode-se explorar, por exemplo, a redundância espacial dos sensores de imagem, ainda com base no método CHROM, para identificar o que é ruído de movimento e o que é sinal útil (Wang; Stuijk; Haan, 2015b). Um melhor detalhamento dos métodos já desenvolvidos pode ser visto na seção 2.4.

Assim como para o caso do ruído de iluminação, os artefatos de movimento representam ainda um grande desafio a ser superado. O quão eficientes os métodos de tratamento do sinal devem ser depende muito das circunstâncias de aplicação dessa nova tecnologia. É óbvio que aplicações em que os indivíduos costumam se movimentar com mais frequência e intensidade necessitam de um processo de tratamento mais robusto.

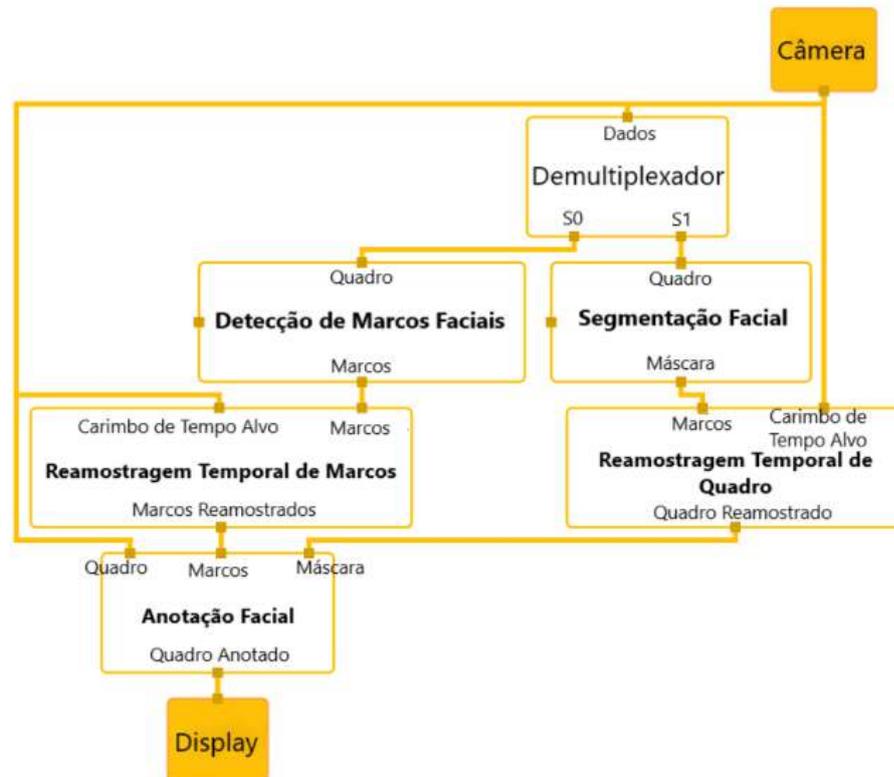
2.2 Visão Computacional

A visão computacional, também chamada de visão artificial, é um campo da inteligência artificial que se dedica à análise de imagens, seja para a extração de informações, seja para a identificação de objetos. Essa área, em constante expansão nos últimos anos, tem sido amplamente utilizada em aplicações como reconhecimento de pessoas, assinaturas e objetos. Para o seu desenvolvimento, são utilizados bancos de dados que, por meio de técnicas de inteligência artificial, permitem compreender visualmente o ambiente, reconhecer padrões e extrair informações relevantes (Conci; Azevedo; Leta, 2022).

Como mencionado, a visão computacional é uma área em crescimento acelerado, o que possibilitou, ao longo dos anos, o surgimento de diversos algoritmos voltados à análise de imagens proposta por essa tecnologia. A seguir, são apresentados alguns dos algoritmos mais utilizados atualmente para detecção de objetos e reconhecimento facial.

- **MediaPipe:** Foi projetado para a prototipagem rápida de pipelines de percepção com modelos de inferência e outros componentes reutilizáveis. Além de facilitar a implementação da tecnologia da percepção para aplicativos em diferentes plataformas. Este possui uma facilidade em reutilizar os próprios componentes em diferentes pipelines, já que compartilham de uma interface comum orientada em torno de dados de séries temporais. Cada pipeline pode ser executado com o mesmo comportamento em uma variedade de plataformas, permitindo o desenvolvimento do aplicativo em diferentes estações de trabalho, como aparelhos móveis, computadores etc. O MediaPipe consiste em três partes principais: (a) uma estrutura para inferência a partir de dados sensoriais, (b) um conjunto de ferramentas para avaliação de desempenho e (c) uma coleção de componentes de inferência e processamento reutilizáveis chamados calculadoras (Lugaresi *et al.*, 2019).

Figura 2.11 – Pipeline de funcionamento do modelo de detecção e rastreamento facial MediaPipe.



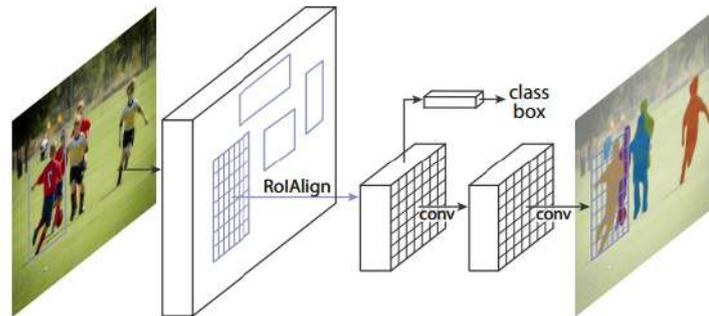
Fonte: Adaptado de [Lugaresi et al. \(2019\)](#)

Na figura 2.11, as caixas transparentes apresentam os nós de computação (calculadoras) em um gráfico MediaPipe. As caixas sólidas representam a entrada, que pode ser a câmera, vídeo ou imagem, e a saída externa para o gráfico, representada como o display. As linhas que entram na parte superior e que saem da parte inferior dos nós representam os fluxos de entrada e saída. Desta forma, é possível entender melhor o processo do pipeline para detecção e rastreamento de facial.

- **You only look once (YOLOv3):** É um sistema de detecção de objetos em tempo real que utiliza uma única rede neural à imagem completa. Diferentemente de outros sistemas baseados em classificadores, ele considera o contexto global da imagem para as suas previsões. Essa rede divide a imagem em regiões e prevê caixas delimitadoras e probabilidades para cada região. Dessa forma, é considerado um sistema de detecção prévia que redireciona classificadores para realizar a detecção, aplicando o modelo a uma imagem em vários locais e escalas. A partir disso, as regiões de alta pontuação são consideradas detecções ([Redmon; Farhadi, 2018](#)).
- **Faster R-CNN e Mask R-CNN:** Faster R-CNN é um sistema avançado de detecção de objetos que utiliza a Region Proposal Network (RPN), uma rede convolucional que gera propostas de caixas delimitadoras, calculando tanto a probabilidade de um objeto

estar presente quanto as coordenadas da caixa delimitadora (Ren *et al.*, 2015). O Mask R-CNN expande o Faster R-CNN ao adicionar uma ramificação para prever máscaras de segmentação em cada região de interesse, em paralelo com a ramificação existente de classificação e regressão da caixa delimitadora (class box), como mostrado na figura 2.12, (He *et al.*, 2017).

Figura 2.12 – A estrutura Mask R-CNN para segmentação de instância.



Fonte: (He *et al.*, 2017)

- Dlib: É uma biblioteca de software de código aberto multiplataforma escrita em C++ que inclui ferramentas de aprendizado de máquina para desenvolvimento. A biblioteca é composta por quatro componentes principais, a álgebra linear, ferramentas de aprendizado de máquina, otimização e redes Bayesianas (King, 2009).

2.2.1 Detecção e Rastreamento Facial

Conforme ressaltado em tópicos anteriores, as frequências cardíaca e respiratória são indicadores vitais fundamentais na detecção e prevenção de inúmeras doenças. Uma abordagem eficiente para a aquisição dessas frequências é a rPPG, que, como descrito na seção 2.1.1, pode ser realizada à distância utilizando câmeras. Assim, ao adquirir um vídeo, o rosto da pessoa deve ser detectado e rastreado para garantir que o sinal capturado seja proveniente da mesma ROI em todos os quadros do vídeo. Em outras palavras, é essencial preservar a continuidade entre os quadros. Por isso, a eficiência do algoritmo utilizado na detecção e rastreamento facial é um fator crucial.

Atualmente, diversos estudos exploram a rPPG utilizando diferentes algoritmos de rastreamento facial. Em um desses estudos, foi empregada uma combinação dos algoritmos Haar Cascade e Dlib Toolkit para detectar caixas delimitadoras faciais e obter 68 pontos de referência facial pré-treinados, permitindo o recorte das regiões selecionadas da ROI (Premkumar; Hemanth, 2022). Outros trabalhos utilizaram o algoritmo Haar Cascade Classifier para calcular o estresse por meio da variabilidade da frequência cardíaca (Nikolaiev; Telenyk; Tymoshenko, 2023), bem como para a detecção de faces (Maestre-Rendon *et al.*,

2020). Adicionalmente, pesquisas compararam os algoritmos Dlib e MTCNN, indicando que o Dlib apresentou maior precisão (Fahim, 2024). Estudo semelhante comparou os modelos MTCNN, YOLOv3, Dlib e RetinaFace, concluindo que MTCNN e RetinaFace foram mais precisos do que Dlib e YOLOv3 (Smelyakov *et al.*, 2021). Em outra análise, a comparação entre MTCNN e YOLOv3 demonstrou que o MTCNN foi mais acurado.

Embora haja muitos estudos na área, não existe uma padronização nos testes realizados, o que gera resultados variados. Nesse contexto, (Jayasinghe; Katsigiannis; Malasinghe, 2023) propôs uma padronização para avaliar algoritmos de detecção e rastreamento facial para rPPG, considerando a facilidade de aquisição da ROI, o tempo de processamento e a acurácia na análise da frequência cardíaca. Nesse estudo, foram examinados os modelos MediaPipe Face Mesh (MPFM), derivado da biblioteca MediaPipe, Haar Cascade, MTCNN e Dlib. Os resultados indicaram que o MPFM apresentou a melhor acurácia, seguido pelo Dlib; o menor tempo de processamento foi alcançado pelo MPFM, seguido pelo Haar Cascade; e a maior facilidade de seleção da ROI também foi obtida pelo MPFM, seguido pelo Dlib.

O MediaPipe oferece várias APIs e bibliotecas multiplataformas para diferentes tipos de soluções. Uma dessas ferramentas é o MediaPipe Face Landmark, cuja pipeline é ilustrada na Figura 2.11. Ele realiza a detecção de pontos de referência facial junto com a segmentação de retratos. Para reduzir a carga computacional necessária para executar essas duas tarefas simultaneamente, adota uma estratégia que aplica as operações em dois subconjuntos de quadros. O MediaPipe alcança isso por meio de um nó de desmultiplexação, que divide os pacotes do fluxo de entrada em subconjuntos intercalados, direcionando cada subconjunto a um fluxo de saída distinto (Lugaresi *et al.*, 2019).

2.3 Região de Interesse

Na rPPG, a ROI corresponde à área da imagem capturada onde está localizada a pele selecionada para processamento e análise. Uma ROI muito grande demanda altos recursos computacionais, como memória e tempo de processamento, especialmente em implementações de hardware mais simples, onde o tempo de processamento é um fator limitante para a obtenção de medidas em tempo real. Além disso, ao utilizar câmeras de alta resolução, trabalhar com regiões extensas pode se tornar computacionalmente custoso (Kwon *et al.*, 2015).

Outro aspecto crucial na definição da melhor ROI é o ruído presente na imagem. ROIs menores apresentam maior quantidade de ruído de quantização, gerado na conversão de vídeo. Por outro lado, áreas menores sofrem menos interferência causada por iluminação irregular (Wang, 2021). A anatomia da pele humana também influencia a qualidade do sinal obtido, uma vez que variáveis como a capacidade de absorção do pulso sanguíneo e a presença de pelos podem afetar os resultados.

No contexto da rPPG, alguns estudos consideram como ROI toda a região do rosto (Poh; McDuff; Picard, 2010; Qi; Wang; Miao, 2015; Bousefsaf; Maaoui; Pruski, 2013), enquanto outros analisam áreas específicas, como a testa (Verkruyse; Svaasand; Nelson, 2008), as bochechas (Caroppo *et al.*, 2024) ou combinações dessas regiões (Haugg; Elgendi; Menon, 2023).

Kwon *et al.* (2015) realizaram uma análise detalhada das regiões faciais para identificar aquelas que apresentavam maior qualidade de sinal rPPG e eficiência. Foram avaliadas áreas como testa, bochechas (esquerda e direita), nariz, boca e queixo, em indivíduos com cabelo preso e sem barba. Os testes utilizaram métricas como razão SNR, coeficiente de correlação, além de sua média e desvio padrão, para identificar as melhores regiões. Constatou-se que áreas superiores da face geralmente apresentam sinais de melhor qualidade, enquanto as regiões inferiores raramente possuem sinais de alta qualidade. Na testa, o meio da região apresentou melhor qualidade, enquanto a ponta teve sinais de baixa qualidade. Nas bochechas, áreas sob os olhos apresentaram boa qualidade de sinal em diversos indivíduos, embora as bordas geralmente fossem de qualidade inferior.

Além de segmentar a ROI em regiões específicas da face, outros estudos analisam a divisão da ROI em pequenos pedaços (patches) para selecionar as áreas ideais. O fluxograma do método proposto é apresentado na Figura 2.13. De acordo com Wang (2021), muitas abordagens utilizam SNR, intensidade e variação de luz para selecionar a ROI ideal. Outras utilizam a Análise de Espectro Singular (SSA), um método capaz de extrair componentes oscilatórios de séries temporais (Ghil *et al.*, 2002), combinado com métodos de sub-banda para estimar a frequência cardíaca mesmo sob variações de iluminação.

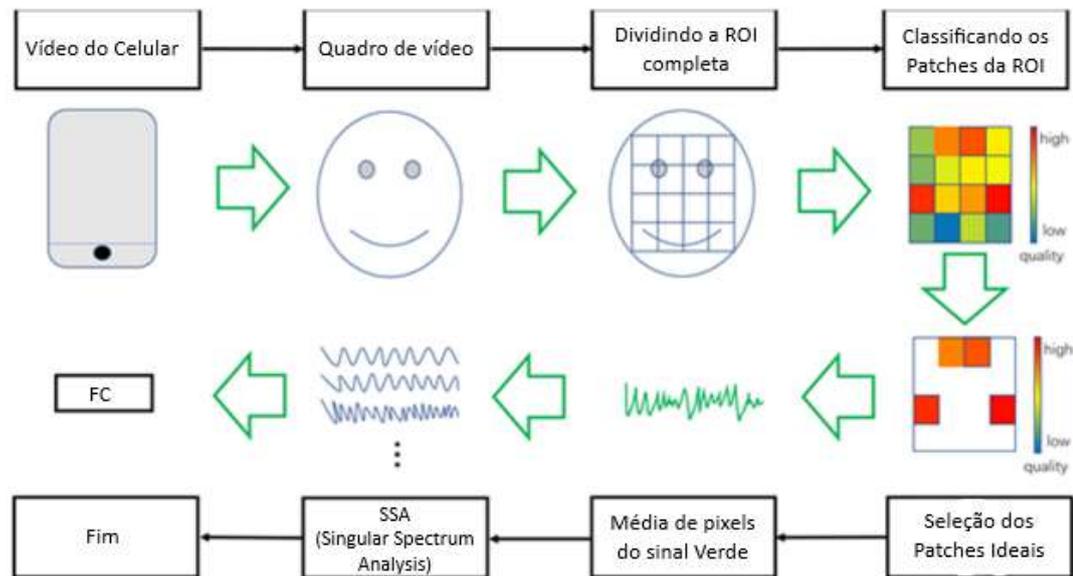
Wang (2021) destacam que a seleção de ROIs muito pequenas aumenta a interferência de ruído de quantização, enquanto ROIs muito grandes sofrem com maior interferência de iluminação irregular. Adicionalmente, o desempenho do SSA tende a se deteriorar em áreas maiores devido à presença de ruído de iluminação nas regiões periféricas. Assim, enquanto ROIs pequenas são mais suscetíveis ao ruído de quantização, ROIs extensas enfrentam desafios relacionados à iluminação desigual, sendo necessário um equilíbrio na seleção das regiões.

2.4 Implementações de Fotopletismografia Remota

O campo da fotopletismografia remota está em crescimento nos últimos anos e um grande número de abordagens tem sido desenvolvidas visando superar desafios de variação de luminosidade, artefatos de movimento e outros fatores que podem comprometer a precisão das medições.

A padronização das metodologias desenvolvidas ainda é pequena, o que pode ser um problema na comparação de eficiência entre implementações distintas. Apesar disso, alguns

Figura 2.13 – Fluxograma do método proposto.



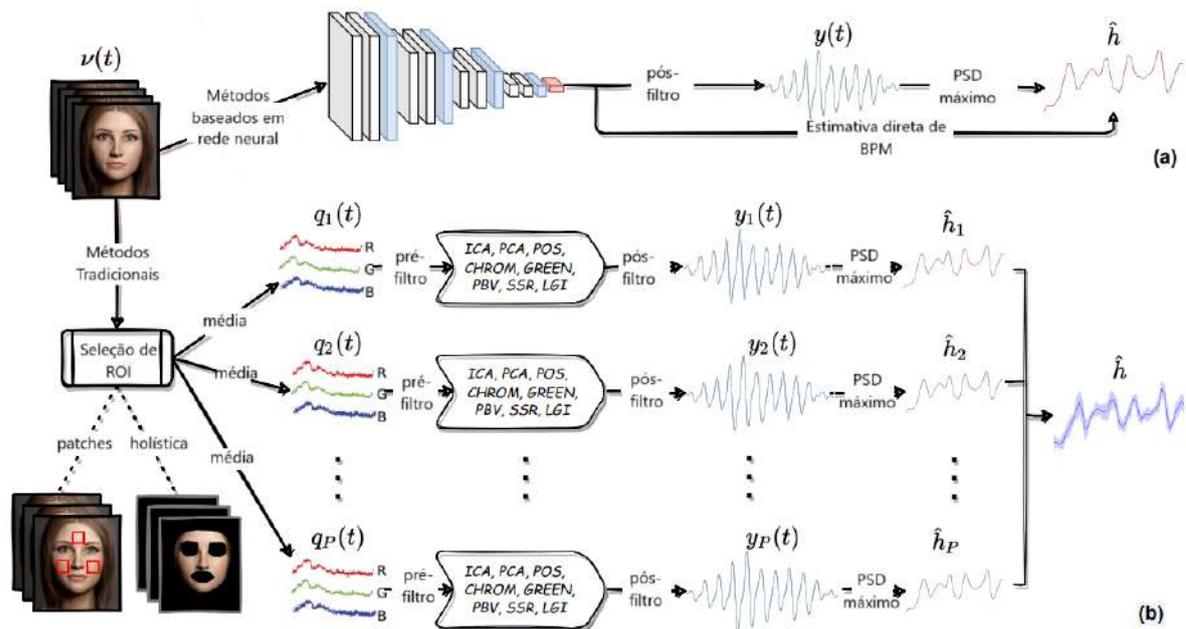
Fonte: Adaptado de Wang (2021)

autores elencam etapas frequentes que se fazem presentes em grande parte dos estudos, como seleção do ROI, pré-processamento, método rPPG, pós-processamento e estimativa da frequência de pulso (Unakafov, 2018). Tendo como base essa tentativa de classificação, alguns frameworks voltados à rPPG foram desenvolvidos, como é o caso do pyVHR, uma biblioteca de código aberto em Python que disponibiliza ferramentas para o estudo da aferição da frequência cardíaca (Boccignone *et al.*, 2022). A figura 2.14 mostra a forma como esse framework organiza as etapas de uma implementação rPPG. A primeira observação a ser feita é a diferenciação entre métodos tradicionais e métodos baseados em aprendizado de máquina.

Nos últimos anos, a inteligência artificial tem sido utilizada para solucionar os mais variados problemas tecnológicos, e o caso da rPPG não é diferente (Pirzada; Wilde; Harris-Birtill, 2024; Liu *et al.*, 2021). Implementações baseadas em aprendizado de máquina oferecem uma abordagem ponta a ponta, em que a entrada é normalmente constituída dos quadros capturados $v(t)$ e a saída é o sinal PPG $y(t)$, também denominado como Blood Volume Pulse (BVP), e/ou a estimativa da frequência cardíaca \hat{h} . Mesmo sendo simples e tendo uma boa acurácia, implementações desse tipo ainda possuem desafios a serem superados. O treinamento dos modelos, realizado com uma enorme quantidade de dados, exige um alto custo computacional, e mesmo depois de treinados, ainda requerem uma quantidade significativa de recursos.

Além disso, há questões críticas relacionadas ao viés da inteligência artificial e à capacidade de generalização dos modelos. Muitas vezes, os conjuntos de dados utilizados no

Figura 2.14 – Processo de obtenção de estimativas de frequência cardíaca utilizando o pipeline do framework pyVHR.



Fonte: Adaptado de [Boccignone et al. \(2022\)](#)

treinamento não são suficientemente diversos, o que pode levar a modelos que funcionam bem apenas em condições específicas ou para certos grupos de pessoas, mas falham em se generalizar para diferentes cenários, como variações de etnia, idade, iluminação ou movimentos faciais. Esse viés pode comprometer a confiabilidade dos sistemas de rPPG, o que se demonstra preocupante em aplicações de saúde ([Pirzada; Wilde; Harris-Birtill, 2024](#)).

Outro problema é que poucas soluções têm sido disponibilizadas publicamente, tanto em termos de código quanto de pesos dos modelos treinados. Isso levanta preocupações sobre a reprodutibilidade dos resultados e dificulta a avaliação independente da eficácia dos métodos. Sem o acesso a esses recursos, a comunidade científica enfrenta desafios para validar, comparar e melhorar as técnicas existentes ([Boccignone et al., 2022](#)).

O segundo lado da dicotomia estabelecida são os métodos tradicionais, implementados por meio de um pipeline. A primeira etapa consiste na extração das regiões de interesse, de onde será retirado o sinal PPG. A seleção pode ser holística, e considerar toda a pele do rosto da pessoa ou pode considerar apenas sub regiões denominadas patches.

Após isso, as regiões selecionadas são utilizadas para calcular os sinais brutos correspondentes aos canais de cor RGB. O sinal obtido do i -ésimo patch (sub região) é denominado $q_i(t)$ e é calculado como sendo a média espacial dos valores dos pixels que o compõem. Matematicamente:

$$q_i(t) = \frac{1}{N_i} \sum_{j=1}^{N_i} p_i^j(t), \quad i = 1, \dots, P. \quad (2.3)$$

Onde $p_i^j(t)$ é a intensidade de cor do j -ésimo pixel do patch i e N_i é o número de pixels pertencentes ao i -ésimo patch no tempo t . Para o caso holístico, em que toda a pele do rosto é analisada, o valor de P é igual a 1.

Para proporcionar dinamicidade ao pipeline durante a aferição, os quadros são agrupados em forma de janelas sobrepostas. Isso permite que o sinal $q_i(t)$ seja calculado continuamente para cada janela formada, fornecendo uma atualização periódica da frequência cardíaca durante a execução do algoritmo.

Uma etapa opcional de pré-filtragem pode ser adicionada visando melhorar a qualidade dos sinais brutos obtidos. Normalização e remoção de tendências são exemplos de procedimentos a serem usados. A filtragem passa-faixa é outro tratamento comumente utilizado, dado que a frequência cardíaca possui uma faixa de valores possíveis, isso permite eliminar ruídos de alta e baixa frequência.

O próximo passo é utilizar os valores $q_i(t)$ para obter o sinal PPG. Na literatura é possível encontrar diversas maneiras de executar essa tarefa. Um dos casos mais simples é o método GREEN (Verkruysse; Svaasand; Nelson, 2008). Dado que $R_i(t)$, $G_i(t)$ e $B_i(t)$ representam respectivamente os canais de cores vermelho, verde e azul de um sinal $q_i(t)$, o método GREEN pode ser expresso da seguinte forma:

$$y_i(t) = G_i(t). \quad (2.4)$$

Alguns métodos são baseados em separação cega de fontes (BSS), como é o caso da ICA (Poh; McDuff; Picard, 2010). Essa abordagem trata o sinal $q_i(t)$ como uma composição do sinal PPG adicionado aos sinais emitidos por fontes de ruído e busca fazer a separação destes sem nenhuma informação prévia a respeito do processo de mistura. Considerando $q_i(t) = A \cdot Z(t)$, onde A é uma matriz sem memória de mistura das fontes $Z(t) = [z_1(t), z_2(t), z_3(t)]^T$, uma matriz estimada $W = A^{-1}$ é usada para a realização da separação. Normalmente, a fonte de sinal correspondente ao sinal PPG é aquela mais periódica. Considerando essa como sendo $z_2(t)$, tem-se que:

$$y_i(t) = z_2(t). \quad (2.5)$$

Enquanto a ICA busca separar os sinais considerando uma independência estatística, outro método, denominado PCA (Lewandowska *et al.*, 2011b), propõe uma redução de dimensionalidade por meio da maximização da variância. A ideia é encontrar os componentes $c_1(t), c_2(t), \dots, c_N(t)$ de $C(t)$ com a maior quantidade de variância para N componentes. Os componentes são obtidos da seguinte forma:

$$C(t) = W^T \cdot q_i(t). \quad (2.6)$$

A matriz W é estimada pelo método e representa a matriz de mistura. Normalmente, o segundo componente é considerado o sinal PPG:

$$y_i(t) = c_2(t). \quad (2.7)$$

Os métodos Plane Orthogonal to the Skin (POS) (Wang *et al.*, 2017a) e CHROM (Haan; Jeanne, 2013) utilizam de modelos ópticos para tentar melhorar a obtenção do sinal PPG a partir de $q_i(t)$. Para o caso do CHROM, normaliza-se cada canal de cor de $q_i(t)$ dividindo suas amostras pela média sobre um intervalo temporal. Isso produz os canais normalizados $R_{ni}(t)$, $G_{ni}(t)$ e $B_{ni}(t)$. O sinal PPG é dado por:

$$y_i(t) = X_{F1}(t) - \alpha X_{F2}(t). \quad (2.8)$$

Sendo que $X_{F1}(t)$ e $X_{F2}(t)$ correspondem aos resultados de $X_{S1}(t)$ e $X_{S2}(t)$ quando submetidos a um filtro passa-faixa. Esses, por sua vez, são definidos como:

$$X_{S1}(t) = 3R_{ni}(t) - 2G_{ni}(t), \quad X_{S2}(t) = 1.5R_{ni}(t) + G_{ni}(t) - 1.5B_{ni}(t). \quad (2.9)$$

O coeficiente α é dado pela razão entre os desvios padrão de $X_{F1}(t)$ e $X_{F2}(t)$ durante a janela de tempo analisada:

$$\alpha = \frac{\sigma(X_{F1})}{\sigma(X_{F2})}. \quad (2.10)$$

O método POS possui uma abordagem parecida e também usa os canais normalizados de $q_i(t)$. Para o caso do POS, o sinal PPG é dado por:

$$y_i(t) = Q_1(t) - \alpha Q_2(t). \quad (2.11)$$

Sendo que:

$$Q_1(t) = G_{ni}(t) - B_{ni}(t), \quad Q_2(t) = G_{ni}(t) + B_{ni}(t) - 2R_{ni}(t). \quad (2.12)$$

O coeficiente α é dado pela razão entre os desvios padrão de $Q_1(t)$ e $Q_2(t)$ durante a janela de tempo analisada:

$$\alpha = \frac{\sigma(Q_1)}{\sigma(Q_2)}. \quad (2.13)$$

Esses são alguns exemplos de métodos dentre os vários que podem ser encontrados na literatura. Além desses, a biblioteca pyVHR também implementa PBV (Haan; Leest, 2014), Invariância de Grupo Local (LGI) (Pilz *et al.*, 2018) e Rotação Espacial de Subespaço (SSR) (Wang; Stuijk; Haan, 2015a). O pipeline ainda prevê uma pós-filtragem opcional, na qual é possível filtrar o sinal PPG obtido com um filtro de banda estreita para eliminar frequências fora da banda de interesse.

O sinal $y_i(t)$ é o sinal PPG obtido para o i -ésimo patch em uma determinada janela de tempo. Durante a execução do programa, várias janelas temporais são utilizadas para estimar a frequência cardíaca em diferentes momentos. Dessa forma, define-se $y_i^k(t)$ como o sinal PPG do patch i associado à k -ésima janela temporal.

O método de Welch é utilizado para se obter $S_i^k(v)$, o espectro de potência associado a $y_i^k(t)$. A frequência cardíaca da janela k é definida como o valor de frequência entre 39 e 240 bpm onde o espectro de potência atinge seu valor máximo. Esse processo fornece a estimativa \hat{h}_i^k .

Nesta etapa têm-se um conjunto de várias estimativas de BPM para cada janela de tempo e para cada patch. Considerando o número de patches igual a P , uma estimativa final de BPM pode ser calculada por meio da mediana dos valores estimados em cada patch, fornecendo assim uma estimativa final para o instante de tempo da janela temporal. Definindo H^k como a lista ordenada das P previsões de BPM provenientes de cada patch para a k -ésima janela temporal, tem-se que a frequência cardíaca \hat{h}^k pode ser definida como:

$$\hat{h}^k = \text{mediana}(H^k) = \begin{cases} H^k \left[\frac{P-1}{2} \right], & \text{se } P \text{ for ímpar,} \\ \frac{1}{2} (H^k \left[\frac{P}{2} - 1 \right] + H^k \left[\frac{P}{2} \right]), & \text{se } P \text{ for par.} \end{cases} \quad (2.14)$$

Nota-se que se a solução holística for adotada, ou seja, $P = 1$, o valor do BPM tomado será o próprio valor estimado para a região de interesse.

Esse é o pipeline implementado pelo framework pyVHR, desenvolvido para facilitar a comparação entre diferentes metodologias de aferição da frequência cardíaca. Apesar de implementar uma gama de realizações possíveis, o pipeline apresentado está longe de englobar todas as metodologias desenvolvidas. Alguns exemplos da ampla variedade de algoritmos que os estudos da área utilizam são: Joint Blind Source Separation (JBSS) (Chen *et al.*, 2019), Transformada de Wavelet (Bousefsaf; Maaoui; Pruski, 2013), combinação de BSS com técnicas de aprendizado de máquina (Monkaresi; Calvo; Yan, 2014), Laplacian Eigenmap (LE) (Wei *et al.*, 2013), Ampliação Euleriana de Vídeo (EVM) (Rodrigues; Pereira; Pádua, 2016; Wu *et al.*, 2012) e algoritmo de controle de exposição (Laurie *et al.*, 2020).

A exposição desse pipeline teve o intuito de trazer uma ideia sobre os processos envolvendo algoritmos de rPPG. Trata-se de uma maneira simples de implementação e que pode ser aprimorada. Por exemplo, usar um algoritmo de detecção de picos ao invés de análise espectral no sinal PPG poderia possibilitar a estimativa não somente da frequência

cardíaca como da variabilidade da frequência cardíaca (HRV) (Balaraman; Claret, 2023). Outra ideia seria dar pesos aos sinais de cada patch considerando a propensão das regiões faciais de produzirem sinais mais ou menos ruidosos (Kumar; Veeraraghavan; Sabharval, 2015). Um exemplo de possível sofisticação baseada neste pipeline é uma modificação do próprio framework (dhananjay1710, 2024). Esta API (Application Programming Interface) não só realiza a estimativa da frequência cardíaca a partir de vídeos utilizando algoritmos de rPPG, como também oferece a capacidade de estimar a saturação de oxigênio (SpO2) e as incursões respiratórias (taxa de respiração - BR).

Vale à pena citar aqui também outras metodologias que estão além do pipeline detalhado, e que inclusive já foram melhor explicadas na subseção 2.1.6. Quanto à seleção de ROI, por exemplo, além de rosto, outras regiões podem ser usadas, como a palma da mão (Sun *et al.*, 2012) e a região de fundo, usada como referência para a eliminação de ruídos (Li *et al.*, 2014; Cheng *et al.*, 2017). Além disso, situações como monitoramento de várias pessoas, monitoramento com várias câmeras e o uso do espaço YCrCb ao invés do RGB estão além do escopo do modelo apresentado (Chen *et al.*, 2019). O hardware utilizado e as condições experimentais também diversificam as metodologias encontradas na literatura, como por exemplo o uso de câmeras infravermelhas/térmicas e dispositivos de carga acoplada (Haan; Jeanne, 2013; Jeanne *et al.*, 2013; Gastel; Stuijk; Haan, 2015; Zhao *et al.*, 2013; Wang; Shan, 2020), o uso de iluminação artificial (Wang; Shan, 2020; Lin *et al.*, 2017) e a distância de aferição (Pirzada; Wilde; Harris-Birtill, 2024).

A conclusão que se pode tirar é que, embora o campo esteja progredindo significativamente, há ainda muito espaço para inovação e refinamento. O desenvolvimento de métodos mais precisos, acessíveis e generalizáveis, combinados com a disponibilidade de código aberto e a transparência na divulgação de modelos treinados, será crucial para o futuro da rPPG.

3 Desenvolvimento

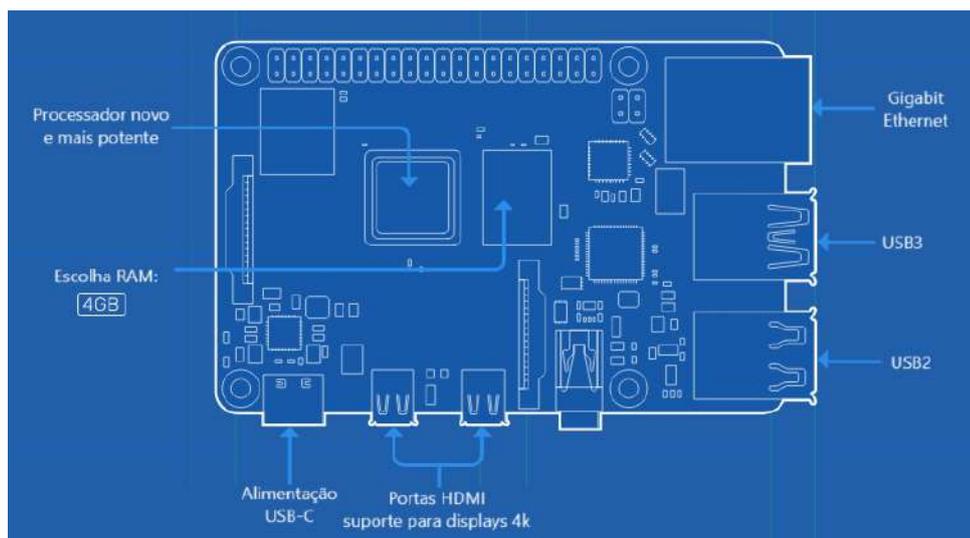
3.1 Seleção do Hardware e Software

3.1.1 Hardware

O hardware escolhido como base para o desenvolvimento do dispositivo de fotopletiografia remota foi o Raspberry Pi 4 Model B. Essa escolha se justifica por diversos fatores, como seu desempenho, versatilidade, suporte a interfaces diversas e acessibilidade econômica.

Originalmente lançado em 2019, o Raspberry Pi 4 apresenta avanços significativos em relação às versões anteriores. Ele é equipado com um processador quad-core ARM Cortex-A72 de 64 bits, operando a 1,5 GHz, e suporta até 8 GB de memória RAM, sendo 4 GB no modelo utilizado neste projeto. Além disso, oferece uma ampla gama de interfaces de conectividade, incluindo portas USB 3.0, Ethernet Gigabit, Wi-Fi de banda dupla (2,4/5,0 GHz), Bluetooth 5.0 e GPIOs (General Purpose Input/Output) para comunicação com sensores e atuadores. Esses recursos tornam o Raspberry Pi 4 ideal para uma variedade de aplicações, incluindo projetos de automação, Internet das Coisas (IoT) e dispositivos biomédicos (Upton; Halfacree, 2014; Foundation, 2019; Ltd, 2024). A figura 3.1 mostra a especificação técnica que foi detalhada.

Figura 3.1 – Disposição dos elementos de hardware no dispositivo Raspberry Pi 4.



Fonte: Adaptado de Ltd (2024)

Uma das vantagens notáveis dessa plataforma é sua capacidade de realizar tarefas de processamento em tempo real, necessárias para análise de sinais biomédicos, enquanto

permite integração com outros sistemas. Mesmo que nem todos os recursos do dispositivo sejam utilizados inicialmente, a possibilidade de expansão futura garante que o hardware possa atender a necessidades adicionais sem grandes modificações. Além disso, sua arquitetura ARM e recursos computacionais modestos tornam os softwares desenvolvidos para o Raspberry Pi altamente portáteis e compatíveis com sistemas mais robustos, como laptops e desktops baseados em x86.

Outro fator relevante é a vasta comunidade de desenvolvedores em torno do Raspberry Pi, que oferece suporte através de documentações, bibliotecas de software e projetos já implementados. Esse ecossistema colaborativo mitiga desafios técnicos e acelera o desenvolvimento de novos projetos (Richardson; Wallace, 2012). O custo inicial acessível (cerca de 35 dólares) também contribui para sua popularidade, especialmente em projetos acadêmicos que demandam soluções tecnológicas de ponta com viabilidade econômica.

No desenvolvimento do protótipo de fotopletismografia remota, foi utilizada a câmera Raspberry Pi Camera Module 3. Este módulo possui um sensor CMOS Sony IMX708 de 12 megapixels, com foco automático por detecção de fase (PDAF), suporte ao modo HDR e resolução de até 4608×2592 pixels. A câmera utiliza a interface MIPI CSI-2, que oferece maior largura de banda (até 10 Gb/s) e menor latência na transmissão de dados, comparada às câmeras USB. Isso garante alta qualidade de imagem e precisão na captura de dados em tempo real, além de maior controle e customização sobre as configurações de captura (consystems, 2023).

A interface MIPI CSI-2 também reduz a sobrecarga na CPU, permitindo que o sistema opere de forma eficiente mesmo com recursos de hardware limitados. Isso é crucial para minimizar variações na taxa de amostragem do dispositivo e garantir a qualidade dos dados adquiridos. Comparativamente, câmeras USB são projetadas para simplicidade e facilidade de uso, com configurações limitadas, enquanto o MIPI CSI-2 permite ajustes detalhados que impactam diretamente na precisão e confiabilidade do sistema.

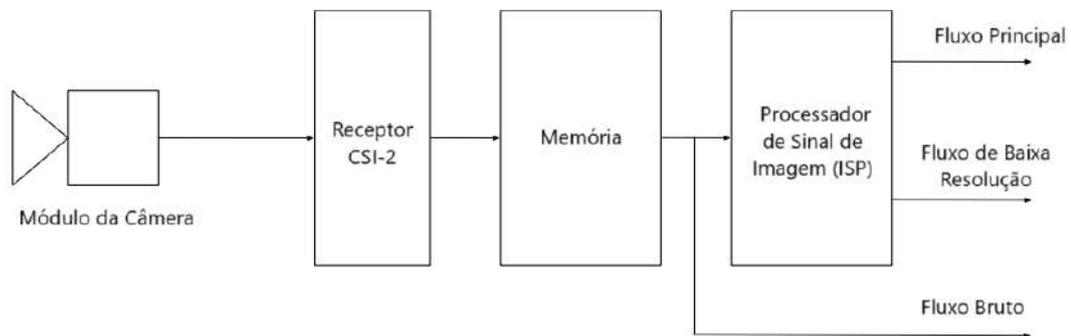
Vale destacar que a viabilização do projeto foi favorecida pela disponibilidade dos equipamentos fornecidos pela instituição. Essa acessibilidade é fundamental em cenários acadêmicos, onde restrições financeiras podem limitar o uso de dispositivos mais sofisticados. Apesar de suas limitações, o Raspberry Pi 4 se mostrou eficiente no processamento de imagens, uma tarefa que normalmente demanda recursos computacionais elevados. A CPU quad-core Cortex-A72, por exemplo, proporciona até 108.00 BogoMIPS por núcleo, permitindo que algoritmos otimizados realizem tarefas complexas de maneira eficiente.

Com essas características, o Raspberry Pi 4 Model B atende às necessidades do protótipo, demonstrando como recursos acessíveis podem ser empregados para desenvolver soluções tecnológicas inovadoras, aliando eficácia, baixo custo e flexibilidade.

3.1.1.1 Arquitetura do Sistema da Câmera

O sistema de captura de imagens utilizado em dispositivos como o Raspberry Pi emprega uma arquitetura que permite processar e entregar imagens de alta qualidade para diferentes aplicações. Como mostra a figura 3.2, o processo envolve diversas etapas, desde a recepção do sinal bruto da câmera até a disponibilização de fluxos de imagem processados, atendendo às necessidades específicas de cada uso.

Figura 3.2 – Arquitetura do sistema de captura de quadros do hardware utilizado no desenvolvimento do dispositivo.



Fonte: Adaptado de [Foundation \(2024\)](#)

Inicialmente, o módulo de câmera captura as imagens e as transmite por meio de um cabo flat para o Raspberry Pi. Contudo, as imagens enviadas não estão imediatamente prontas para visualização. Trata-se de dados brutos que necessitam de processamento significativo para se transformarem em imagens realistas e utilizáveis. O primeiro componente responsável por lidar com esses dados é o receptor CSI-2 (Camera Serial Interface 2), que transfere os dados recebidos para a memória do sistema.

Uma vez na memória, entra em ação o Processador de Sinal de Imagem (Image Signal Processor, ou ISP). Este componente é responsável por uma série de tarefas cruciais, como correção de cor, redução de ruído e ajuste de contraste. O ISP gera dois tipos de saída a partir de cada quadro recebido: a imagem principal, que pode ser configurada nos formatos RGB ou YUV, e uma versão de baixa resolução, conhecida como lores. Esta segunda saída é limitada em tamanho, sendo sempre igual ou menor que a principal. Em dispositivos mais recentes, como o Raspberry Pi 5, tanto a imagem principal quanto a lores podem estar disponíveis em formatos RGB ou YUV.

Além disso, os dados brutos recebidos do sensor podem ser armazenados diretamente na memória e disponibilizados para aplicações que necessitam de acesso às imagens sem processamento, conhecidas como imagens raw. Esses diferentes tipos de saídas permitem uma flexibilidade considerável na configuração e utilização do sistema de câmera.

A memória CMA (Contiguous Memory Allocator) desempenha um papel central

nesse processo, fornecendo espaço contínuo para armazenar os buffers usados pelos diferentes fluxos de imagem. Essa memória é compartilhada com o sistema operacional Linux, o que pode levar a fragmentações e problemas de alocação, especialmente em cenários de alta demanda. Configurações como o ajuste do tamanho da área CMA e a definição do número de buffers alocados por tipo de fluxo ajudam a mitigar esses problemas, garantindo o equilíbrio entre desempenho e estabilidade.

Por fim, o comportamento do sistema também é ajustável por meio de parâmetros específicos, como o número de buffers utilizados para capturas de imagem e o gerenciamento de filas internas no Picamera2. Por exemplo, fluxos de vídeo geralmente demandam mais buffers para evitar perdas de quadros, enquanto capturas de imagem estática podem operar com menos buffers para economizar memória. Além disso, o sistema pode reter o quadro mais recente na memória para reduzir atrasos em operações sequenciais, ou, alternativamente, configurar-se para capturar novos quadros a cada requisição, dependendo das necessidades da aplicação.

Essa arquitetura modular e configurável permite que o sistema de câmera seja otimizado para uma ampla gama de aplicações, desde transmissões ao vivo até capturas de alta resolução, equilibrando as restrições de hardware com os requisitos funcionais de cada uso.

3.1.2 Software

A linguagem de programação escolhida para o desenvolvimento do projeto foi o Python, uma decisão estratégica que leva em consideração vários aspectos. Python é amplamente reconhecido por sua sintaxe clara e intuitiva, facilitando o desenvolvimento rápido e a manutenção do código. Além disso, sua ampla biblioteca padrão e o extenso ecossistema de pacotes de terceiros oferecem soluções prontas para uma variedade de problemas, desde processamento de dados até comunicação com hardware específico. Essa versatilidade torna Python uma escolha ideal para projetos que requerem desenvolvimento ágil e integração com tecnologias diversas.

Para acessar e controlar a câmera do Raspberry Pi, foi empregada a biblioteca Picamera2. Desenvolvida como uma evolução da antiga PiCamera, a Picamera2 é construída sobre o projeto open source libcamera, que fornece suporte abrangente a sistemas de câmeras no Linux. A Picamera2 oferece uma API simplificada e poderosa, projetada para maximizar a eficiência no uso das funcionalidades da câmera. Além de ser uma escolha moderna, a biblioteca permite acesso direto a parâmetros avançados de configuração e controle, proporcionando flexibilidade e precisão no ajuste das condições de captura. Essa capacidade é especialmente importante em projetos como o presente, que dependem da qualidade do sinal de imagem para etapas subsequentes de análise.

Um dos pontos fortes da Picamera2 é a sua abordagem modular, que separa as configurações da câmera em "configurações" e "controles". As configurações definem parâmetros

gerais, como formato e resolução do fluxo de vídeo, enquanto os controles permitem ajustes dinâmicos durante a execução, como exposição, foco e balanço de branco. Nos experimentos, por exemplo, utilizou-se a configuração pré-definida criada pelo comando `picam2.create_video_configuration`, otimizada para captura de frames com alta frequência de amostragem. Essa configuração foi ajustada para o formato RGB888 com resolução de 640x480 pixels, um equilíbrio entre qualidade de imagem e carga computacional.

O controle preciso de parâmetros da câmera foi outro aspecto crucial no desenvolvimento do software. Nos primeiros testes, por exemplo, o foco contínuo, frequentemente ajustado automaticamente pela câmera, foi pausado após um ajuste inicial ideal para evitar a introdução de componentes de frequência que poderiam interferir na análise do sinal. De forma semelhante, o equilíbrio de branco automático foi desativado para garantir consistência nos valores de cor dos frames capturados, eliminando possíveis variações abruptas que poderiam comprometer a precisão do sinal obtido.

Além disso, cuidados específicos foram tomados com relação à memória e à manipulação de buffers. Os frames capturados pela câmera são armazenados temporariamente na memória contígua do Raspberry Pi (CMA), que é compartilhada com o sistema operacional. Para mitigar problemas relacionados à fragmentação ou retardo na solicitação de frames, foi implementada uma fila de maior capacidade via software, enquanto os buffers na CMA foram configurados para comportar até 15 frames. Essa estratégia garantiu que o sistema pudesse operar de forma confiável, mesmo em condições de alta demanda.

Outro aspecto relevante foi o ajuste do tempo de exposição, configurado para garantir uma determinada taxa de captura em frames por segundo (fps), sendo 30 fps um valor comum em aplicações de vídeo e suficiente para as necessidades do projeto. Uma taxa de amostragem consistente é fundamental para evitar inconsistências nos dados capturados e melhorar a qualidade do processamento subsequente.

Por fim, a integração com outras bibliotecas como OpenCV foi facilitada pelo formato de saída escolhido para os frames. A compatibilidade com ferramentas amplamente utilizadas no ecossistema Python reforça a flexibilidade do software desenvolvido, permitindo futuras expansões e ajustes com maior facilidade. Assim, a escolha da combinação entre Python e Picamera2 não apenas atende às demandas técnicas e operacionais do projeto, mas também proporciona uma base robusta e eficiente para etapas futuras.

3.1.2.1 Processamento de Imagens

Para a detecção facial, foi escolhida a utilização do modelo de rastreamento facial MPFM, considerando que, de acordo com o estudo de [Jayasinghe, Katsigiannis e Malasinghe \(2023\)](#), ele possui a melhor acurácia, o menor tempo de processamento e a maior facilidade de seleção da ROI em comparação aos outros métodos avaliados.

O MPFM faz parte de uma das APIs do MediaPipe, conhecida como MediaPipe

Face Landmarker, projetada como um marcador facial que usa uma série de modelos já treinados para prever pontos de referência de rostos. O seu processo é dividido em três etapas: o primeiro modelo detecta rostos, um segundo localiza pontos de referência nos rostos detectados e um terceiro os usa para identificar características faciais e expressões (Google AI, 2024). Neste trabalho, utilizaremos até a segunda etapa, onde o modelo de malha de rostos fornece um mapeamento completo do rosto que gera uma estimativa de 478 pontos de referência tridimensionais, como ilustrado na imagem abaixo. A figura 3.3 mostra a malha de pontos faciais que o recurso do MediaPipe é capaz de identificar. Devido a limitações da capacidade computacional do dispositivo desenvolvido, apenas alguns pontos-chave foram utilizados durante o desenvolvimento do protótipo, pois o tempo de processamento aumentaria consideravelmente para todos os landmarks. São esses os pontos de número: 151, 101, 330, 10, 104, 107, 108, 109, 135, 18, 188, 199, 266, 280, 299, 333, 336, 337, 338, 347, 36, 364, 4, 50, 6, 69, 9. A escolha baseia-se no fato de que regiões como olhos e sobrancelhas produzem um sinal muito ruidoso e podem ser descartadas sem prejuízo para a análise. Além disso, o código do protótipo pode ser facilmente modificado, simplesmente inserindo outros landmarks que se deseja analisar.

Como abordado anteriormente, a região facial que produz o melhor sinal, apesar de normalmente estar na testa e bochechas, ainda varia de acordo com a pessoa. Tendo isso em vista, o protótipo desenvolvido permite que o operador escolha quais regiões do rosto ele pretende analisar. Isso pode ser útil quando se está analisando pessoas com barba, tatuagens, máscaras ou qualquer outro item que possa cobrir regiões do rosto. Nesse caso, o operador pode selecionar apenas regiões viáveis para a análise e poupar tempo de análise, uma vez que o poder computacional que antes estaria processando as regiões cobertas se torna exclusivo para as regiões de interesse selecionadas.

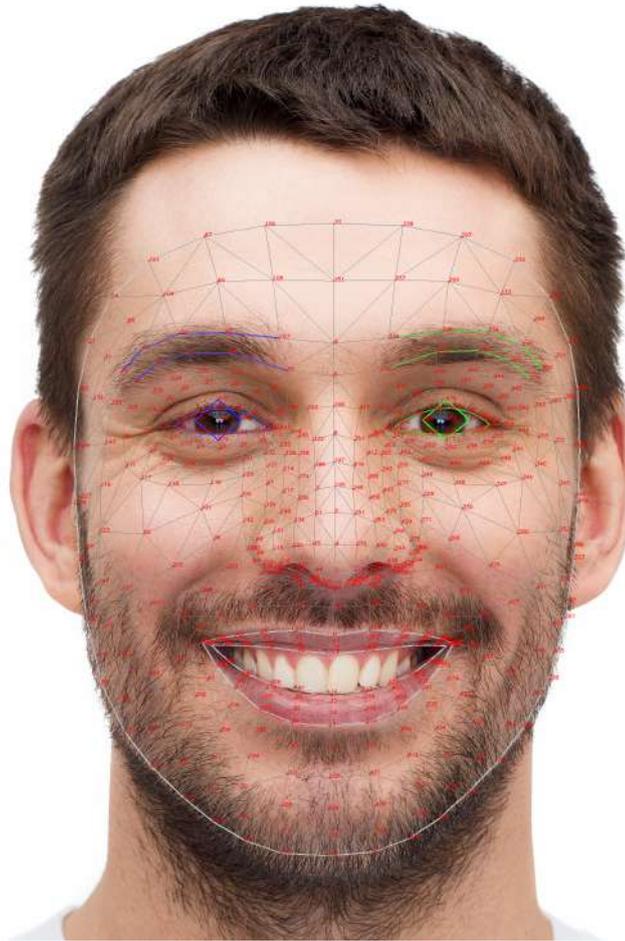
A implementação do protótipo se deu conforme o pipeline mostrado na seção 2.4 (métodos tradicionais), sendo possível uma análise individual de cada patch ou uma análise holística, considerando todos os patches simultaneamente. Uma média aritmética dos pixels dentro de cada região é feita, produzindo os sinais brutos dos canais RGB. Esses sinais são processados e resultam em uma curva PPG para cada patch.

3.1.2.2 Análise de Sinais

A partir da análise das curvas correspondentes aos canais RGB geradas para cada patch, é possível aplicar técnicas de processamento de sinal com o objetivo de converter essas informações no sinal PPG. Na literatura, há diversos métodos propostos para alcançar esse objetivo. Na seção 2.4, é apresentado o PyVHR, um framework desenvolvido especificamente para aplicações relacionadas à rPPG.

O PyVHR incorpora uma ampla gama de métodos amplamente utilizados na área, com destaque para as abordagens GREEN, ICA, PCA, POS e CHROM, que são detalhadamente

Figura 3.3 – Mapeamento completo de pontos de referência faciais do recurso MediaPipe Face Mesh.



Fonte: (Google AI, 2024)

descritas naquela seção. Além disso, o framework também oferece suporte a outros métodos, como LGI, PBV, OMIT e SSR, os quais serão explorados e explicados a seguir. Essas técnicas permitem uma análise mais robusta e adaptável, contribuindo para o avanço das aplicações baseadas em sinais PPG extraídos remotamente.

O LGI (Pilz *et al.*, 2018), é um método que se concentra em garantir a invariância dos recursos em diferentes condições. O principal objetivo dessa abordagem é aprimorar a precisão na estimativa da FC ao introduzir características robustas a variações decorrentes de movimentos faciais rígidos e não rígidos, bem como de mudanças nas condições de iluminação.

O método LGI permite obter uma distribuição mais concentrada do sinal de volume de sangue no espaço vetorial, contribuindo para a atenuação de fatores incômodos que frequentemente obscurecem o sinal de frequência cardíaca alvo. Esse processo inicia-se com a definição de um espaço de recursos extraído dos dados do vídeo, assumindo-se que tais recursos seguem uma distribuição normal. Essa premissa facilita o entendimento e o

acompanhamento da variação da distribuição ao longo do tempo.

Para garantir a invariância local das alterações no volume sanguíneo em função do tempo, o LGI aplica a minimização de um termo de regularização específico. Este processo envolve o cálculo da derivada de uma função f em relação a uma transformação T , onde:

$$T = 0 : \left. \frac{\partial}{\partial T} \right|_{T=0} f(L_T, x(t)) = 0 \quad (3.1)$$

Onde L_t representa o local que é aplicado às transformações dos recursos. Por fim, a invariância local é reforçada aproximadamente pela minimização do seguinte regularizador:

$$\frac{1}{l} \sum_{i=1}^l \left(\left. \frac{\partial}{\partial T} \right|_{T=0} f(L_T, \vec{x}_i) \right)^2 \quad (3.2)$$

Para a matriz de covariância da observação, $\{\vec{x}_i : i = 1, \dots, l\}$.

O método PBV (Haan; Leest, 2014) é uma abordagem projetada para garantir robustez a movimentos, com o objetivo de suprimir sinais que divergem da "assinatura" característica do pulso de volume sanguíneo presente nos valores médios de pixel de uma região da pele, calculando outra combinação linear de valores médios de pixel de pele RGB. Seu cálculo é feito a partir da equação abaixo:

$$P_{bV} = \frac{[\partial(\vec{R}_n), \partial(\vec{G}_n), \partial(\vec{B}_n)]}{\sqrt{\partial^2(\vec{R}_n) + \partial^2(\vec{G}_n) + \partial^2(\vec{B}_n)}} \quad (3.3)$$

Em que, \vec{R}_n , \vec{G}_n e \vec{B}_n representam, respectivamente, a média centralizada e normalizada do sinal das cores R, G e B.

A Transformação de imagem de matriz ortogonal (OMIT) (Casado; López, 2023), é um método avançado que utiliza a decomposição QR para converter sinais RGB brutos em sinais de BVP. Esse método fundamenta-se em técnicas de decomposição de matrizes e tem como principal objetivo gerar uma matriz ortogonal composta por componentes linearmente não correlacionados, os quais representam componentes ortonormais na base de cores RGB.

A geração dessa matriz ortogonal permite a recuperação precisa de sinais fisiológicos, uma vez que elimina correlações redundantes entre os canais de cor, preservando apenas as informações essenciais para a análise do pulso. Como mencionado, o OMIT baseia-se na aplicação da decomposição QR, cuja formulação é expressa na seguinte equação:

$$A = QR \quad (3.4)$$

Onde, $A \in \mathfrak{R}^{nx3}$ representa a matriz RGB de entrada, $Q \in \mathfrak{R}^{nx3}$ denota a base ortonormal do espaço de colunas de A , e $R \in \mathfrak{R}^{nx3}$ é uma matriz triangular superior que contém os coeficientes necessários para expressar as colunas de A como combinações lineares

dos vetores da base ortonormal em Q . Em seguida, é usada a matriz ortogonal Q para calcular uma matriz de projeção que permite extrair o sinal BVP da matriz de entrada A .

A Rotação do Subespaço Espacial (Spatial Subspace Rotation - SSR) (Wang; Stuijk; Haan, 2015a) é um algoritmo cujo princípio central é medir a rotação temporal do subespaço espacial dos pixels da pele para a extração de sinais pulsáteis. Essa abordagem se baseia na análise dinâmica da relação entre os subespaços espaciais ao longo do tempo. O método é composto por duas etapas principais:

1. **Domínio Espacial:** Um subespaço de pixels da pele é construído no espaço RGB, representando a distribuição espacial das informações cromáticas da pele.
2. **Domínio Temporal:** O ângulo de rotação entre os subespaços espaciais construídos em quadros subsequentes é medido, permitindo a extração do sinal pulsátil diretamente a partir dessas variações angulares.

O seu algoritmo final deste método pode ser visto abaixo:

Algoritmo 3.1 Rotação do Subespaço Espacial

Fonte: (Wang; Stuijk; Haan, 2015a) Editado

Require: Um vídeo contendo uma sequência de K frames

Ensure: O sinal de pulso \vec{P}

```

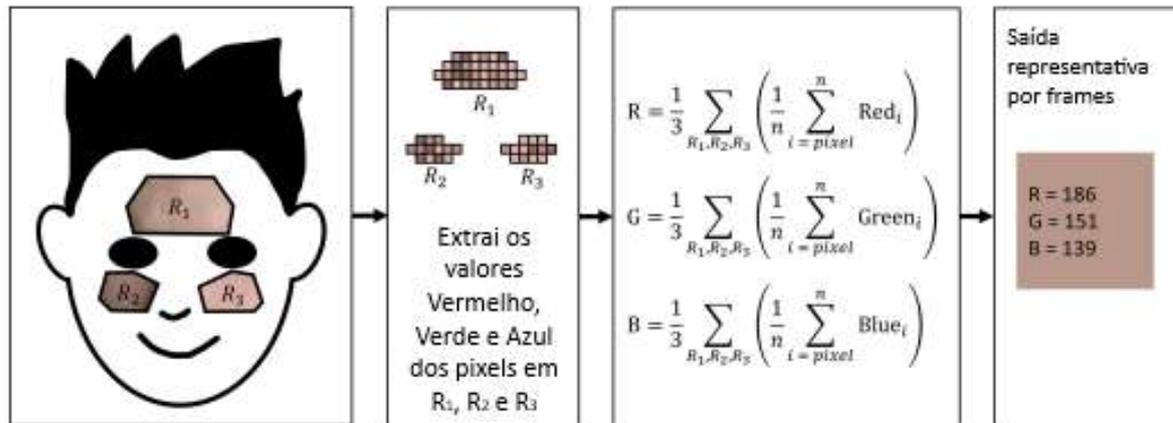
1: Inicializa:  $\vec{P} = \mathbf{zeros}(1, K)$ 
2: for  $k = 1, 2, \dots, K$  do
3:    $C^k = \frac{V^k \top V^k}{N}$ 
4:    $[U^k, \Lambda^k] = \text{eigs}(C^k)$  onde  $U^k = \{u_i^k\}$ ,  $\Lambda^k = \{\lambda_i^k\}$ 
5:   if  $\tau = k - l + 1 > 0$  then
6:     for  $t = \tau, \tau + 1, \dots, k$  do
7:        $SR' = \sqrt{\frac{\lambda_1^t}{\lambda_2^t}} \cdot u_1^t \top \cdot u_2^\tau \cdot u_2^\tau \top + \sqrt{\frac{\lambda_1^t}{\lambda_3^t}} \cdot u_1^t \top \cdot u_3^\tau \cdot u_3^\tau \top$ 
8:        $\vec{SR}' \leftarrow$  concatenado por  $SR'$ 
9:     end for
10:     $\vec{p} = \vec{SR}'_1 - \frac{\sigma(\vec{SR}'_1)}{\sigma(\vec{SR}'_2)} \cdot \vec{SR}'_2$ 
11:     $\vec{P}^{t-l} = \vec{P}^{t-l} + (\vec{p} - \mu(\vec{p}))$ 
12:   end if
13: end for

```

Além dos métodos mencionados anteriormente, também foi utilizado o método GRGB (Haugg; Elgendi; Menon, 2023). Este algoritmo realiza o cálculo de valores denominados $R(t)$, $G(t)$ e $B(t)$, que estão diretamente relacionados a cada um dos canais de cores (vermelho, verde e azul) dos quadros capturados pela câmera. Esses valores representam a intensidade média de cada canal em função do tempo, permitindo a análise detalhada das variações cromáticas ao longo dos frames, como ilustrado na imagem abaixo.

A Figura 3.4 apresenta um resumo do pipeline utilizado pelo método GRGB. Esse processo é repetido para cada quadro do vídeo, resultando na geração de três séries temporais:

Figura 3.4 – Processo de extração dos sinais a partir dos quadros capturados pela câmera.



Fonte: Adaptado de Haugg, Elgendi e Menon (2023)

$R(t)$, $G(t)$ e $B(t)$. Essas séries correspondem às variações temporais nos canais vermelho, verde e azul, respectivamente, e são calculadas a partir dos valores médios de pixel dentro das ROIs definidas.

No contexto do método, i representa um pixel específico, n refere-se ao número total de pixels presentes na ROI, e R_1 , R_2 e R_3 indicam as diferentes regiões de interesse consideradas na análise. Com base nas séries temporais, utiliza-se a seguinte equação para a aquisição do sinal rPPG:

$$rPPG(t) = \frac{G(t)}{R(t)} + \frac{G(t)}{B(t)} \quad (3.5)$$

3.1.2.3 Estimativa das Frequências Cardíaca e Respiratória

Após a obtenção da curva PPG para cada patch analisado, diversas abordagens podem ser adotadas para estimar a frequência cardíaca. Entre as possibilidades estão:

1. Estimar a frequência cardíaca no sinal de cada patch por meio de análise espectral e, posteriormente, calcular a média das estimativas individuais para obter a frequência cardíaca da pessoa.
2. Estimar a frequência cardíaca no sinal de cada patch por meio de análise espectral e, em seguida, calcular a mediana das estimativas individuais como a frequência cardíaca da pessoa.
3. Utilizar métricas de qualidade para avaliar o sinal de cada patch, descartando aqueles excessivamente ruidosos e os que apresentam valores muito distantes da maioria. Após esse filtro, aplicar uma das técnicas anteriores para a estimativa da frequência cardíaca.

4. Realizar um processamento mais detalhado para combinar as curvas PPG dos patches menos ruidosos e, somente depois, estimar a frequência cardíaca.

Inicialmente, optou-se pela segunda abordagem para implementação no protótipo. No entanto, após os testes iniciais de validação, é recomendável que todas as abordagens mencionadas sejam testadas para identificar aquela que apresenta maior robustez e melhores resultados.

A implementação da abordagem escolhida é relativamente simples. Um filtro passa-faixa de 12ª ordem, com frequências de corte entre 0,6 Hz e 3,6 Hz, é aplicado ao sinal bruto para eliminar frequências indesejadas. Em seguida, uma FFT é aplicada ao sinal filtrado, obtendo-se o espectro de frequência. A frequência correspondente ao maior valor de amplitude no espectro é considerada como a frequência cardíaca.

Vale destacar que essa escolha inicial tem como objetivo validar o protótipo. Em etapas posteriores, testes adicionais poderão apontar formas mais eficazes de filtragem e aferição do sinal.

Já para a frequência respiratória, existem três meios principais de ser determinada, conforme mencionado na seção 2.1.3. O estudo de [Filho *et al.* \(2023\)](#) descreve detalhadamente a aplicação desses 3 métodos em código. São eles:

1. **Método da FFT:** Esse método usa a função `SciPyfft` da biblioteca Python SciPy para retornar a transformada discreta de Fourier de uma sequência real ou complexa. A extração da FR do sinal PPG é feita convertendo o sinal PPG do domínio do tempo para o domínio da frequência aplicando a FFT. Em seguida, a frequência é transformada para iRPM, multiplicando o pico dominante por 60. Por fim, é identificado as frequências dominantes extraíndo a FR dentro de um intervalo aceitável para humanos.
2. **Método da Mediana:** Neste método, é aplicado um filtro mediano que permite extrair a linha de base presente no sinal PPG. Para a implementação, é utilizado a função `numpy.median` da biblioteca Python Numpy, que retorna a mediana dos elementos vetoriais. A extração da FR é feita calculando a mediana de um vetor deslizante do tamanho da taxa de amostragem do sinal. Em seguida, é aplicada uma FFT no vetor resultante e é selecionado o pico de frequência dominante dentro da faixa da FR válida.
3. **Método RIIV:** Este método explora a variação da linha de base obtida a partir de uma interpolação linear entre o sinal PPG e seus picos. Para a implementação, são utilizadas as funções `SciPy.find_peaks` e `Scipy.interpolate`, ambas da biblioteca Python SciPy. A função `SciPy.find_peaks` retorna um vetor contendo os picos do sinal analisado, enquanto a função `Scipy.interpolate` gera um vetor com valores interpolados, ou seja, novos valores obtidos a partir dos pontos fornecidos. A partir

desse vetor interpolado, é realizada uma FFT, e a FR é determinada ao selecionar o pico de frequência dominante dentro da faixa válida de FR.

A implementação final escolhida foi o método da Mediana. Essa técnica é particularmente eficaz na atenuação de valores discrepantes e na suavização do sinal final, garantindo uma estimativa mais confiável dos parâmetros fisiológicos.

3.2 Montagem e Implementação do Protótipo

3.2.1 Primeiro Protótipo

No primeiro protótipo desenvolvido, utilizamos uma Raspberry Pi 4 conectada a um monitor com resolução de 1920x1080, acompanhada da câmera Picamera Módulo 3. Além disso, foram conectados à Raspberry Pi periféricos como teclado e mouse para facilitar a interação durante os testes. Este protótipo foi concebido com o objetivo principal de realizar experimentos iniciais, buscando avaliar a precisão e a funcionalidade da integração entre o software desenvolvido e os componentes de hardware. A Figura 3.5 ilustra o dispositivo montado e operacional.

É importante destacar que, nesta fase preliminar, a portabilidade e a versatilidade do projeto foram temporariamente deixadas em segundo plano. O foco central era testar o desempenho e a operacionalidade dos algoritmos iniciais, garantindo que as funcionalidades básicas estivessem implementadas de maneira satisfatória antes de avançar para estágios mais avançados de desenvolvimento.

Neste estágio inicial, os testes eram realizados diretamente via terminal, uma vez que nenhuma interface gráfica havia sido projetada até então. A câmera e a Raspberry Pi estavam fixadas de forma improvisada no próprio monitor de visualização, utilizando adesivos para sua sustentação. Além disso, foi configurada uma conexão VNC (Virtual Network Computing), que possibilitava a operação remota do dispositivo por meio de um notebook, complementando o uso do teclado e mouse fisicamente conectados à Raspberry Pi.

Essa solução híbrida trouxe uma flexibilidade significativa durante o processo de desenvolvimento e validação dos algoritmos. A possibilidade de acessar remotamente o dispositivo foi especialmente útil para mitigar os impactos de alta latência observados durante a execução de programas diretamente no hardware, devido às limitações de processamento computacional da Raspberry Pi. Assim, foi possível otimizar o tempo de trabalho e melhorar a eficiência dos testes iniciais, estabelecendo uma base sólida para as etapas subsequentes do projeto.

Figura 3.5 – Primeiro dispositivo de teste desenvolvido, versão desktop.



Fonte: Autores

3.2.2 Segundo Protótipo

A concepção do segundo protótipo foi guiada pela ideia de transformá-lo em um dispositivo móvel. Para atingir esse objetivo, conectamos à Raspberry Pi uma tela touchscreen de 7 polegadas, eliminando, assim, a necessidade de utilizar teclado e mouse. Além disso, foi projetada e implementada uma caixa de plástico personalizada para abrigar a Raspberry Pi, uma bateria, a câmera Picamera Módulo 3 e outras duas câmeras termais, que, embora não tenham sido utilizadas durante o desenvolvimento deste protótipo, estão previstas para serem empregadas em futuros projetos. A bateria escolhida foi uma bateria externa de 6000 mAh, que inicialmente se mostrou uma solução prática e portátil. A Figura 3.6 apresenta o dispositivo desenvolvido nesta etapa.

Na imagem, é possível observar as entradas USB da Raspberry Pi, que, embora tenham se tornado dispensáveis devido à interface touchscreen, permanecem disponíveis para a conexão eventual de teclado e mouse. Também são visíveis a tela em funcionamento, a entrada para alimentação, o interruptor liga/desliga e um suporte de tripé. Este suporte oferece versatilidade ao protótipo, permitindo sua utilização tanto em superfícies elevadas, com um mini tripé, quanto em locais mais amplos, com um tripé de maior porte para apoio no chão.

Outro detalhe importante revelado na figura é o impacto da bateria externa no de-

sign do dispositivo. Ele representa o componente de maior volume e peso no interior do equipamento, evidenciando que, apesar do protótipo já ser compacto, ainda há espaço para otimizações em termos de escala e leveza. Para evitar problemas de superaquecimento, foram incorporadas aberturas laterais na caixa plástica, garantindo ventilação adequada e preservando a funcionalidade do hardware.

Figura 3.6 – Segundo dispositivo de teste desenvolvido, versão portátil.



Fonte: Autores

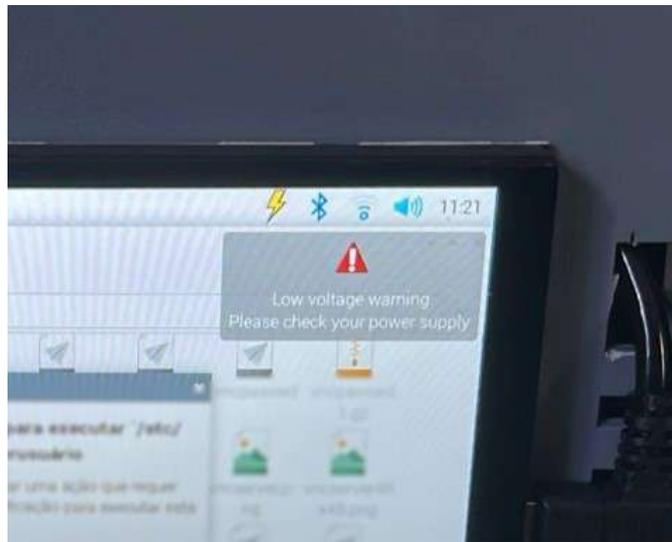
No entanto, durante os testes realizados com o conjunto completo, foi identificada uma falha de energia, conforme ilustrado nas Figuras 3.7a e 3.7b. O erro ocorreu devido à insuficiência de potência da bateria externa, que não conseguiu atender às demandas energéticas da Raspberry Pi. Como solução temporária, foi empregada uma fonte de 12V para alimentar o dispositivo, o que garantiu sua funcionalidade. Contudo, o uso dessa fonte inviabilizou o protótipo como um dispositivo móvel, uma vez que passou a depender da proximidade de tomadas para alimentação.

Mesmo com a restrição de mobilidade imposta por essa solução, decidiu-se manter o protótipo em funcionamento como um equipamento estacionário, adaptado para operar em ambientes com acesso a energia elétrica. Essa abordagem permitiu continuar os testes e validações sem comprometer o progresso do projeto, enquanto se busca uma alternativa para viabilizar novamente a funcionalidade móvel desejada.

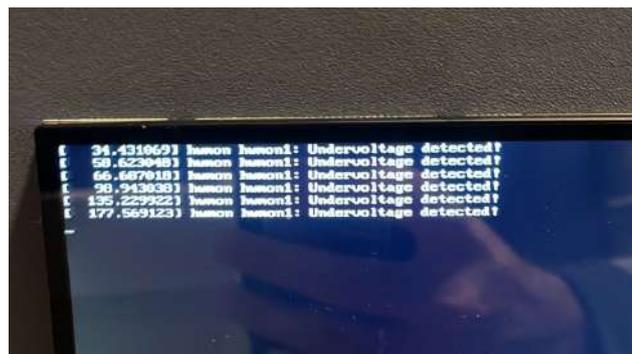
A Figura 3.8 apresenta a primeira tentativa de implementação de uma interface gráfica desenvolvida após o término do segundo protótipo. Nesta etapa do projeto, os autores

Figura 3.7 – Erros encontrados durante testes com a bateria externa.

(a) Aviso apresentado enquanto o dispositivo estava ligado.



(b) Erro apresentado enquanto ligava o dispositivo.



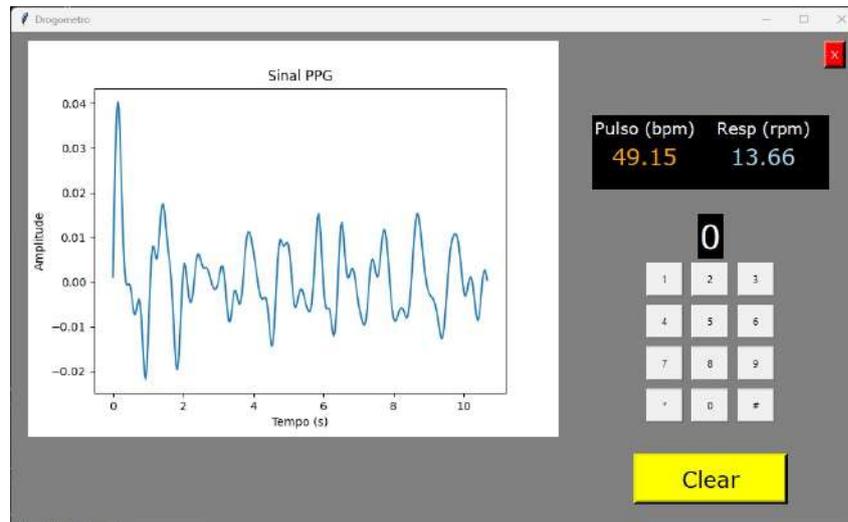
Fonte: Autores

possuíam pouca experiência no desenvolvimento de interfaces desse tipo, resultando em um modelo inicial bastante simplificado.

O modelo inicial apresentava uma tela para exibição das imagens capturadas pela câmera e um botão de início, responsável por acionar a captura dos frames. Após a captura e o processamento, as estimativas de frequência cardíaca e respiratória eram exibidas, e o sinal PPG era mostrado em forma de gráfico. Apesar de sua simplicidade, a interface dispensava o uso de teclado e mouse, sendo totalmente projetada para telas sensíveis ao toque.

Durante os testes com essa interface, foram identificados diversos problemas, que posteriormente foram corrigidos na versão mais recente. Um dos principais inconvenientes era o congelamento da tela durante a captura dos frames, o que impedia o monitoramento em tempo real do enquadramento da pessoa. Essa limitação apresentava o risco de o indivíduo sair da área de captura sem que o operador percebesse. Outro problema significativo era a ausência de informações sobre o andamento das etapas do processo. Não era possível

Figura 3.8 – Primeira interface gráfica desenvolvida.



Fonte: Autores

identificar se o programa ainda estava capturando os quadros ou se já havia iniciado o processamento. Isso resultava em incertezas, obrigando o indivíduo a permanecer enquadrado durante todo o período de execução para garantir o funcionamento correto.

Essas e outras observações foram cruciais para o redesenho da interface gráfica. Na nova versão, buscou-se oferecer maior controle ao usuário, permitindo o ajuste direto de parâmetros como foco, tempo de captura, saturação, brilho, frequência de amostragem e outros, que anteriormente só podiam ser modificados no nível de código.

Além disso, foi estabelecido como meta para a nova interface a implementação de um registro automático de todos os parâmetros configurados e dos resultados obtidos durante os testes. Essa funcionalidade visa permitir a geração de um histórico detalhado do uso do dispositivo, fornecendo dados valiosos para análises posteriores e melhorias contínuas no sistema.

3.3 Interface gráfica

Desenvolvida com base na biblioteca Python **PyQt5**, a interface gráfica foi projetada para simplificar e aprimorar experimentos de fotopletismografia remota. Apesar de estar em uma fase inicial de desenvolvimento, a interface destaca-se por sua alta flexibilidade, permitindo adaptações e reconfigurações conforme surgirem necessidades específicas de uso. Embora o protótipo ofereça suporte ao uso de mouse e teclado, ele foi especialmente concebido para operar de forma otimizada em telas sensíveis ao toque, garantindo maior versatilidade no manuseio.

3.3.1 Janela Principal

O **Menu Principal**, como mostra a figura 3.9, constitui a tela inicial da interface, permitindo a navegação para as demais janelas e funcionando como o núcleo para a captura de frames e o processamento dos resultados.

Figura 3.9 – Janela principal da interface gráfica.



Fonte: Autores

A biblioteca **Picamera2**, utilizada para acessar o módulo da câmera conectado ao Raspberry Pi, oferece controle de baixo nível sobre a câmera, permitindo a configuração de diversos parâmetros. Essa flexibilidade resulta em um número de combinações possíveis que ultrapassam a casa dos milhares. A proposta central da interface gráfica é registrar automaticamente as combinações de parâmetros empregadas em cada experimento, facilitando análises futuras sobre como esses fatores influenciam a qualidade dos resultados. Tanto os valores configurados quanto os resultados obtidos são armazenados em um arquivo de texto. O primeiro botão disponível no menu, o Salvar, permite que esses arquivos de texto sejam gravados em uma pasta específica, acessível durante e após os testes realizados com a interface gráfica. Além dos parâmetros relacionados ao módulo da câmera, variáveis ambientais também podem impactar a precisão das medições. Com isso em mente, o campo “Selecione as variáveis do ambiente” permite registrar condições experimentais, que também são salvas no arquivo.

3.3.1.0.1 Variáveis Ambientais Disponíveis:

- **Tipo de Apoio:** Indica a condição de sustentação do protótipo.
- **Iluminação:** Corresponde ao tipo de iluminação utilizado no ambiente.
- **Cor da Pele:** Refere-se ao nível de melanina da pele do indivíduo analisado.

- **Ambiente:** Descreve o local de realização do experimento, considerando ruídos específicos, como o de faróis de veículos.
- **Restrição ao Movimento:** Define a condição de mobilidade aplicada ao sujeito durante o experimento.

3.3.1.0.2 Campos Numéricos:

- **Distância:** Registra o afastamento da região de interesse em relação ao protótipo.
- **Tempo de Análise:** Indica a duração da captura de quadros, diretamente relacionada ao número de frames analisados.

3.3.1.0.3 Outras Funcionalidades:

- Uma **barra de progresso** exibe o andamento da captura e do processamento.
- O botão **Start** inicia a captura e a análise.
- Botões adicionais permitem acessar outras janelas da interface: **Foco, Configurações, Configurações Avançadas e Resultados**.

Durante o processo de captura, o **retângulo azul** exibe as imagens capturadas pela câmera.

3.3.2 Janela de Foco

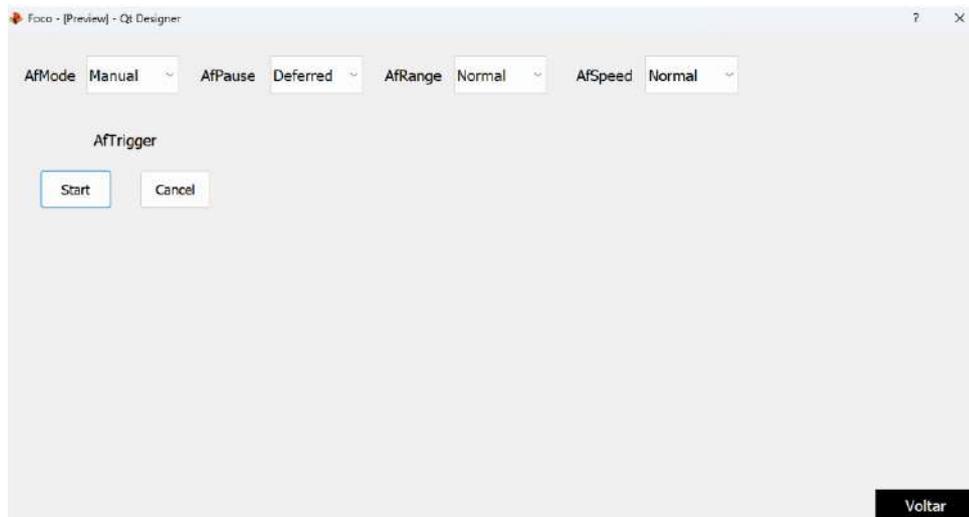
A janela **Foco**, como mostra a figura 3.10, permite realizar ajustes nas lentes da câmera para obter imagens mais nítidas, proporcionando maior controle sobre a qualidade da captura. O parâmetro *AfMode* possibilita a configuração do foco em três modos distintos:

- **Manual:** Fixa a posição da lente em um ponto definido, sem ajustes automáticos.
- **Automático:** Permite que o foco seja ajustado pelo parâmetro *AfTrigger*, ativado ao clicar no botão Start.
- **Contínuo:** Realiza ajustes de foco continuamente durante a captura, garantindo uma adaptação dinâmica ao cenário.

3.3.2.1 Parâmetros do Autofoco

- **AfPause:** Determina como o autofocus contínuo será pausado:
 - *Deferred:* Pausa o autofocus contínuo apenas quando não estiver mais realizando varredura.
 - *Immediate:* Pausa o autofocus contínuo imediatamente.
 - *Resume:* Retoma o autofocus contínuo.

Figura 3.10 – Janela de foco da interface gráfica.



Fonte: Autores

- **AfRange:** Define o intervalo de busca do foco:
 - *Normal:* Busca na faixa padrão.
 - *Macro:* Busca apenas na faixa mais próxima.
 - *Full:* Realiza a busca em todo o intervalo disponível.
- **AfSpeed:** Ajusta a velocidade do movimento do foco:
 - *Normal:* Configura a velocidade padrão.
 - *Fast:* Prioriza uma movimentação mais rápida das lentes.

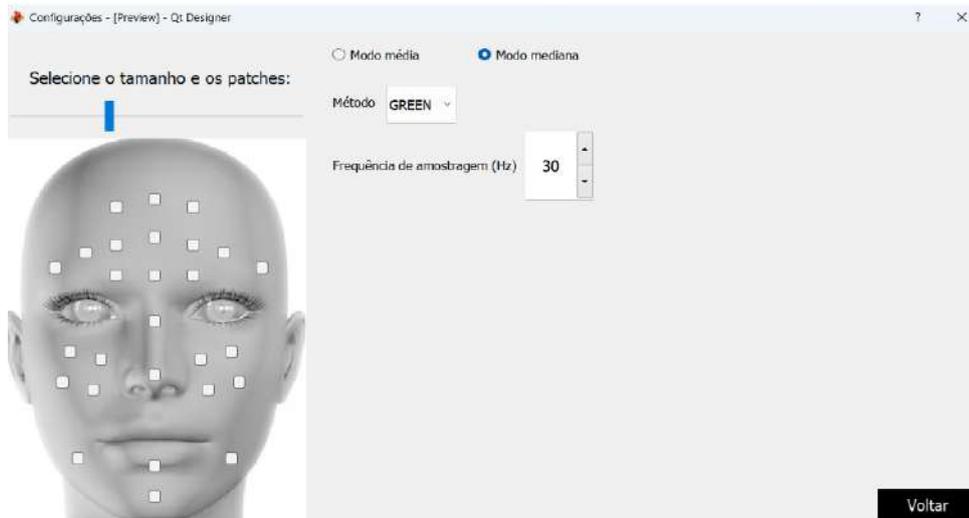
O botão **Voltar** salva os parâmetros selecionados e retorna ao Menu Principal.

3.3.3 Janela de Configuração

A **janela Configuração**, como mostra a figura 3.11, permite ao usuário selecionar quais *patches* serão analisados, determinar seu tamanho, ajustar a frequência de amostragem e escolher o método para obtenção da curva PPG (*Photoplethysmogram*). Estão disponíveis 10 métodos para essa finalidade: GREEN (Verkruyssen; Svaasand; Nelson, 2008), ICA (Poh; McDuff; Picard, 2010), PCA (Lewandowska *et al.*, 2011a), CHROM (Haan; Jeanne, 2013), SSR (Wang; Stuijk; Haan, 2015a), POS (Wang *et al.*, 2017a), LGI (Pilz *et al.*, 2018), OMIT (Casado; López, 2023), GRGB (Haugg; Elgendi; Menon, 2023) e PBV (Haan; Leest, 2014). Alguns desses métodos são relativamente simples, enquanto outros apresentam maior complexidade.

Os métodos foram importados, em sua maioria, da biblioteca pyVHR, com exceção dos métodos GRGB e GREEN, que foram implementados manualmente. O método GREEN utiliza o canal verde do *patch* como a curva PPG, enquanto o método GRGB considera a PPG como a soma do canal verde normalizado pelo canal vermelho e do canal verde

Figura 3.11 – Janela de configurações da interface gráfica.



Fonte: Autores

normalizado pelo canal azul. Detalhes adicionais sobre os métodos mais complexos podem ser encontrados em suas respectivas referências. Além da escolha do método, é possível alternar entre dois modos de cálculo da PPG. Essas configurações oferecem flexibilidade na análise, adaptando-se a diferentes necessidades e níveis de complexidade. Os modos são:

- **Modo Média:** Trata os patches como um único patch ampliado.
- **Modo Mediana:** Calcula a PPG individualmente para cada patch.

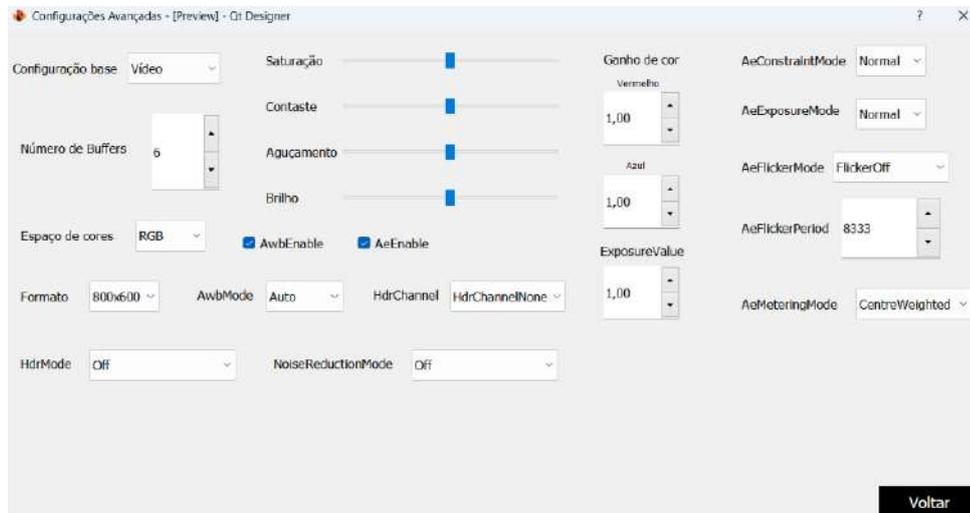
3.3.4 Janela de Configurações Avançadas

A biblioteca Picamera2 oferece um controle extremamente detalhado sobre o módulo de câmera, permitindo ajustes tanto básicos quanto avançados. Como mostra a figura 3.12, esses ajustes podem ser configurados diretamente na seção Configurações Avançadas, que abrange uma ampla gama de parâmetros.

A **Configuração Base** da Picamera2 permite criar uma configuração inicial como ponto de partida para ajustes personalizados. Isso elimina a necessidade de especificar todas as variáveis, permitindo que apenas as relevantes sejam modificadas. Existem três configurações básicas disponíveis: **Vídeo**, otimizada para gravação de vídeos; **Still**, ideal para capturas de imagens estáticas; e **Preview**, focada na visualização de quadros capturados.

O **Número de Buffers** é fundamental para evitar perdas de quadros devido a atrasos no processamento. A biblioteca utiliza buffers que armazenam temporariamente os quadros antes de enviá-los à aplicação, e o número pode ser ajustado conforme a necessidade, limitado pela memória CMA do Raspberry Pi. Na configuração básica **Vídeo**, são utilizados seis buffers para garantir estabilidade durante a gravação, enquanto na configuração **Still**, apenas um buffer é reservado, já que o foco é a captura de uma única imagem.

Figura 3.12 – Janela de configurações avançadas da interface gráfica.



Fonte: Autores

O **Espaço de Cores** define como os canais de cor dos quadros são representados. Os valores disponíveis incluem **RGB**, **YCbCr** e **HSV**. Já o **Formato** especifica a resolução em pixels dos quadros capturados. Embora nem todos os formatos ofereçam boa eficiência de armazenamento, a Picamera2 permite identificar e otimizar esses casos. Exemplos de formatos eficientes incluem 992x750, 800x600, 640x480, 512x384 e 320x240.

O parâmetro **AwbEnable** ativa o algoritmo automático de balanço de branco (AWB), que ajusta os ganhos de cor para corrigir a tonalidade de iluminação da imagem. Quando desativado, esses ajustes devem ser feitos manualmente, sendo o balanço de branco crucial para assegurar que as cores da imagem sejam reproduzidas com precisão, independentemente da fonte de luz. O **AwbMode**, por sua vez, permite selecionar o modo de funcionamento do AWB. Os modos disponíveis incluem **Auto** (ajuste automático para qualquer iluminação), **Tungsten** (iluminação de tungstênio), **Fluorescent** (luz fluorescente), **Indoor** (ambientes internos), **Daylight** (luz natural), **Cloudy** (condições nubladas) e **Custom** (configurações personalizadas).

O **HdrMode** controla o uso do modo HDR (High Dynamic Range), que combina múltiplas exposições para melhorar a qualidade da imagem em condições desafiadoras de iluminação. Este recurso, disponível para dispositivos Raspberry Pi 5, possui os seguintes modos: **Off**, que desativa o HDR; **SingleExposure**, que combina imagens de exposições curtas; **MultiExposure**, que combina exposições curtas e longas para cenas estáticas; **Night**, que melhora os detalhes em baixa luz; e **MultiExposureUnmerged**, que retorna imagens de exposições separadas.

O **NoiseReductionMode** permite selecionar o modo de redução de ruído, suavizando imperfeições causadas por altas sensibilidades ISO ou baixa iluminação. Os valores possíveis incluem **Off** (sem redução), **Fast** (rápida, com foco no desempenho) e **HighQuality**

(qualidade superior, mas que pode impactar a taxa de quadros).

O ajuste de **Ganho de Cor (Color Gain)** é gerenciado pelo algoritmo AWB e é essencial para equilibrar as cores da imagem de acordo com as condições de luz disponíveis, garantindo tonalidades naturais. Já o **AeEnable** ativa ou desativa o algoritmo AEC/AGC (Auto Exposure Control / Automatic Gain Control), responsável por ajustar automaticamente o ganho e a exposição. O **AEC** regula o tempo de exposição para capturar a luz, enquanto o **AGC** ajusta o ganho eletrônico para melhorar o brilho em condições de baixa luz.

O **AeConstraintMode** define como o algoritmo AEC/AGC prioriza diferentes partes da cena. Os modos incluem **Normal** (exposição equilibrada), **Highlight** (prioriza áreas iluminadas), **Shadows** (foca em sombras) e **Custom** (configurações personalizadas). Já o **AeExposureMode** especifica o modo de exposição utilizado: **Normal** (padrão), **Short** (exposições curtas), **Long** (detalhes em baixa luz) e **Custom** (valores específicos).

O **AeFlickerMode** controla a prevenção de oscilações de luz (flicker), que ocorrem devido à incompatibilidade entre a taxa de captura e a frequência da iluminação ambiente. Os modos disponíveis são **FlickerOff** (sem prevenção) e **FlickerManual** (definição manual). O **AeFlickerPeriod** ajusta o período de oscilação em microssegundos, com o valor padrão configurado para 60 Hz.

Por fim, o **AeMeteringMode** especifica o modo de medição para determinar a exposição ideal: **CentreWeighted** (prioriza o centro), **Spot** (mede um ponto específico), **Matrix** (analisa toda a cena) e **Custom** (configurações definidas pelo usuário). A **ExposureValue**, que controla a compensação de exposição em “stops”, ajusta o brilho geral da imagem, com valores positivos aumentando a luminosidade e negativos reduzindo-a.

Todos os valores definidos para essas variáveis, bem como os resultados obtidos, são armazenados em um arquivo de texto para análise detalhada da interferência de cada parâmetro na qualidade dos resultados.

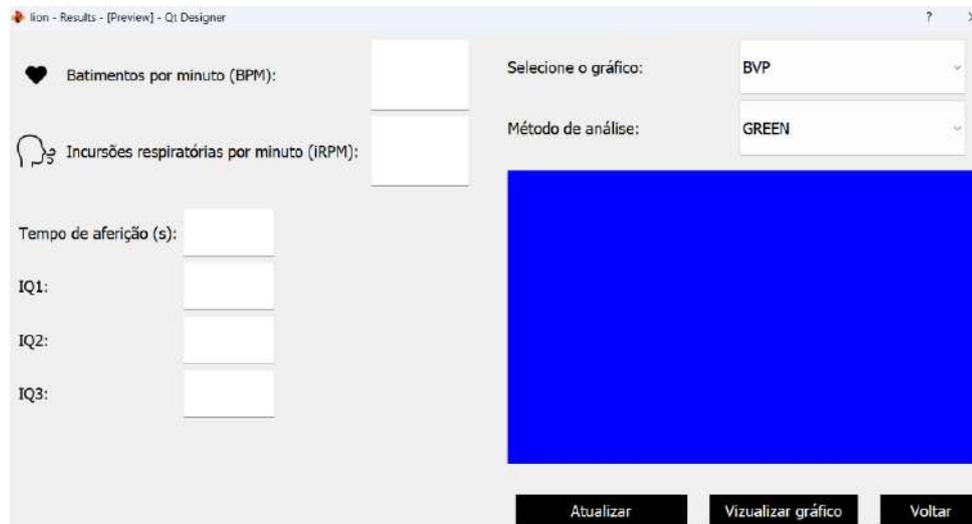
3.3.5 Janela de Resultados

Após o processamento dos quadros capturados, os resultados podem ser acessados na seção **Resultados**. Como mostra a figura 3.13, essa janela reúne informações essenciais sobre a análise realizada e permite ao usuário acompanhar métricas detalhadas de desempenho e qualidade.

As **Estimativas de Frequência Cardíaca e Respiratória** correspondem aos valores iniciais exibidos, medidos em batimentos por minuto (bpm) para a frequência cardíaca e em incursões respiratórias por minuto (rpm) para a frequência respiratória. Esses dados são derivados da análise da curva PPG e oferecem uma visão rápida das condições fisiológicas do sujeito.

O **Tempo de Aferição** indica o tempo total de captura dos quadros, conforme definido

Figura 3.13 – Janela de resultados da interface gráfica.



Fonte: Autores

previamente na configuração do sistema. Essa informação é útil para correlacionar a duração da medição com a estabilidade e a precisão dos resultados.

Os **Índices de Qualidade (IQ1, IQ2, IQ3)** avaliam a qualidade da curva PPG capturada. Configuráveis no código da interface, esses índices analisam métricas específicas, como a relação sinal-ruído e a curtose, que indicam a confiabilidade e a precisão dos dados coletados.

O campo **Método de Análise** exibe a técnica utilizada para gerar a curva PPG a partir dos quadros capturados. Essa informação é importante para validar a abordagem aplicada, especialmente quando diferentes algoritmos ou métodos de extração de sinais estão disponíveis.

A funcionalidade **Seleção de Gráficos** permite ao usuário escolher a visualização exibida na área destacada em azul. As opções incluem a **Curva PPG Bruta**, que apresenta a forma original da curva capturada sem processamento; a **Curva PPG Filtrada**, que exibe a curva após o processamento com ruídos removidos; e o **Módulo do Espectro de Frequência**, que representa as componentes de frequência da curva PPG filtrada, sendo útil para identificar padrões rítmicos.

Os **Botões de Interação** oferecem ações específicas. O botão **Visualizar Gráfico** exibe o gráfico selecionado na área azul. Já o botão **Atualizar** recalcula e exibe os valores dos campos numéricos, garantindo que os resultados estejam sincronizados com a captura mais recente.

3.4 Testes e Avaliação Inicial

3.4.1 Teste no banco de dados UBFC-Phys

Este teste representou a primeira avaliação significativa no desenvolvimento do protótipo, com foco na validação dos algoritmos de detecção facial e extração de regiões de interesse. Até este ponto, os esforços estavam concentrados exclusivamente no aperfeiçoamento dessas etapas fundamentais. Para verificar a eficácia do desenvolvimento, utilizou-se o banco de dados público UBFC-Phys, projetado para estudos psicofisiológicos e análise de sinais fisiológicos durante situações de estresse social.

O UBFC-Phys contém dados de 56 participantes que realizaram três tarefas distintas: repouso (T1), fala (T2) e resolução de problemas matemáticos (T3). Durante essas atividades, os participantes foram filmados por uma câmera EO-23121C da Edmund Optics e usaram uma pulseira Empatica E4, que capturou sinais BVP e Atividade Eletrodérmica (EDA). Adicionalmente, antes e após as tarefas, os participantes preencheram questionários que permitiram o cálculo de escores de ansiedade auto-relatados.

Os dados organizados no UBFC-Phys incluem informações como gênero, cenário experimental (teste ou controle), e registros detalhados de vídeo, sinais BVP e EDA, além de escores de ansiedade. Os vídeos foram gravados a uma taxa de amostragem de 35 Hz, enquanto os sinais BVP e EDA foram amostrados a 64 Hz e 4 Hz, respectivamente.

Para este experimento, optou-se por utilizar apenas a condição de repouso (T1), uma vez que o laptop empregado no desenvolvimento não possuía memória suficiente para processar todos os vídeos do dataset. Além disso, a condição de repouso é mais compatível com a situação idealizada para a implementação do projeto. Assim, os vídeos de três minutos dessa condição foram analisados.

O sinal bruto extraído dos patches foi processado com base no algoritmo GBGR (Hagg; Elgendi; Menon, 2023), um dos métodos implementados no protótipo final. Este algoritmo representa uma maneira simples e de baixa complexidade de se obter a curva PPG. Como o foco estava em testar a extração do sinal bruto, apenas esse método foi testado. Em seguida, aplicou-se a FFT para identificar a frequência correspondente à frequência cardíaca, sendo essa a frequência cuja amplitude do espectro de frequência do sinal atinge seu valor máximo.

Para otimizar o processo, os vídeos foram segmentados em trechos de 45 segundos, aumentando a quantidade de amostras disponíveis. Além disso, o número de patches analisados foi reduzido para três: dois correspondentes às bochechas e um à testa. Essa simplificação visou acelerar o tempo de processamento sem comprometer a precisão dos resultados.

A validação da acurácia foi conduzida por meio de uma comparação entre o sinal rPPG, obtido remotamente através dos vídeos processados, e o sinal BVP fornecido pelo dataset UBFC-Phys. Este último representa a fotopletismografia aferida diretamente em

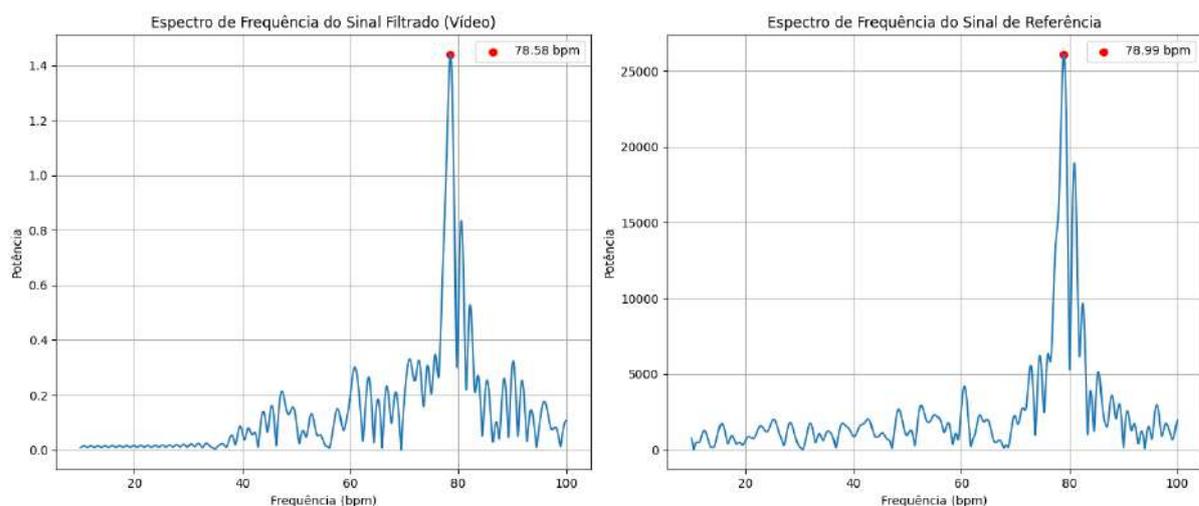
contato com a pele, apresentando maior precisão e confiabilidade. Para ambos os casos, a análise concentrou-se na identificação da maior amplitude no espectro de frequência, obtido por meio da FFT, como o parâmetro representativo da frequência cardíaca.

É importante ressaltar que essa etapa foi concebida como uma análise qualitativa inicial, destinada principalmente a guiar os próximos passos do desenvolvimento experimental e a fornecer uma base de confiança nos algoritmos já implementados. Embora não tenha sido realizada uma validação quantitativa nesta fase, os resultados obtidos desempenharam um papel crucial na orientação do projeto, permitindo identificar aspectos promissores e potenciais limitações.

A abordagem central dessa análise consistiu na busca por similaridades entre as curvas de fotopletismografia remota, extraídas pelo algoritmo implementado no protótipo, e as curvas de fotopletismografia tradicional, disponibilizadas pelo banco de dados. Por se tratar de sinais aferidos diretamente em contato com a pele, o BVP do UBFC-Phys possui um grau mais elevado de confiabilidade, servindo como referência fundamental para a validação dos sinais rPPG.

As curvas PPG apresentam, em sua maioria, características que as assemelham a ondas periódicas. Por essa razão, a expectativa inicial era de que os espectros de frequência dos sinais obtidos evidenciassem uma componente de frequência predominante, com amplitude significativamente maior em relação às demais. Essa predominância seria indicativa da frequência correspondente aos batimentos cardíacos.

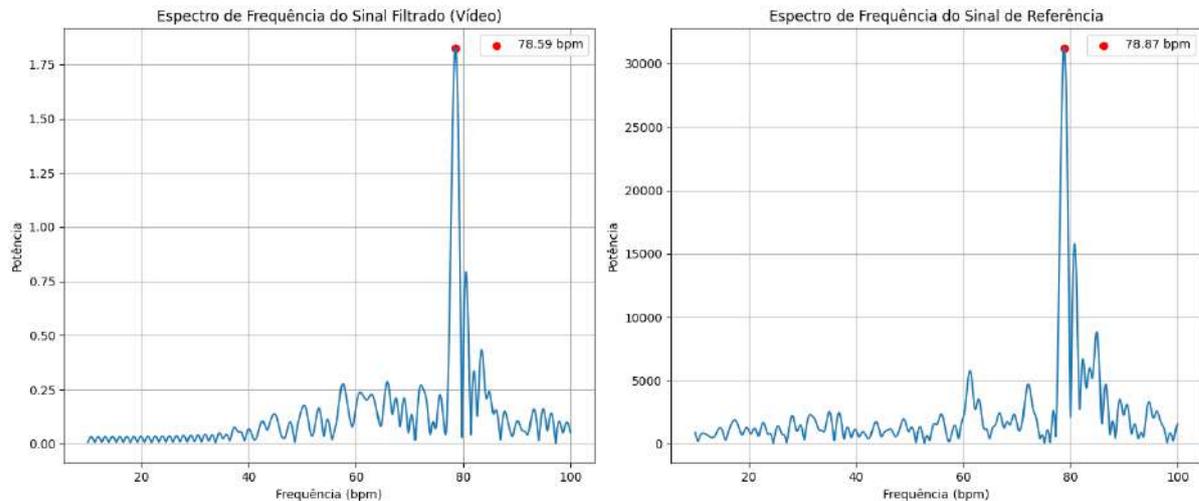
Figura 3.14 – Comparação entre ao espectro de frequência da curva PPG de referência, do banco de dados UBFC-Phys e aferida em contato com a pele, e a curva PPG extraída dos vídeos pelo algoritmo desenvolvido - vídeo 12 parte 3.



Fonte: Autores

As Figuras 3.14 e 3.15 ilustram casos em que a periodicidade do sinal extraído foi tão marcante que o maior pico presente no espectro de frequência apresenta uma potência

Figura 3.15 – Comparação entre ao espectro de frequência da curva PPG de referência, do banco de dados UBFC-Phys e aferida em contato com a pele, e a curva PPG extraída dos vídeos pelo algoritmo desenvolvido - vídeo 12 parte 4.



Fonte: Autores

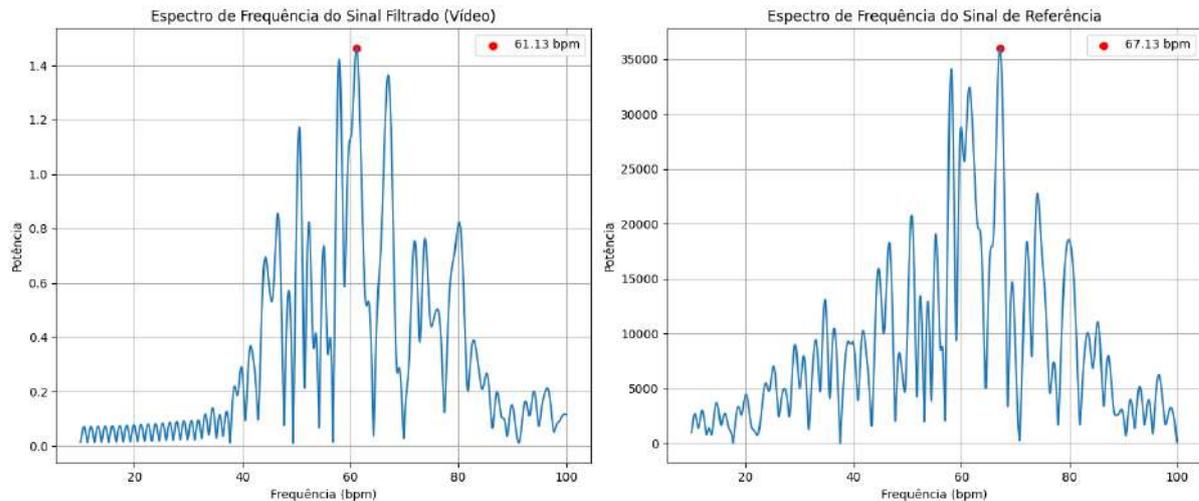
significativamente superior em relação ao restante do sinal. Em situações como essas, o valor do batimento cardíaco estimado pelo algoritmo desenvolvido mostrou-se frequentemente muito próximo do valor obtido no espectro de referência.

Além disso, foi observado que não apenas os picos principais dos espectros coincidiam entre as curvas analisadas, mas também que o formato do espectro nas proximidades desses picos apresentava uma grande semelhança. Isso sugere que, além da frequência principal, outras componentes harmônicas do sinal foram adequadamente identificadas e preservadas durante o processamento. Essa consistência entre os espectros reforça a precisão do algoritmo na extração de informações relevantes dos sinais PPG, demonstrando sua eficácia em capturar tanto a frequência dominante quanto outras características importantes do sinal.

A Figura 3.16 ilustra um caso em que a frequência principal não se destaca significativamente em relação às demais componentes de frequência. Nesse exemplo, observa-se que as estimativas entre o espectro de referência e o espectro obtido pelo algoritmo diferem substancialmente. O formato da curva sugere que o verdadeiro pico de frequência cardíaca está imerso entre diversos candidatos potenciais, o que aumenta a incerteza na estimativa.

Na Figura 3.17, por outro lado, mesmo em condições de maior ruído, observa-se uma certa robustez na estimativa obtida pelo algoritmo. Nesse exemplo, ainda que picos próximos ao principal estejam presentes, este último apresenta potência suficiente para se destacar claramente, resultando em uma medida precisa. No entanto, as observações indicam que, caso o nível de ruído aumente além de um determinado limite, um pico de alta potência não relacionado à frequência cardíaca poderia ultrapassar o pico principal, comprometendo a precisão da estimativa.

Figura 3.16 – Comparação entre ao espectro de frequência da curva PPG de referência, do banco de dados UBFC-Phys e aferida em contato com a pele, e a curva PPG extraída dos vídeos pelo algoritmo desenvolvido - vídeo 2 parte 2.



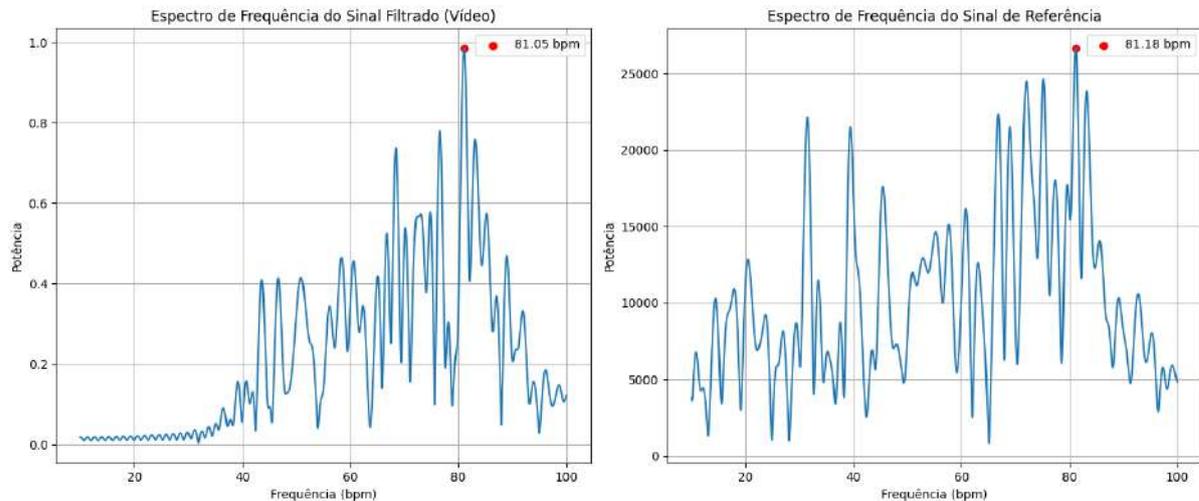
Fonte: Autores

Essas observações sugerem a necessidade de um indicador de qualidade para estimar o grau de confiança das aferições realizadas. Espectros nos quais o pico de maior potência se destaca das demais componentes poderiam indicar maior certeza sobre a estimativa. Por outro lado, espectros com valores de potência semelhantes em múltiplos picos, como o apresentado na Figura 3.16, indicariam maior incerteza. Essa abordagem é corroborada pelos espectros "bem comportados" das Figuras 3.14 e 3.15, que apontam para maior confiabilidade nos resultados.

A Figura 3.18 apresenta a comparação geral entre os valores de frequência cardíaca estimados a partir do sinal PPG de referência e aqueles obtidos pelo algoritmo de rPPG. Cada cor representa um vídeo diferente, enquanto cada ponto corresponde a uma estimativa feita em um intervalo específico de tempo dentro do vídeo. Observa-se que, nos vídeos com espectros nos quais o pico principal possui potência consideravelmente superior às demais componentes, os pontos se concentram próximos à linha tracejada, indicando que as estimativas rPPG estão em boa concordância com os valores de referência. Em contrapartida, nos vídeos onde há múltiplos picos de potência similares, as estimativas apresentam maior variabilidade e menor precisão, como é o caso dos pontos em laranja.

É importante ressaltar que a frequência cardíaca de referência também se trata de uma estimativa, embora obtida por um método considerado mais confiável devido ao contato direto com a pele. Ainda assim, durante os experimentos, houve situações em que o sinal rPPG apresentou características mais consistentes que o sinal de referência. Por exemplo, na Figura 3.16, o espectro do sinal de referência exibe dois picos de alta potência na região entre 20 e 40 bpm, enquanto no espectro rPPG esses picos aparecem com menor intensidade,

Figura 3.17 – Comparação entre ao espectro de frequência da curva PPG de referência, do banco de dados UBFC-Phys e aferida em contato com a pele, e a curva PPG extraída dos vídeos pelo algoritmo desenvolvido - vídeo 2 parte 2.



Fonte: Autores

permitindo uma melhor definição da frequência dominante.

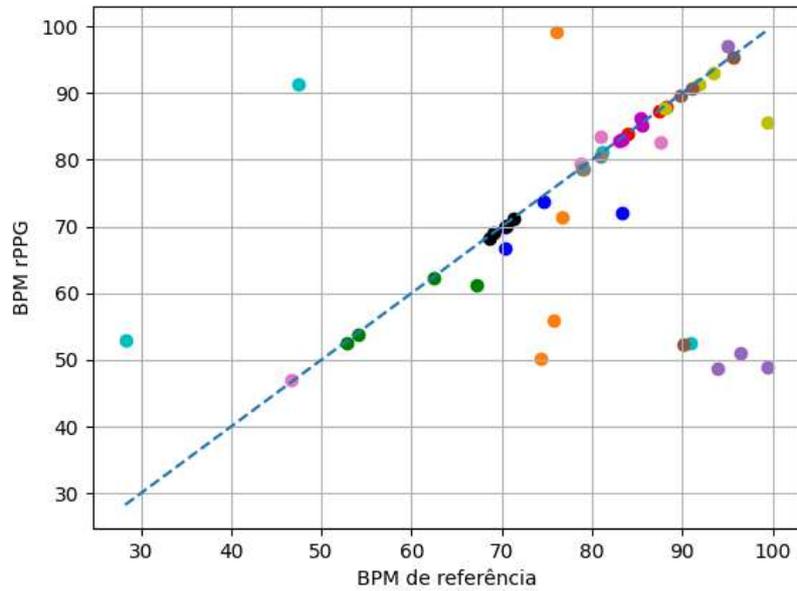
Essas observações motivaram a idealização de novos experimentos, com uma metodologia mais rigorosa, voltada a confirmar as hipóteses levantadas. Ao final desses experimentos, pode-se concluir que os algoritmos iniciais de detecção e extração do sinal rPPG apresentaram um bom comportamento, proporcionando uma certa confiança para a continuação do desenvolvimento, o que de fato era o objetivo inicial dos testes.

3.4.2 Teste no notebook de desenvolvimento

A constatação de que, em alguns casos, a análise espectral dos testes nos vídeos do banco de dados aparentava ser melhor que a análise espectral dos valores de referência levantou preocupações quanto à influência do hardware utilizado na captura dos vídeos. A gravação dos vídeos do banco de dados UBFC-Phys foi realizada com equipamentos de alta qualidade e iluminação controlada, o que gerou dúvidas sobre a reprodutibilidade dos resultados no dispositivo idealizado para o projeto, que contava com hardware mais modesto. Para investigar essa questão, foram realizados testes utilizando vídeos gravados em laptops comuns dos autores, processados pelos mesmos algoritmos desenvolvidos.

A Figura 3.19 apresenta o sinal bruto PPG de baixa qualidade extraído de um dos vídeos gravados pelo notebook. Durante a gravação, o ajuste automático de balanço de branco da câmera resultou em alterações abruptas na intensidade dos pixels, causando uma queda significativa na amplitude do sinal entre 25 e 30 segundos. Esse comportamento evidenciou a necessidade de maior controle sobre as configurações da câmera utilizada, visto

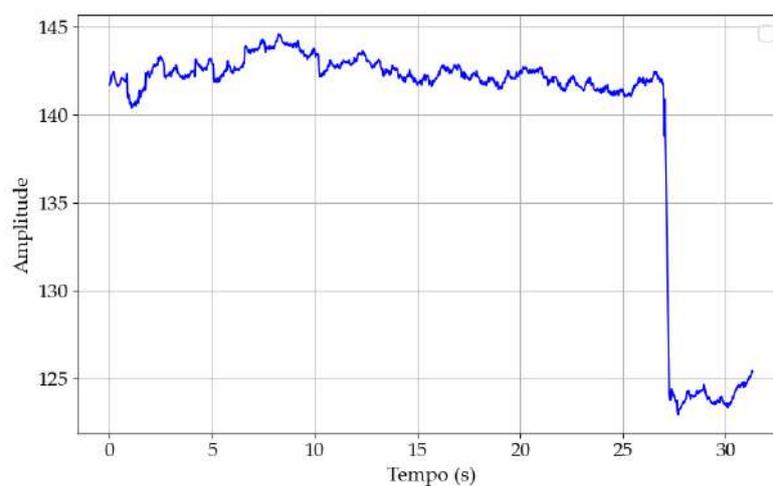
Figura 3.18 – Comparação entre os valores de frequência cardíaca estimados a partir do sinal PPG de referência e do sinal de fotopletismografia remota obtido por meio dos algoritmos desenvolvidos. Cada cor representa um vídeo diferente e cada ponto representa uma estimativa feita em um determinado intervalo de tempo dentro do vídeo.



Fonte: Autores

que ajustes automáticos de foco, balanço de branco ou outros algoritmos poderiam impactar negativamente na qualidade dos sinais extraídos.

Figura 3.19 – Sinal bruto PPG de baixa qualidade extraído um dos vídeos gravados pelo notebook.

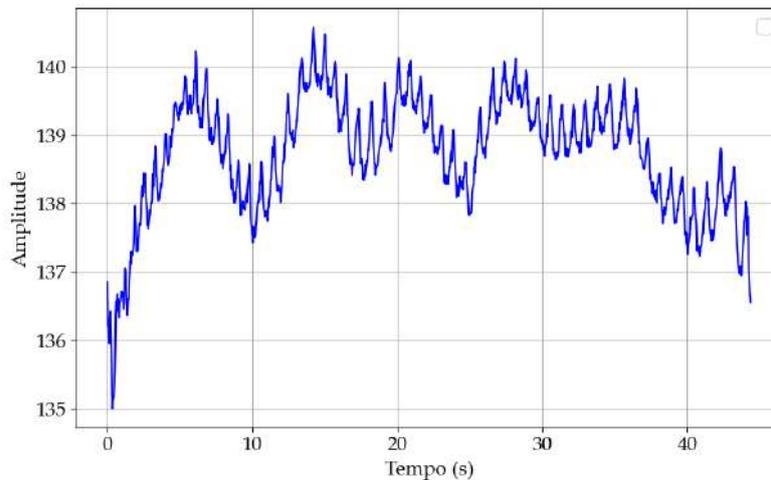


Fonte: Autores

A Figura 3.20, por sua vez, apresenta um sinal bruto PPG considerado de alta qualidade, também extraído de um vídeo gravado pelo notebook. À primeira vista, os resultados

pareciam promissores, pois as oscilações presumivelmente causadas pelos batimentos cardíacos eram claramente perceptíveis, permitindo a contagem diretamente no sinal bruto. Apesar da presença de oscilações em frequências menores, o sinal indicava boa consistência na identificação de padrões compatíveis com os batimentos cardíacos, algo posteriormente confirmado.

Figura 3.20 – Sinal bruto PPG de alta qualidade extraído um dos vídeos gravados pelo notebook.



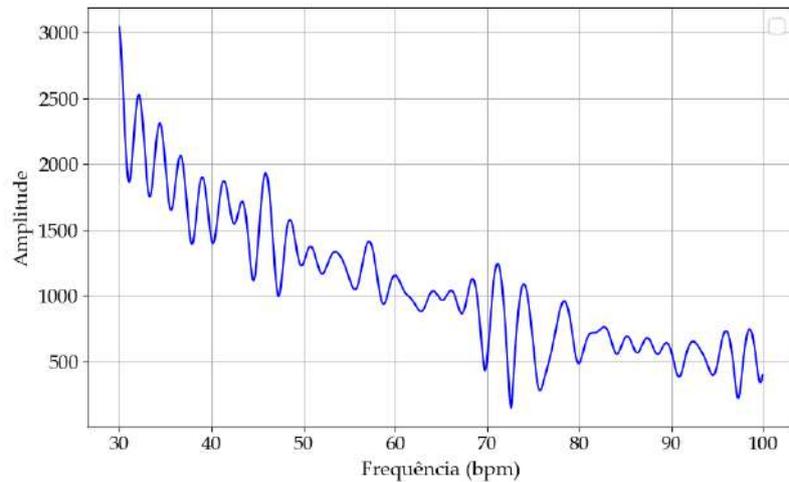
Fonte: Autores

O espectro de frequência correspondente ao sinal bruto da Figura 3.19 é mostrado na Figura 3.21. Nota-se a ausência de um pico dominante, dificultando a identificação clara da frequência cardíaca. Por outro lado, na Figura 3.22, que apresenta o espectro do sinal da Figura 3.20, observam-se três picos proeminentes, localizados entre 60 e 70 bpm, 70 e 80 bpm, e logo acima de 80 bpm. Apesar de não haver uma confirmação imediata sobre qual desses picos corresponde à frequência cardíaca, o pico entre 70 e 80 bpm se destaca como o melhor candidato, devido à sua amplitude superior às demais.

Os resultados desses testes reforçaram a importância de fatores experimentais, como iluminação, movimentação da cabeça, distância da câmera ao rosto e configurações da câmera, na qualidade do sinal extraído. Com base nesses resultados, decidiu-se pela utilização de um eletrocardiógrafo para validar as estimativas de frequência cardíaca e confirmar as hipóteses observadas nos experimentos. Paralelamente, buscou-se maior controle sobre as configurações da câmera, incluindo ajustes manuais de balanço de branco, foco, frequência de amostragem, saturação, nitidez, brilho, contraste e proporções do quadro.

Essa abordagem visa minimizar as interferências causadas por algoritmos automáticos de processamento da câmera durante a aquisição dos frames, garantindo maior consistência nos resultados obtidos e uma melhor reprodutibilidade do sistema em diferentes condições de hardware.

Figura 3.21 – Espectro de frequência de um sinal de PPG de baixa qualidade extraído um dos vídeos gravados pelo notebook. A amplitude no gráfico é o valor do módulo das amplitudes resultantes da FFT.

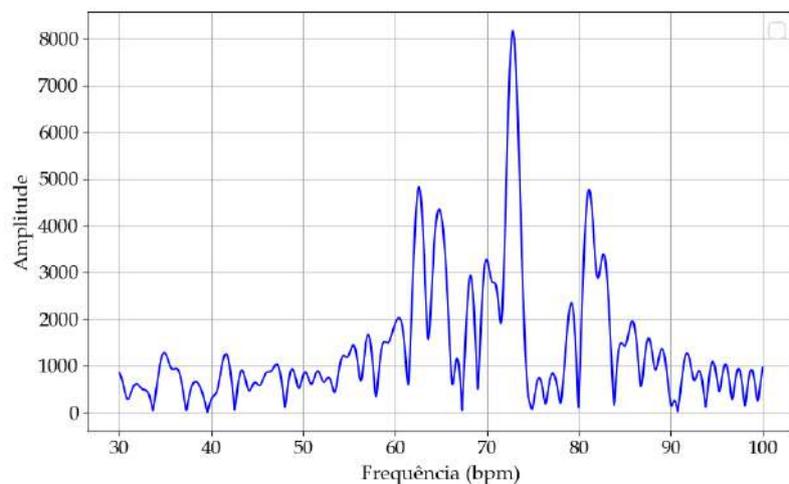


Fonte: Autores

3.4.3 Teste no dispositivo desktop

Como o teste anterior evidenciou, era importante ter um controle de mais baixo nível sobre a câmera utilizada, para evitar que algoritmos nativos interferissem nos resultados obtidos.

Figura 3.22 – Espectro de frequência de um sinal de PPG de alta qualidade extraído um dos vídeos gravados pelo notebook. A amplitude no gráfico é o valor do módulo das amplitudes resultantes da FFT.



Fonte: Autores

A solução para os problemas identificados foi a utilização da biblioteca Picamera2, que oferece um controle aprimorado sobre as funcionalidades da câmera. Essa biblioteca inclui ajustes de foco, algoritmo de equilíbrio de branco automático (AWB), e diversas outras funcionalidades, como a configuração da taxa de amostragem e o uso de filas para evitar a perda de frames. Isso garante uma taxa de amostragem consistente, fundamental para a obtenção de sinais rPPG de qualidade.

O hardware utilizado também foi trocado, neste momento do trabalho passou-se a usar o primeiro protótipo, descrito na seção 3.2.1. Portanto, a capacidade de processamento e a câmera utilizada já eram as mesmas da versão final desenvolvida.

Foram realizados testes para avaliar as configurações que poderiam gerar ruídos e interferir na determinação da frequência cardíaca e respiratória. Esses testes foram conduzidos com captura de frames em tempo real, sob iluminação mista: uma lanterna direcionada para o rosto da pessoa e uma lâmpada LED alimentada por corrente alternada de 60 Hz, com uma taxa de amostragem configurada em 30 Hz. As configurações analisadas foram as seguintes:

1. **AeEnable:** Controla o algoritmo AEC/AGC (Auto Exposure Control/Automatic Gain Control). Quando desativado (False), não há atualizações automáticas nas configurações de ganho ou exposição da câmera.
2. **AeFlickerMode:** Este parâmetro pode ser ajustado como FlickerManual, para corrigir cintilações causadas por fontes de luz artificial, como lâmpadas fluorescentes ou LEDs, de acordo com o valor definido no parâmetro AeFlickerPeriod. Quando configurado como FlickerOff, essa correção é desativada.
3. **AfMode:** Define o comportamento do foco. No modo Auto, o foco é ajustado apenas quando solicitado, e, para os testes, nenhuma calibração foi solicitada durante a amostragem. Já no modo Continuous, o foco é continuamente calibrado durante a captura.
4. **AwbEnable:** Permite ativar (True) ou desativar (False) o equilíbrio de branco automático, que ajusta as cores da imagem para que objetos brancos apareçam corretamente.
5. **NoiseReductionMode:** Configura o modo de redução de ruído. As opções incluem Fast (rápido), Off (sem redução), e HighQuality (alta qualidade). O modo HighQuality pode reduzir a taxa de amostragem da câmera.

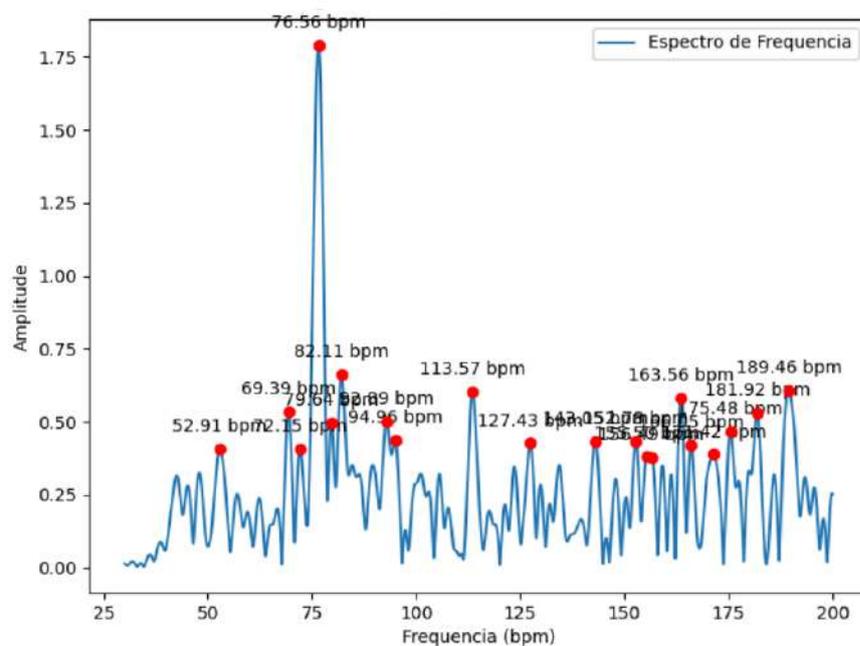
As amostragens foram realizadas em períodos de 30 segundos, combinando diferentes valores desses parâmetros. Para cada combinação, foram feitas três aferições com resoluções de **640x480**, **320x240**, e **160x120** (em pixels). A taxa de amostragem foi validada com base no metadado SensorTimestamp, associado a cada frame capturado. Esse metadado registra

o momento exato da captura, permitindo verificar se os intervalos entre frames estavam consistentes com a taxa de 30 Hz configurada.

Para avaliar a influência das configurações, foi criado um indicador de qualidade do sinal rPPG baseado no formato do espectro de frequência do sinal. Dessa vez, antes da análise espectral, foi aplicada apenas uma filtragem passa-faixa utilizando um filtro Butterworth de 6ª ordem, com frequências de corte entre **0.7 Hz e 3.5 Hz**.

Como observado nos testes anteriores, um espectro com um pico muito acima dos demais indicaria um certo nível de confiança para a aferição, como é o caso do resultado de número 3, mostrado na figura 3.23. Por outro lado, como mostra a figura 3.24 quando o ruído é muito grande, uma certa dúvida é gerada, exaltando a possibilidade do maior pico no espectro ser causado na verdade pelo ruído.

Figura 3.23 – Espectro de frequência de um sinal de PPG de alta qualidade obtido por meio da primeira versão do protótipo.

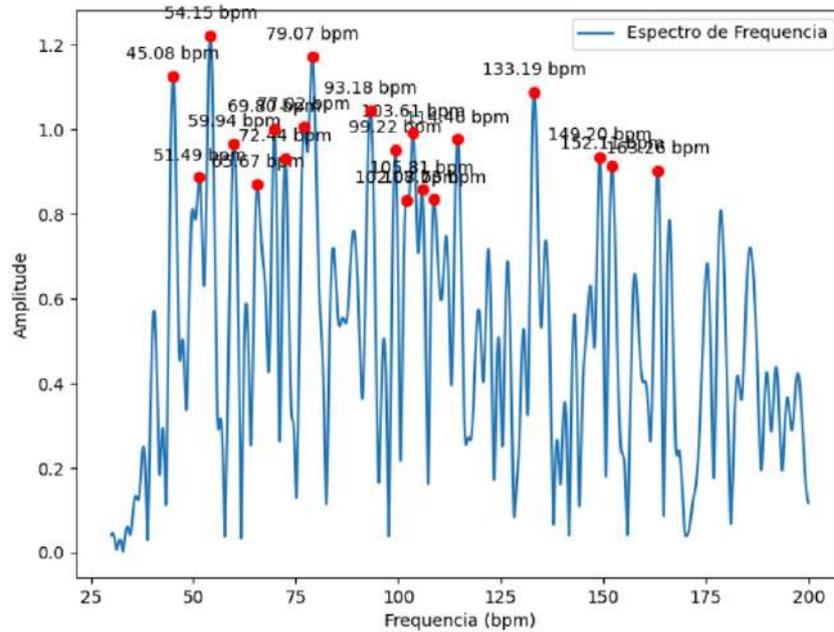


Fonte: Autores

Um índice de qualidade (Q) foi desenvolvido com base nas observações realizadas. Embora se reconheça que o sinal PPG não é composto por uma única frequência específica, mas sim por várias componentes, considerou-se válido o desenvolvimento deste indicador devido à sua simplicidade e coerência com as expectativas levantadas sobre sinais ótimos. O índice de qualidade é calculado pela seguinte fórmula:

$$Q = P_{\max} - \frac{1}{k} \sum_{n=1}^k P_n \quad (3.6)$$

Figura 3.24 – Espectro de frequência de um sinal de PPG de baixa qualidade obtido por meio da primeira versão do protótipo.



Fonte: Autores

É importante destacar que todas as amplitudes no espectro de frequência foram previamente normalizadas. Para isso, dividiu-se todo o espectro pelo valor da maior amplitude presente, de forma que as amplitudes mencionadas a partir deste ponto referem-se às amplitudes normalizadas.

Na Equação 3.6, P_{\max} representa a amplitude do pico mais elevado no espectro de frequência, correspondente à frequência cardíaca aferida. Já P_n é a amplitude do n -ésimo pico dentro de um conjunto de k picos (são os pontos em vermelho das figuras 3.23 e 3.24, com exceção daquele de maior amplitude). O índice de qualidade é obtido subtraindo-se da amplitude máxima a média das amplitudes do conjunto k .

O conjunto k é definido como os k maiores picos do espectro (excluindo o pico correspondente a P_{\max}), cujas frequências estão a mais de 2 bpm de distância da frequência associada a P_{\max} . Esta exclusão é fundamentada na expectativa de que picos próximos a P_{\max} não aumentam significativamente a incerteza da medição. Em contraste, picos de amplitudes semelhantes, mas localizados em frequências muito distintas, podem gerar uma maior incerteza, prejudicando a qualidade da aferição.

Cada combinação de parâmetros gerou três índices de qualidade referentes às aferições feitas nos formatos 640x480, 320x240 e 160x120. Comparou-se o valor da média dos índices de qualidade para cada configuração. A Tabela A.1 apresenta os resultados organizados em ordem decrescente de qualidade.

Na tabela A.1, a qualidade nula foi atribuída quando não foi possível obter resultados

por meio do pipeline de processamento. Observou-se que, quando o parâmetro `AeEnable` era configurado como `FALSE`, ou seja, sem atualizações automáticas nas configurações de ganho ou exposição da câmera, os frames capturados eram excessivamente escuros, impossibilitando a extração de sinais utilizáveis com a implementação atual.

Quanto aos demais parâmetros, não foi possível inferir nenhuma correlação forte a partir da tabela. Ressalta-se, porém, que entre os 11 melhores resultados, apenas um apresentava o parâmetro `NoiseReductionMode` configurado como `Off`, indicando que a redução de ruído contribui positivamente para a qualidade do sinal. Além disso, nenhuma análise mais aprofundada dos resultados foi feita, tendo em vista que ainda não se tinha um eletrocardiógrafo e um dispositivo de contagem de respiração para validar as frequências cardíacas e respiratórias. Portanto, qualquer conclusão obtida a partir de uma análise mais profunda seria nada mais nada menos que uma especulação em cima de ideias do que seriam espectros bons e ruins.

Adicionalmente, verificou-se que o algoritmo de foco automático, mesmo quando configurado para operar continuamente (`AfMode = Continuous`), não introduziu componentes significativas no espectro de frequência da FFT. Quanto ao ajuste automático de balanço de branco (`AwbEnable`), não se observou mudanças abruptas na coloração dos pixels.

3.4.4 Teste da taxa de amostragem

Uma das principais preocupações durante os experimentos era verificar se a frequência de amostragem configurada realmente se mantinha constante durante a execução do programa. A captura de quadros é realizada em uma *thread* separada do restante do programa, garantindo independência no processo. Isso significa que, mesmo em situações onde há tarefas que exigem alto poder de processamento, como o processamento de imagens requerido no projeto, a captura dos quadros mantém uma prioridade relativa, sem necessariamente esperar pela conclusão dessas tarefas.

Apesar dessa vantagem, duas preocupações principais permanecem:

1. **Atrasos na *thread* de captura:** Embora as capturas sejam realizadas em uma linha de processamento separada, há outras funcionalidades implementadas na mesma *thread*. Essas podem causar atrasos no processo de captura ou, em casos mais extremos, bloquear o *loop* de eventos da *thread*.
2. **Perda de quadros:** Mesmo que os quadros sejam capturados corretamente, eles ainda precisam ser transferidos para a aplicação. O sistema de captura utiliza uma fila para armazenar os quadros antes que sejam requisitados. Caso o processamento da aplicação não acompanhe a frequência de amostragem, o quadro pode ser recuperado da fila, que é armazenada na memória CMA. O tamanho dessa fila é configurado pelo parâmetro `buffer_count`, ajustável na interface gráfica desenvolvida. Contudo,

atrasos excessivos podem levar ao esgotamento do espaço na fila, resultando na perda de quadros.

Para mitigar essas preocupações, a biblioteca **Picamera2** oferece recursos úteis para monitorar a taxa de amostragem:

- **Funções de *callback*:**

- `pre_callback`: Executa uma determinada tarefa antes dos quadros serem fornecidos para a aplicação, codificadores de vídeo ou janelas de visualização.
- `post_callback`: Executa uma determinada tarefa depois dos quadros serem fornecidos para a aplicação, mas antes de serem passados para codificadores de vídeo ou janelas de visualização.

Essas funções podem ser usadas como gatilhos para registrar os instantes em que os quadros são capturados. Os tempos registrados podem ser analisados ao final dos testes para identificar possíveis problemas na captura.

- **Metadado `SensorTimestamp`:** Um recurso mais simples e eficiente adotado neste projeto foi o uso do metadado `SensorTimestamp`, que indica o momento exato em que o quadro foi gerado pelo sensor. Esse tempo, medido em nanossegundos desde a inicialização do sistema, é registrado durante a interrupção de início de quadro da câmera, quando o primeiro pixel do novo quadro é escrito pelo sensor. Como esse metadado já implementa uma solução eficaz para o monitoramento da captura, ele foi utilizado para verificar a consistência da frequência de amostragem durante os testes.

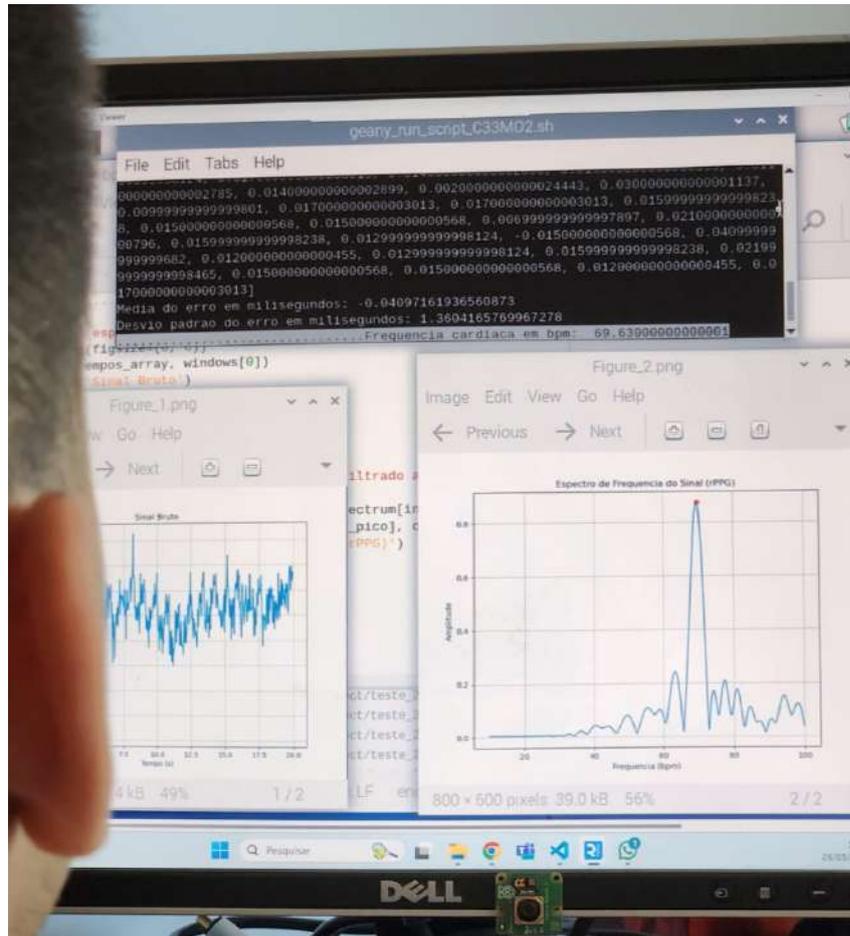
A Figura 3.25 ilustra o procedimento de verificação da amostragem realizado durante os testes. Nessa figura, além do sinal bruto e do espectro de frequência, é apresentada a lista de atrasos dos quadros em milissegundos. Na parte inferior, encontra-se o valor médio do erro, que é de aproximadamente -0,00004 segundos.

Considerando que, neste caso, como na maioria dos testes, o intervalo entre as capturas dos quadros é de 0,033... segundos, o erro médio corresponde a apenas 0,12% desse valor. Portanto, pode-se assumir que esse erro não apresenta impacto significativo sobre o resultado final. Essa ordem de magnitude para o erro médio mostrou-se consistente na maioria dos testes realizados.

Nos casos em que o erro médio apresentou alterações significativas, a causa foi atribuída a implementações alternativas que ocasionaram sobrecarga no processamento. Tais implementações foram descartadas, pois não garantiam uma amostragem adequada.

Ao implementar o sistema na forma de uma interface gráfica, a thread responsável pela captura dos quadros passou a ser a mesma que controla a interface, devido a características inerentes à biblioteca `Picamera2`. Com essa configuração, a taxa de amostragem e

Figura 3.25 – Análise da amostragem, visualização da curva PPG bruta e seu respectivo espectro de frequência durante a realização dos testes.



Fonte: Autores

suas microvariações puderam ser visualizadas em tempo real na tela durante a captura dos quadros, o que facilitou ainda mais o monitoramento e controle do processo.

Como medida adicional de segurança, foram utilizadas funções de callback para registrar a quantidade de quadros capturados ao longo dos testes. O número de quadros capturados foi consistentemente igual à quantidade de quadros recebidos pela aplicação, indicando que não houve perdas durante o processo.

3.5 Preparação para o Teste de Acurácia

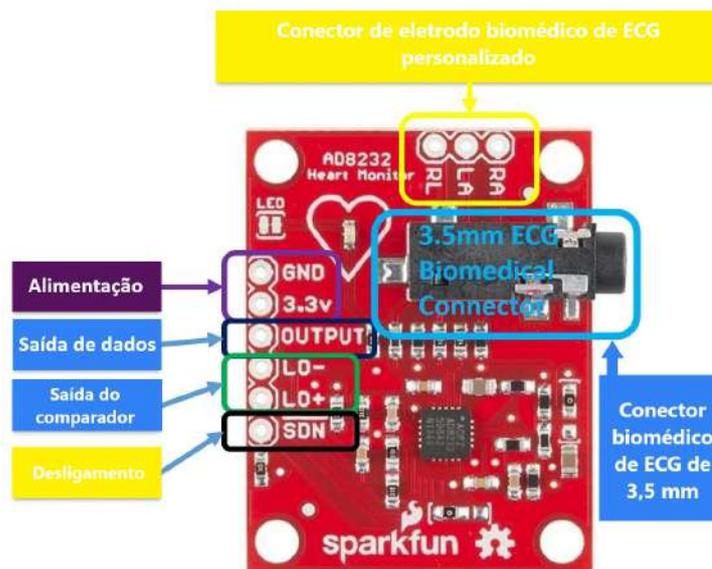
Com base nos testes preliminares realizados e no aperfeiçoamento contínuo do protótipo descrito nas seções anteriores, o próximo passo será a realização do teste final para validação do dispositivo. Antes disso, é necessário desenvolver dispositivos auxiliares capazes de detectar, em tempo real, as frequências cardíaca e respiratória. Esses dispositivos servirão como uma referência confiável para a comparação dos dados estimados pelo protótipo,

funcionando como uma prova real para validação de sua eficácia.

Para avaliar a acurácia das estimativas de frequência cardíaca e respiratória, foram implementados dispositivos auxiliares que servem como referência. Um monitor de frequência cardíaca foi desenvolvido utilizando o módulo AD8232, conhecido por extrair, amplificar e filtrar pequenos sinais biopotenciais na presença de condições ruidosas, como aquelas criadas por posicionamento de eletrodo entre outras.

O monitor de frequência cardíaca AD8232 oferece nove conexões principais no seu circuito integrado. Essas conexões podem ser utilizadas por meio de pinos, fios ou outros conectores soldados na placa. Os pinos essenciais incluem: SDN, LO+, LO-, OUTPUT, 3.3V e GND, que possibilitam o funcionamento do monitor em conjunto com placas de desenvolvimento, suas saídas podem ser melhor vista na imagem 3.26. Também são fornecidos nesta placa os pinos RA (Braço Direito), LA (Braço Esquerdo) e RL (Perna Direita) permitindo a conexão de sensores personalizados para medições adaptadas. Além disso, há uma luz indicadora LED que vai pulsar ao ritmo de um batimento cardíaco.

Figura 3.26 – Localização dos pinos do Módulo ECG AD8232.



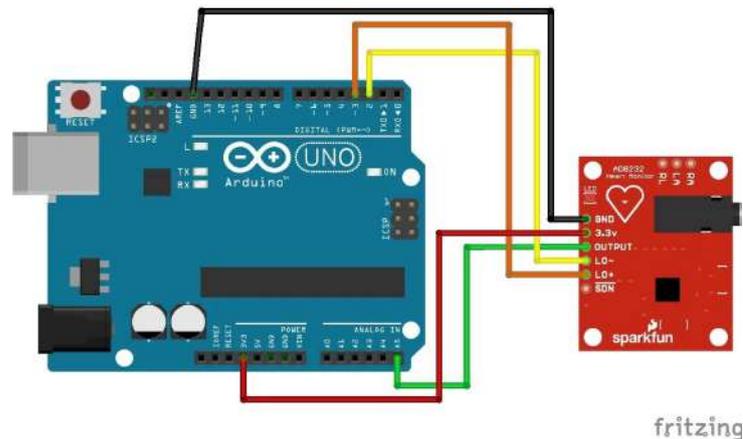
Fonte: Adaptado de [Microcontrollerslab \(2024\)](#)

O módulo descrito acima foi integrado a uma placa Arduino modelo Uno. As conexões foram realizadas de acordo com as especificações do módulo, conforme ilustrado na Figura 3.27.

No Arduino, foi implementado um código simples que recebe os sinais do módulo AD8232 e imprime sua saída no Serial Monitor, como é visto no código código 3.1. Esse procedimento permite visualizar os dados capturados em tempo real.

Para complementar, foi utilizado o Processing, um ambiente de desenvolvimento integrado (IDE) baseado em uma adaptação da linguagem Java. O Processing foi empregado

Figura 3.27 – Interface do módulo de ECG AD8232 com o Arduino.



Fonte: Adaptado de [Microcontrollerslab \(2024\)](#)

Código 3.1 – Código utilizado no arduino do ECG. Adaptado de [Microcontrollerslab \(2024\)](#).

```

1 void setup() {
2   // Inicializa a comunicação serial:
3   Serial.begin(9600);
4   pinMode(3, INPUT); // Configurando pino de leitura para LO +
5   pinMode(2, INPUT); // Configurando pino de leitura para LO -
6 }
7
8 void loop() {
9   if((digitalRead(10) == 1)|| (digitalRead(11) == 1)){
10    Serial.println('!');
11   }
12   else{
13    // Imprime o valor da porta analogica A5:
14    Serial.println(analogRead(A5));
15   }
16   //Pequeno atraso para evitar sobrecarga
17   delay(1);
18 }

```

para criar um programa dedicado à plotagem do sinal ECG em tempo real.

Para avaliar a frequência respiratória, foi integrado ao sistema um Módulo Sensor Barométrico de Pressão Digital MPS20N0040D, que pode ser visto na figura 3.28, projetado para detectar variações sutis na pressão. Para capturar esses dados, foi utilizado um cateter nasal, posicionado no rosto do indivíduo em teste. O sensor barométrico foi acoplado na extremidade do cateter, de forma a captar diretamente as mudanças de pressão geradas pelo fluxo de ar durante a inspiração e expiração. Essa configuração proporciona uma medição sensível e confiável, assegurando que as informações capturadas sejam representativas do padrão respiratório.

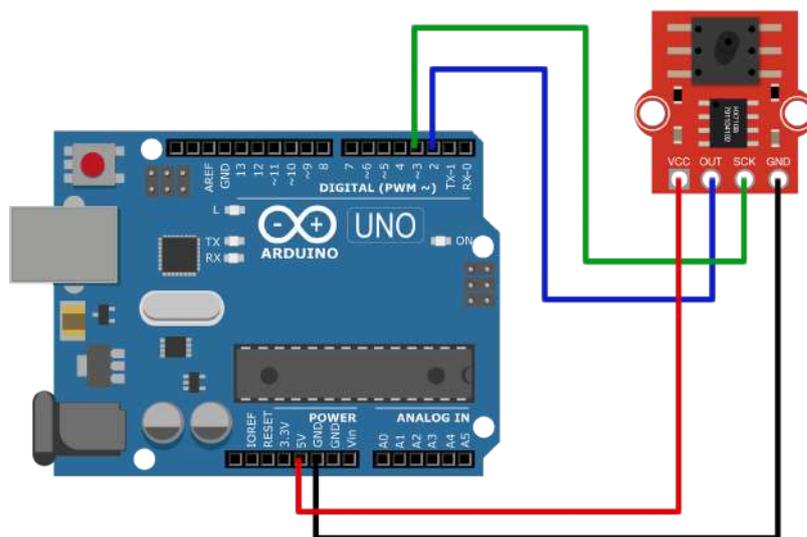
O Módulo Sensor Barométrico de Pressão Digital é equipado com um conversor analógico-digital embutido, permitindo uma conexão direta entre o módulo e o microcontrolador. Seu sensor opera em uma faixa de pressão que varia de 0 a 40 KPa, garantindo uma alta sensibilidade para detectar variações sutis, como aquelas associadas ao ciclo respiratório. O módulo apresenta quatro conexões principais, que possibilitam a integração por meio de pinos, fios ou outros conectores soldados. As conexões essenciais incluem: VCC, OUT, SCK e GND.

Figura 3.28 – Módulo MPS20N0040D utilizado para a aferição da pressão no cateter nasal.



Assim como o módulo ECG, o módulo MPS20N0040D foi integrado a outra placa Arduino modelo Uno. As conexões foram realizadas de acordo com as especificações do módulo, conforme ilustrado na Figura 3.29

Figura 3.29 – Módulo MPS20N0040D ligação com o arduino.



No Arduino, foi implementado um código simples que recebe os sinais do módulo e imprime sua saída no Serial Monitor, como é visto no código [código 3.2](#). Esse procedimento permite visualizar os dados capturados em tempo real.

Código 3.2 – Código utilizado no arduino do barômetro. Adaptado de [MakerPortal \(2024\)](#).

```

1 #include <Q2HX711.h>
2
3 const byte MPS_OUT_pin = 2; // Pino de saída de dados (OUT)
4 const byte MPS_SCK_pin = 3; // Pino de clock de dados (SCK)
5 int avg_size = 10; // Número de pontos para calcular a média
6
7 Q2HX711 MPS20N0040D(MPS_OUT_pin, MPS_SCK_pin); // Inicia a comunicação com
   o HX710B
8
9 void setup() {
10   Serial.begin(9600); // Inicia a porta serial
11 }
12
13 void loop() {
14   float avg_val = 0.0; // Variável para o cálculo da média
15   for (int ii = 0; ii < avg_size; ii++) {
16     avg_val += MPS20N0040D.read(); // Soma múltiplas leituras do ADC
17     delay(50); // Atraso entre as leituras
18   }
19   avg_val /= avg_size; // Calcula a média
20   Serial.println(avg_val, 0); // Imprime o valor médio
21 }

```

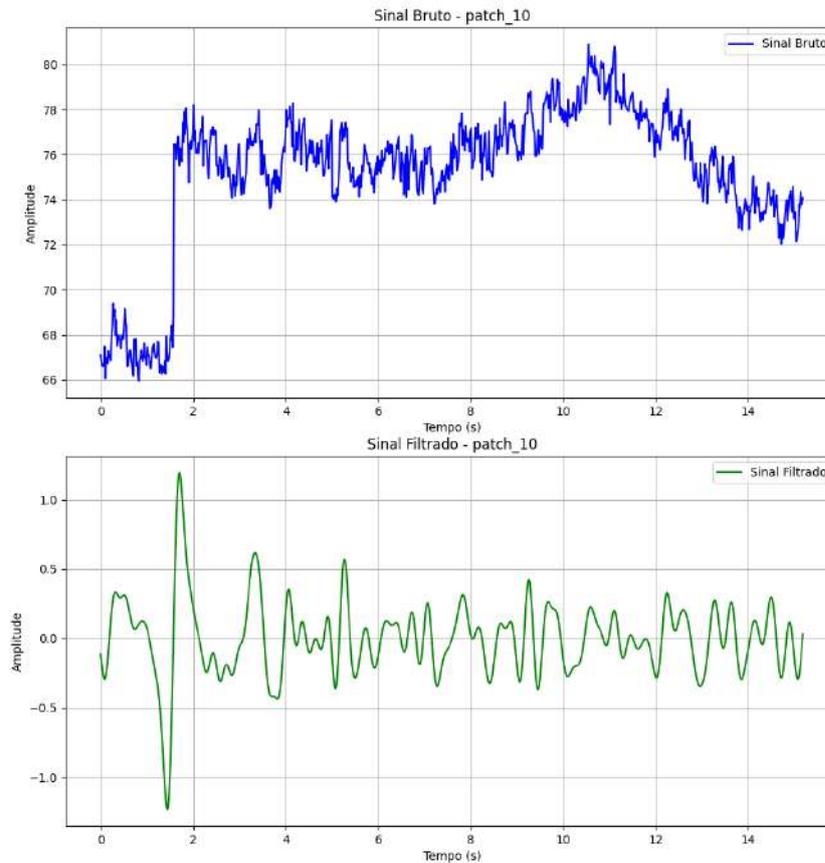
Para complementar, foi utilizado o Processing para criar um programa dedicado à plotagem do sinal da pressão em tempo real. Além disso, a frequência respiratória real foi determinada por meio de uma análise de Fourier, utilizando a FFT aplicada ao sinal de variação da respiração. Assim, analisando dentro do espectro de frequências resultante, o pico dominante foi identificado como correspondente à frequência respiratória.

Contudo, mesmo com os dois dispositivos auxiliares disponíveis, é necessário desenvolver uma estratégia para sincronizar os dados coletados com o sinal PPG. Para esse fim, foi implementada uma lanterna como marcador de sincronização. O funcionamento desse sistema baseia-se em um evento de mudança de iluminação, que gera um pico característico no sinal PPG. Na [Figura 3.30](#), é apresentado o resultado de um teste de sincronização, ilustrando claramente o pico no sinal bruto e sua correspondência no sinal filtrado.

O processo inicia-se com a lanterna ativada. Ao começar a aquisição do PPG pelo dispositivo principal, um botão é acionado, desligando momentaneamente a lanterna e sinalizando o início da aquisição simultânea do ECG e do gráfico de pressão.

Esse método assegura que o momento de início da aquisição seja registrado de forma precisa nos três sinais, permitindo a sincronização temporal entre os dados obtidos. Essa

Figura 3.30 – Gráficos com a queda da mudança de iluminação.

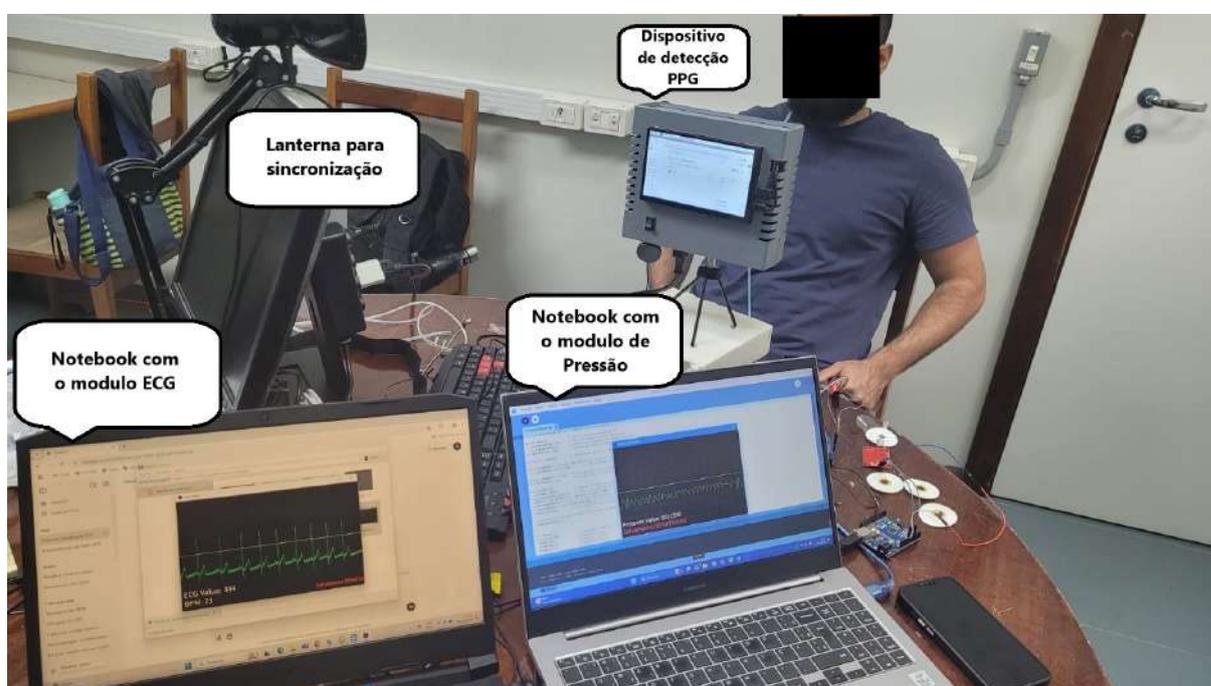


Fonte: Autores

abordagem facilita a comparação direta e precisa entre os sinais PPG, ECG e de pressão, melhorando a confiabilidade dos testes e validações.

Além dos dispositivos auxiliares, foi estruturado um ambiente controlado para a realização dos testes. Este ambiente foi configurado em uma sala com baixa incidência de luz solar, garantindo maior controle sobre as condições de iluminação. Para otimizar a iluminação do rosto utilizado nos testes, foi posicionada uma lanterna de celular próxima ao dispositivo, assegurando uma alta intensidade luminosa na região de interesse. Essa configuração foi estrategicamente planejada para minimizar interferências externas. A figura 3.31 ilustra como ficou o ambiente depois de estruturado.

Figura 3.31 – Ambiente de realização dos testes.



Fonte: Adaptado de [MakerPortal \(2024\)](#)

4 Resultados

4.1 Visão geral

Este item corresponde à exposição dos resultados obtidos por meio de testes realizados na Seção 3.5, e sua respectiva análise. Ao todo, foram 6 grupos de vídeos capturados, envolvendo os autores e mais um participante colaborativo. Um grupo de vídeos refere-se a um conjunto de aferições feitas de uma mesma pessoa em um mesmo momento do dia. A Tabela 4.1 mostra a relação entre a quantidade de vídeos e o número do grupo, além de identificar numericamente, para manter o anonimato, qual participante corresponde a cada grupo.

Tabela 4.1 – Divisão por grupos dos testes realizados.

Grupo (experimento)	Número do participante	Número de vídeos
1	2	19
2	3	20
3	1	11
4	1	9
5	2	22
6	2	9

Durante o processo de aferição, alguns testes foram excluídos devido a interferências, como oclusões no rosto do participante, ruído excessivo no dispositivo eletrocardiógrafo e outros fatores. Os testes dos Grupos 1 e 2 tiveram o intuito de avaliar como a frequência de amostragem e o tempo de captura interferem na precisão dos resultados. Já os Grupos 3, 4, 5 e 6 visaram fornecer uma amostra mais volumosa de dados para uma avaliação mais abrangente da precisão, considerando uma frequência de amostragem e um tempo de captura fixos, definidos com base nos resultados dos grupos anteriores.

Vale ressaltar que todos os métodos de obtenção do sinal PPG foram utilizados, permitindo uma análise da robustez e precisão dos mesmos. O mesmo se aplica às 27 regiões faciais adotadas, todas consideradas em cada vídeo gravado.

O resultado do processamento de cada vídeo foi armazenado em arquivos .csv. Cada método foi testado nas 27 regiões de interesse consideradas, com exceção do método SSR, que, devido a características intrínsecas à biblioteca utilizada para processamento, foi testado apenas na região central da testa, no landmark 151. Cada combinação de método e landmark resultava em 3 arquivos .csv: um para o sinal bruto, um para o sinal filtrado e outro para o espectro de frequência. Ao todo, as combinações de método com patch resultaram em 244 arquivos para cada vídeo, totalizando 21.960 amostras. Como cada amostra gravava 3 arquivos

.csv, 65.880 arquivos foram gerados, totalizando aproximadamente 80 GB de memória.

Devido à alta demanda de recursos computacionais, os vídeos foram gravados no protótipo e processados em outro dispositivo utilizando o mesmo algoritmo desenvolvido. Inicialmente, os primeiros arquivos .csv gerados eram registros brutos dos sinais obtidos dos vídeos, do eletrocardiograma e do sensor de pressão. Uma segunda etapa de processamento foi realizada para gerar dados que possibilitassem a análise, resultando em mais 20 GB de dados. Esses resultados incluem tanto gráficos dos sinais aferidos quanto análises numéricas dos erros, considerando as regiões de interesse, taxa de amostragem, tempo de análise e métodos de obtenção da PPG.

Vale ressaltar que o processo de aquisição da frequência respiratória, realizado por meio do dispositivo construído com Arduino e utilizando o módulo sensor de pressão, apresenta uma margem de erro inerente ao sistema. Esse erro, ao ser propagado, contribui para um aumento no erro absoluto ao comparar o valor considerado como real com o valor estimado pela técnica de rPPG.

4.2 Grupos 1 e 2

Os vídeos dos Grupos 1 e 2 foram submetidos a aferições com durações de 10 e 30 segundos, variando-se a frequência de amostragem nos valores de 30 Hz e 60 Hz. Os erros, que serão recorrentes nas análises subsequentes, referem-se à diferença absoluta em relação às medidas de referência, sendo o ECG empregado para a determinação da frequência cardíaca e o sensor de pressão para a mensuração da frequência respiratória. A escolha do erro absoluto como métrica se justifica pelo fato de as faixas típicas de frequências cardíacas e respiratórias serem bem delimitadas e, sobretudo, por não apresentarem variações de ordem de grandeza significativa. Dessa forma, um desvio de 1 bpm, por exemplo, pode ser interpretado de maneira direta e objetiva, independentemente do valor de referência em bpm.

Um fator relevante para a análise é que o Participante 3, de quem foram aferidos os vídeos do Grupo 2, possui pele escura. Este aspecto é significativo, pois, conforme mencionado anteriormente, a pigmentação da pele suscita questionamentos acerca de sua capacidade de interferência nas medições. Em indivíduos com pele mais escura, os algoritmos de fotople-tismografia remota tendem a apresentar maior imprecisão, um fenômeno que se confirma pelos resultados obtidos.

Para a avaliação geral dos dados, define-se como erro global a média do erro absoluto considerando todos os vídeos e cada combinação de método e patch, totalizando 4.626 amostras para o Grupo 1 e 4.880 amostras para o Grupo 2. Na comparação entre os erros globais desses dois grupos, o Grupo 1, referente ao participante de pele clara, apresentou um erro global de 5,22 bpm. Em contraste, o erro global para os vídeos do Grupo 2, do

Participante 3, de pele escura, foi de 21,90 bpm, mais de quatro vezes superior ao valor registrado para o Participante 2.

Embora esses valores aparentem indicar uma elevada imprecisão do dispositivo, é importante salientar que eles incluem resultados de patches bastante ruidosos, como os localizados em regiões com pelos faciais ou nas áreas onde a mangueira do cateter nasal causava obstrução na pele. Como será discutido adiante, a seleção apropriada dos métodos e patches, aliada ao uso de indicadores de qualidade do sinal, pode tornar os resultados das aferições significativamente mais precisos.

O método que proporcionou o menor erro da frequência cardíaca para as amostras do Grupo 1 foi o SSR, com um erro de 2,41 bpm. É relevante destacar que, conforme mencionado anteriormente, esse método analisa apenas o patch número 151, correspondente à região central da testa. Esta região, frequentemente, gera sinais de alta qualidade, justificando a vantagem de um método que se baseia exclusivamente nela em relação a outros métodos que consideram regiões faciais mais propensas a ruídos, o que eleva a média dos erros devido a grandes desvios em regiões ruidosas. Contudo, essa vantagem traz uma fragilidade significativa: ao focar apenas na testa, o método não possui robustez contra ruídos luminosos ou obstruções nesta região. Assim, quando a testa se torna a pior área para análise, o método não pode recorrer a outras regiões para aproximar o valor aferido ao verdadeiro. Este cenário ocorreu nos vídeos do Grupo 2. A Tabela 4.2 apresenta o erro do método SSR para cada vídeo. Observa-se que, embora em alguns casos, como nos vídeos 0, 2, 3 e 4, a precisão seja elevada, de forma geral, o sinal da testa mostrou-se bastante ruidoso.

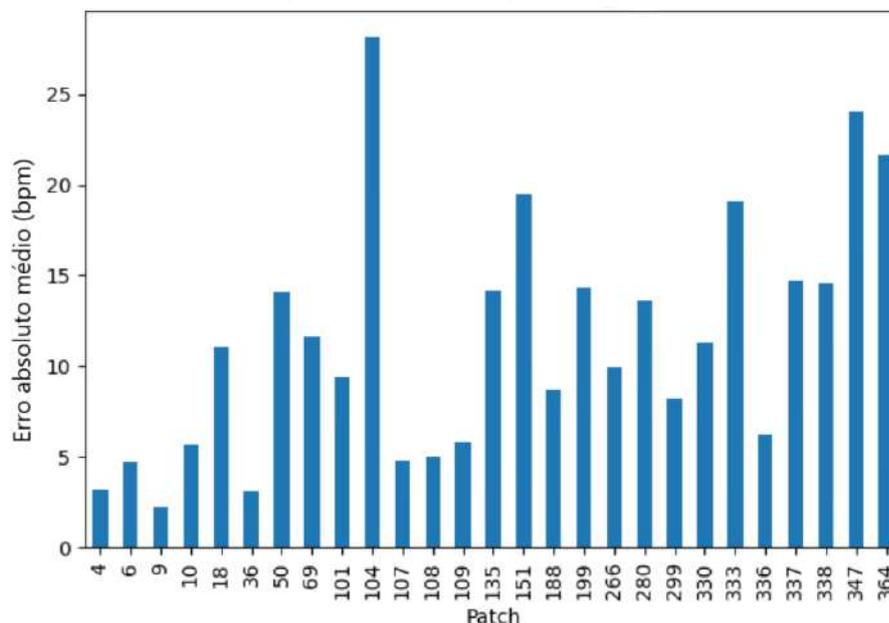
Tabela 4.2 – Erro absoluto médio, para a frequência cardíaca, do método SSR para cada vídeo do Grupo 2.

Número do vídeo	Erro absoluto médio (bpm)	Número do vídeo	Erro absoluto médio (bpm)
0	0,8252	10	20,6422
1	21,2740	11	14,0623
2	0,6003	12	31,3261
3	0,1424	13	71,3905
4	0,5859	14	61,2930
5	95,2444	15	65,5300
6	106,3300	16	63,7496
7	1,5520	17	17,6640
8	6,8429	18	61,6395
9	63,9259	19	67,7692

Tomando o vídeo 6 do Grupo 2 como exemplo, é possível observar, como ilustrado na Figura 4.1, que o patch número 151 é uma das regiões faciais que apresenta o maior erro, resultando em uma alta imprecisão no método SSR. A Tabela 4.3 compara o erro médio para diferentes métodos neste mesmo vídeo. Nota-se que o erro do método SSR é

consideravelmente maior em comparação aos outros métodos.

Figura 4.1 – Erro médio absoluto da frequência cardíaca em função de cada patch para o vídeo 6 do Grupo 2.



Fonte: Autores

Tabela 4.3 – Erro absoluto médio para diferentes métodos no vídeo 6 do Grupo 2.

Método	Erro absoluto médio (bpm)
CHROM	8,2157
GBGR	11,3829
GREEN	11,7266
ICA	10,4890
LGI	8,4166
OMIT	8,1526
PBV	10,0182
PCA	11,6202
POS	19,6222
SSR	106,3300

Para o caso do Participante 3, de pele escura, o método que apresentou o melhor desempenho foi o PBV, com um erro absoluto médio de 19,96 bpm. No Grupo 1, o patch que produziu o menor erro da frequência cardíaca foi o de número 9, localizado na região central da testa, logo acima da linha das sobrancelhas, com um erro médio de 2,44 bpm. E para a frequência respiratória, o menor erro foi o de número 188, localizado na região do nariz, próximo ao olho direito, com um erro médio de 6,32 iRPM, logo após o de número 9, com um erro médio de 6,52 iRPM. Para o Grupo 2, o patch que resultou no menor erro foi o da região do queixo, identificado como número 199, com um erro absoluto médio de 18,72

bpm. Já para a frequência respiratória, o patch de número 109, na região da testa, apresentou o menor erro médio, igual a 6,90 iRPM.

Os erros de frequência respiratória observados do Grupo 1 e 2 e da frequência cardíaca observados no Grupo 2 foram significativamente elevados, o que levanta dúvidas sobre a credibilidade das conclusões derivadas desse conjunto de dados. O alto desvio padrão dos erros sugere que muitas das tendências percebidas podem ser resultado de erros aleatórios, em vez de um fator de interferência concreto. Além disso, foi notado que, em alguns vídeos, os erros se concentravam em uma faixa elevada, sugerindo a possibilidade de erros sistemáticos. Essa suspeita foi reforçada ao se considerar a alternância da frequência de amostragem de 30 Hz para 60 Hz, levantando a hipótese de que o parâmetro de frequência de amostragem pode não ter sido devidamente atualizado em algum trecho do algoritmo de análise. Isso teria resultado em uma frequência aferida equivocadamente dobrada. Com base nisso, os resultados do Grupo 2 foram descartados para a análise referente à influência da frequência de amostragem e do tempo de aferição, utilizando-se apenas os resultados do Grupo 1 para essa avaliação.

As aferições realizadas a partir de vídeos de 30 segundos apresentaram resultados superiores em comparação com aquelas baseadas em vídeos de 10 segundos. Nos vídeos do Grupo 1, o erro médio da frequência cardíaca para os vídeos de 10 segundos foi de 5,99 bpm, com o patch número 10, localizado na região da testa, registrando o menor erro médio de 2,63 bpm. E da frequência respiratória foi de 8,99 iRPM, com o patch número 188, localizado na região do nariz, com o menor erro médio de 6,53 iRPM. Em contrapartida, para os vídeos de 30 segundos, a média do erro foi de 4,53 bpm e 6,12 iRPM, com o patch número 101, na região da bochecha direita, apresentando um erro médio da frequência cardíaca de 1,91 bpm, e o patch número 364, na região da bochecha direita, apresentando o menor erro médio da frequência respiratória de 4,68 iRPM. Esses resultados estão alinhados com o esperado, uma vez que um tempo de 30 segundos permite que ruídos momentâneos de movimento ou luminosidade percam relevância diante de um maior número de amostras, resultando em maior robustez dos resultados.

Quanto à frequência de amostragem, os vídeos capturados a 30 Hz apresentaram resultados melhores do que aqueles capturados a 60 Hz. Idealmente, uma amostragem mais elevada deveria melhorar a qualidade das aferições, entretanto, considerando o baixo poder computacional do dispositivo utilizado, que além de capturar frames, operava uma interface gráfica interativa com o usuário, a maior propensão à perda de quadros durante capturas a 60 Hz justifica esse resultado. O erro médio para as amostras capturadas a 60 fps foi de 5,77 bpm e 8,73 iRPM, com o melhor patch sendo o número 36, correspondente à bochecha direita, e um erro médio da frequência cardíaca de 2,57 bpm, e o patch de número 188, na região do nariz, apresentando o menor erro médio de 6,59 iRPM. Para os vídeos capturados a 30 fps, o erro médio foi de 4,72 bpm e 6,36 iRPM, com o melhor patch sendo o número 9, da região da testa, com um erro médio da frequência cardíaca de 2,05 bpm, e o melhor patch

da frequência respiratória sendo o número 104, da região da testa, com um erro médio de 4,85 iRPM.

Como mencionado anteriormente, e reafirmado por esses novos dados, a região da testa forneceu um sinal de qualidade relativamente boa nos vídeos do Grupo 1. O método SSR, que se baseia exclusivamente na região da testa, destacou-se novamente como o método com menor erro médio em todas as subdivisões analisadas, tanto para vídeos de 30 e 10 segundos quanto para vídeos amostrados a 30 e 60 Hz. Esse padrão se repetirá nas análises dos próximos grupos de vídeos e, portanto, a partir deste ponto, o melhor método considerado será aquele que apresenta o menor erro médio de frequência cardíaca, excluindo o método SSR.

4.3 Grupos 3, 4, 5 e 6

Observou-se que os resultados dos vídeos com duração de 10 segundos frequentemente apresentavam discrepâncias significativas em relação aos valores reais, enquanto que para vídeos de 30 segundos, a precisão era consideravelmente maior. Diante disso, novos grupos de vídeos foram criados com o objetivo de avaliar a precisão do sistema nas condições consideradas ideais, ou seja, com uma frequência de amostragem de 30 Hz e duração de 30 segundos.

Os Grupos 3 e 4 consistem em vídeos gravados de um mesmo participante em diferentes momentos do dia, permitindo analisar a variação dos resultados ao longo do tempo. No Grupo 5, uma alteração metodológica foi implementada: funções não utilizadas no código foram desativadas para agilizar o andamento dos testes, o que possibilitou a realização de um número maior de aferições. Além disso, com as condições experimentais estabilizadas, foi possível dedicar maior atenção aos indicadores de qualidade do sinal, permitindo uma análise mais detalhada de como o erro varia em função desses indicadores.

As aferições do Grupo 6 foram realizadas utilizando uma metodologia que sincroniza a captura de ECG com os frames de vídeo, o que possibilitou a análise da sincronia entre as curvas do eletrocardiograma e da PPG. Apesar dessa sincronia, os dados deste grupo também foram considerados para avaliar a acurácia do sistema, uma vez que a sincronização não interfere na precisão dos resultados obtidos.

Em relação à frequência cardíaca, o participante 2 apresentou os resultados de maior precisão, com o Grupo 5 destacando-se como o de melhor desempenho, registrando um erro médio de 2,81 bpm. O Grupo 6 também mostrou um erro global relativamente baixo, com um valor de 3,14 bpm. Por outro lado, os erros médios globais para o participante 1 foram superiores, alcançando 4,11 bpm no Grupo 3 e 5,56 bpm no Grupo 4.

Quanto à frequência respiratória, o participante 1 obteve os resultados de maior precisão, com o Grupo 3 como o de melhor desempenho, com um erro médio igual a 3,02

iRPM. O Grupo 6 também apresentou um desempenho notável, com um erro médio igual a 3,93 iRPM. Enquanto o Grupo 4 apresentou 4,33 iRPM e o Grupo 5 obteve um valor maior, com 5,57 iRPM.

A Figura 4.2 ilustra como o erro da frequência cardíaca varia por região facial em cada grupo de vídeos. Nota-se uma semelhança nos resultados dos grupos pertencentes ao mesmo participante. Por exemplo, o participante 1 apresenta um grande erro nos patches 199, 135 e 18, tanto no Grupo 3 quanto no Grupo 4. No caso do participante 2, os patches com maiores erros são os de números 18, 135, 199 e 364.

Outro aspecto importante observado nesse conjunto de dados é que, embora as melhores regiões de interesse variem entre os indivíduos, os patches que resultam em maior precisão nas aferições geralmente estão concentrados na região da testa e das bochechas. Esse fato pode ser confirmado ao se observar a distribuição numérica dos patches no rosto, conforme ilustrado na Figura 3.3. Apesar de a imagem ser pequena e dificultar uma visualização clara da distribuição dos patches, uma compreensão mais detalhada pode ser obtida consultando a referência bibliográfica.

Na análise da frequência respiratória, não foi possível identificar uma relação clara entre a distribuição numérica do erro por região dos patches faciais, devido à propagação de erro mencionada anteriormente. Contudo, foi possível observar padrões que indicam melhores resultados em regiões específicas do rosto. Para o participante 1 nos Grupos 3 e 4, os patches que apresentaram os melhores resultados foram o patch 10, localizado na região da testa, e o patch 266, situado na bochecha esquerda. Já para o participante 2, foi identificado um padrão de melhores desempenhos nos patches localizados na região da testa, com os patches 10, 333 e 337, além de um bom desempenho na região do nariz, representado pelo patch de número 6.

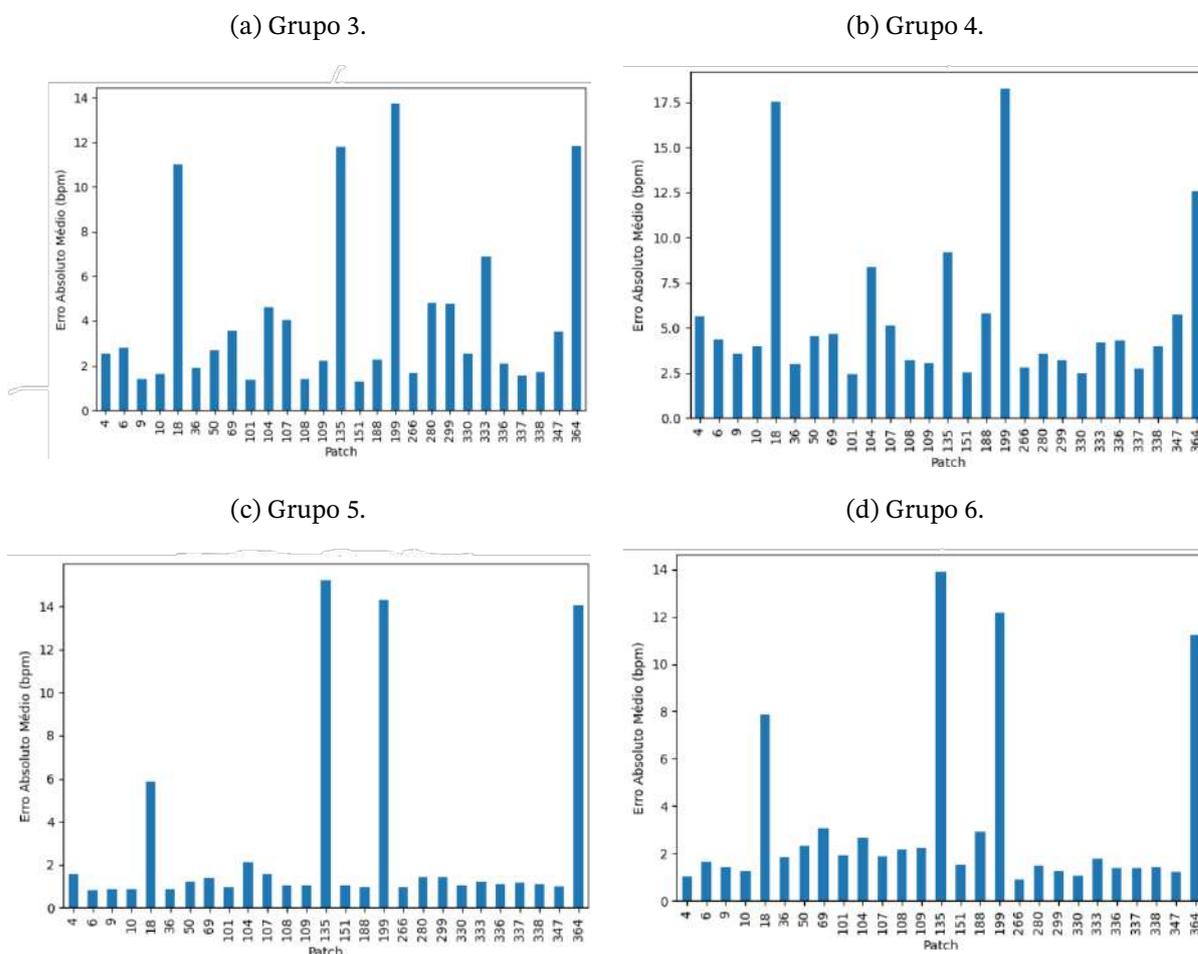
Esses padrões podem ser visualizados na imagem 4.3, que ilustra a distribuição dos patches faciais e seus respectivos resultados em relação à precisão da frequência respiratória. Esses achados da frequência cardíaca e respiratória corroboram o exposto na Seção 2.3, indicando que as regiões faciais que produzem o melhor sinal variam conforme o indivíduo.

Quanto aos métodos avaliados, o que apresentou o melhor desempenho em termos de precisão foi o método CHROM para a frequência cardíaca. Esse método produziu os menores erros absolutos para os grupos 3, 4 e 5, com valores respectivos de 2,50 bpm, 3,50 bpm e 2,16 bpm. Por outro lado, para o grupo 6, o método que obteve o melhor resultado foi o GBGR, com um erro absoluto médio de 1,93 bpm.

Para a frequência respiratória, os métodos que apresentaram melhor precisão variaram entre os diferentes grupos avaliados. No caso do Grupo 3, o método PCA destacou-se, atingindo o menor erro absoluto com um valor de 2,33 iRPM. Já para o Grupo 4, o melhor desempenho foi alcançado pelo método GRGB, com um erro absoluto de 3,34 iRPM.

Por outro lado, nos Grupos 5 e 6, os métodos POS e PBV mostraram-se mais eficazes.

Figura 4.2 – Erro absoluto médio da frequência cardíaca em função de cada patch para os Grupos 3, 4, 5 e 6.



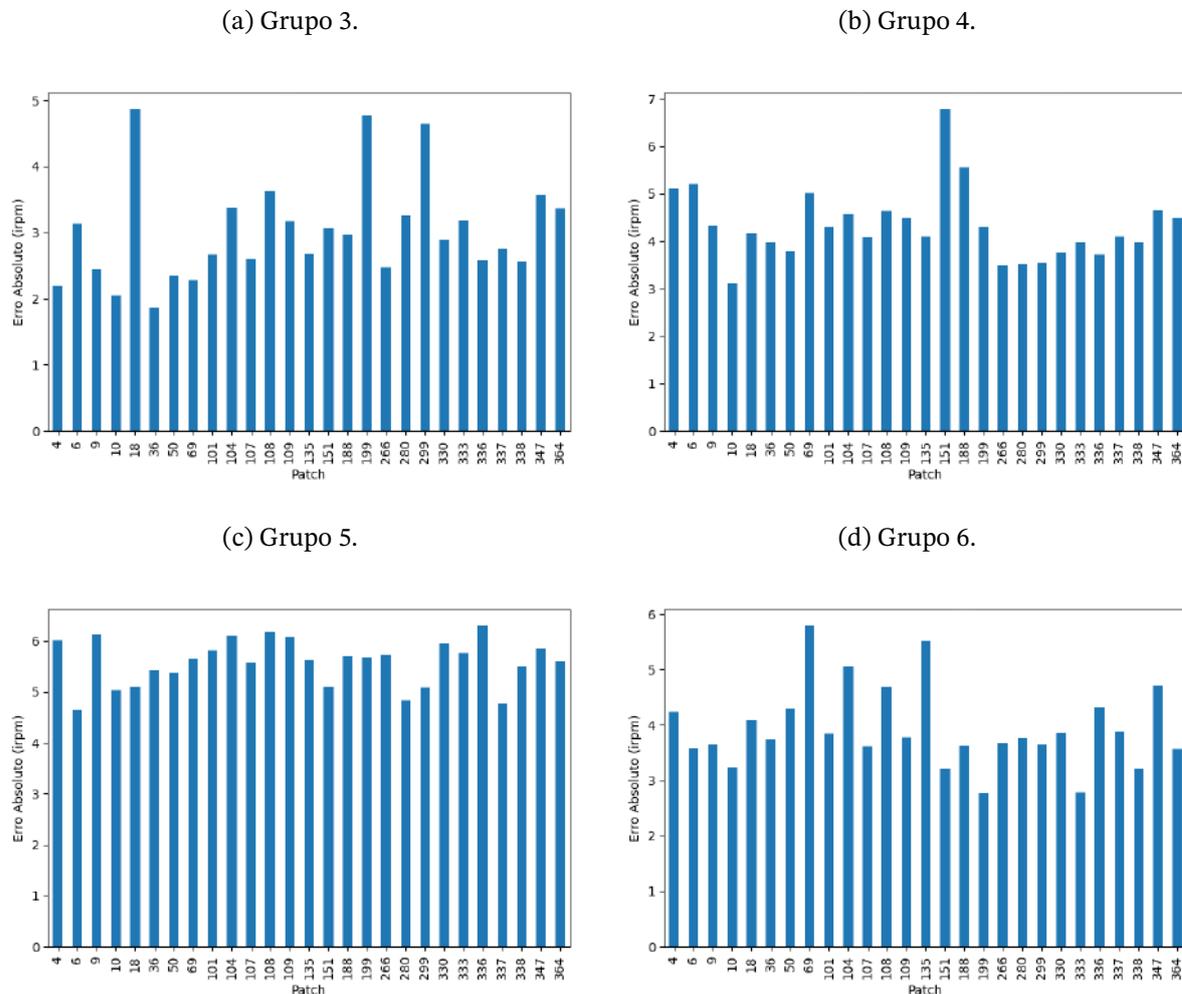
Fonte: Autores

Para o Grupo 5, o método POS alcançou um erro de 5,12 iRPM, enquanto no Grupo 6 o método PBV obteve uma precisão superior, com um erro absoluto de 3,18 iRPM.

Até este ponto da análise, observou-se que os valores dos erros absolutos médios se mantiveram consistentemente acima de 1 bpm e 2 iRPM. Tal resultado pode gerar questionamentos sobre a precisão do dispositivo desenvolvido. No entanto, é importante considerar que os erros globais apresentados até agora incluem tanto medições altamente precisas quanto medições com maior imprecisão. Isso implica que a análise agregada pode mascarar o verdadeiro potencial de precisão do dispositivo. Por exemplo, os erros globais iniciais dos grupos 3, 4, 5 e 6 eram de 4,11 bpm e 3,01 iRPM, 5,56 bpm e 3,34 iRPM, 2,81 bpm e 5,57 iRPM, 3,14 bpm e 3,93 iRPM, respectivamente. Contudo, ao restringir a análise às amostras correspondentes aos melhores métodos de cada grupo, os erros caem significativamente para 2,50 bpm e 2,33 iRPM, 3,50 bpm e 3,34 iRPM, 2,16 bpm e 5,12 iRPM, 1,93 bpm e 3,18 iRPM, respectivamente.

Outra observação relevante é que, mesmo nessas amostras reduzidas, todas as regiões

Figura 4.3 – Erro absoluto médio da frequência respiratória em função de cada patch para os Grupos 3, 4, 5 e 6.



Fonte: Autores

de interesse (ROIs) da face foram consideradas. Isso sugere que ainda há margem para aumentar a precisão, desde que escolhas criteriosas sejam feitas em relação às ROIs. Um fato notável é que, ao inverter a abordagem, ou seja, ao considerar apenas amostras das melhores regiões faciais (independentemente do método utilizado), os erros absolutos médios se reduzem ainda mais. Essa constatação indica que a escolha de regiões faciais apropriadas exerce maior impacto na redução dos erros do que a escolha do método de geração da curva PPG.

As Tabelas 4.4 e 4.5 apresentam os erros absolutos médios para as três melhores regiões faciais de cada grupo analisado. É possível observar que os erros associados a essas regiões são significativamente menores em comparação com os resultados obtidos ao se adotar a metodologia baseada exclusivamente na escolha do melhor método.

Tabela 4.4 – Erros absolutos médios da frequência cardíaca para as 3 melhores regiões faciais de cada grupo analisado.

Grupo	Número do patch	Erro absoluto médio (bpm)	Região do rosto
3	108	1,3857	Testa
3	101	1,3417	Bochecha esquerda
3	151	1,2891	Testa
4	101	2,4046	Testa
4	151	2,5182	Testa
4	330	2,4783	Bochecha direita
5	6	0,8420	Nariz
5	9	0,8685	Testa
5	10	0,8833	Testa
6	330	1,0587	Bochecha direita
6	266	0,9050	Bochecha direita
6	4	1,0203	Nariz

Tabela 4.5 – Erros absolutos médios da frequência respiratória para as 3 melhores regiões faciais de cada grupo analisado.

Grupo	Número do patch	Erro absoluto médio (iRPM)	Região do rosto
3	36	1,8688	Bochecha direita
3	10	2,0545	Testa
3	4	2,1952	Nariz
4	10	3,1094	Testa
4	266	3,4906	Bochecha esquerda
4	280	3,5260	Bochecha esquerda
5	6	4,6446	Nariz
5	280	4,8417	Bochecha esquerda
5	337	4,7586	Testa
6	338	3,2076	Testa
6	333	2,7772	Testa
6	10	3,2461	Testa

As Tabela 4.4 e 4.5 apresentam algumas das melhores amostras obtidas para cada grupo analisado. Embora a quantidade de amostras destacadas seja reduzida, o objetivo principal dessas tabelas é ilustrar que é possível alcançar resultados altamente precisos ao se adotar uma metodologia criteriosa para a escolha do método de análise e da região de interesse. No entanto, seria de pouca relevância utilizar essa tabela isoladamente como justificativa para a existência de medições precisas. Isso porque os números totais de amostras para os grupos 3, 4, 5 e 6 são, respectivamente, 2684, 2196, 5368 e 2196. Dessa forma, a inclusão de apenas cinco amostras representaria apenas 0,17%, 0,23%, 0,09% e 0,17% do total de amostras de cada grupo, respectivamente.

Com base nesses números, não é possível assegurar que a alta precisão observada nas

amostras destacadas seja necessariamente um resultado direto da metodologia empregada, pois existe a possibilidade de que esses valores sejam fruto da aleatoriedade das medições.

A boa notícia, contudo, é que ao expandir a análise para as 1000 melhores amostras de cada grupo, representando 37,26%, 45,53%, 18,62% e 37,26% do total de amostras dos grupos 3, 4, 5 e 6, respectivamente, observa-se que os erros absolutos médios continuam significativamente baixos. Esse resultado reforça a eficácia da metodologia proposta, indicando que é possível alcançar medições de alta precisão mediante a aplicação de critérios adequados para a seleção de métodos e regiões de interesse.

Tabela 4.6 – Amostras com o menor erro absoluto da frequência cardíaca para 5 vídeos de cada grupo.

Grupo	Número do vídeo	Método	Número do patch	Região do rosto	Erro absoluto médio (bpm)
3	8	CHROM	280	Bochecha direita	0,0016
3	5	ICA	50	Bochecha esquerda	0,0027
3	0	CHROM	69	Testa	0,0028
3	1	GBGR	299	Testa	0,0054
3	9	CHROM	18	Queixo	0,0047
4	7	CHROM	109	Testa	0,0002
4	8	ICA	299	Testa	0,0026
4	6	PBV	338	Testa	0,0042
4	5	ICA	50	Bochecha esquerda	0,0063
4	3	GBGR	333	Testa	0,0176
5	2	CHROM	333	Testa	0,0000
5	19	GREEN	4	Nariz	0,0010
5	7	PCA	199	Queixo	0,0032
5	20	PBV	36	Bochecha esquerda	0,0045
5	0	POS	135	Bochecha esquerda	0,0063
6	3	ICA	151	Testa	0,0004
6	4	GBGR	338	Testa	0,0046
6	6	ICA	330	Bochecha direita	0,0050
6	0	CHROM	104	Testa	0,0051
6	2	PBV	151	Testa	0,0056

Tabela 4.7 – Amostras com o menor erro absoluto da frequência respiratória para 5 vídeos de cada grupo.

Grupo	Número do vídeo	Método	Número do patch	Região do rosto	Erro absoluto médio (iRPM)
3	8	CHROM	10	Testa	0,1911
3	3	CHROM	10	Testa	0,2098
3	2	GBGR	10	Testa	0,2623
3	4	PCA	101	Bochecha direita	0,2740
3	9	PCA	101	Bochecha direita	0,2740
4	2	ICA	336	Testa	0,2286
4	3	GBGR	10	Testa	0,2569
4	1	GBGR	10	Testa	0,2664
4	9	GREEN	109	Testa	0,2759
4	4	GBGR	10	Testa	0,2857
5	4	GREEN	10	Testa	0,3823
5	1	PBV	10	Testa	0,4091
5	6	POS	10	Testa	0,4196
5	13	GREEN	109	Testa	0,4300
5	9	GBGR	101	Bochecha direita	0,4510
6	7	PBV	109	Testa	0,1131
6	2	ICA	18	Queixo	0,2616
6	1	CHROM	109	Testa	0,3236
6	0	GREEN	101	Bochecha direita	0,3808
6	8	PCA	10	Testa	0,4385

Especificamente, entre as 1000 melhores amostras analisadas da frequência cardíaca de cada grupo, todas apresentam erros absolutos inferiores a 0,39 bpm no grupo 3 e 1,12 bpm no grupo 4. Para os grupos 5 e 6, os resultados são ainda mais animadores, com erros máximos de 0,32 bpm e 0,59 bpm, respectivamente. Já para as amostras da frequência respiratória, o Grupo 3 e 4 obtiveram os melhores resultados com erros de 0,20 iRPM a 0,30 iRPM, enquanto o Grupo 5 e 6 obtiveram erros de aproximadamente 0,12 iRPM a 3,36 iRPM, o que mostra um erro relativo bem maior em relação aos vídeos do participante 1. Esses dados demonstram que a metodologia proposta é capaz de produzir medições consistentes e precisas, desde que sejam realizadas seleções adequadas de amostras.

No geral, os métodos ICA e PBV apresentaram os piores desempenhos, demonstrando-se menos robustos na avaliação da frequência cardíaca. Por outro lado, os métodos CHROM, LGI, OMIT, PCA e POS mostraram uma precisão relativamente superior. O método SSR também apresentou bons resultados, exceto nos casos em que o sinal proveniente da região da testa estava bastante ruidoso. Para a frequência respiratória, o método POS apresentou o pior desempenho, e os métodos GRGB, ICA, PBV, CHROM e LGI mostraram uma precisão relativamente superior.

A Tabela 4.8 destaca algumas das melhores combinações entre a região de interesse

e o método PPG utilizado. Observa-se que, embora o método PBV tenha apresentado um dos piores desempenhos no geral, quando restrito ao patch de número 266, ele produziu um dos melhores resultados para o grupo 5. Isso sugere que nem sempre a melhor combinação entre patch e método será obtida a partir do melhor método associado ao melhor patch.

Tabela 4.8 – Erro absoluto da frequência cardíaca das melhores combinações de patch e método.

Grupo	Número do patch	Região do rosto	Método	Erro absoluto médio (bpm)
3	109	Testa	PCA	0,41442
3	101	Bochecha esquerda	GBGR	0,41961
3	50	Bochecha esquerda	CHROM	0,45833
4	337	Testa	PCA	0,89234
4	330	Bochecha direita	POS	0,89440
4	336	Testa	CHROM	0,91596
5	333	Testa	CHROM	0,62129
5	266	Bochecha direita	PBV	0,64880
5	333	Testa	PCA	0,68391
6	36	Bochecha esquerda	POS	0,34634
6	101	Bochecha esquerda	PCA	0,37321
6	330	Bochecha direita	CHROM	0,45092

Escolhendo o método CHROM com os patches mais adequados e levando em consideração os pesos de cada grupo, dados pela quantidade de vídeos em cada um deles, o erro absoluto médio considerando todos os vídeos é de 0,61 bpm. Aplicando a mesma abordagem para o método PCA, obtém-se também um erro de 0,61 bpm.

O principal problema dessa abordagem é que ela depende do conhecimento prévio das melhores combinações entre método e região de interesse. Como discutido, a melhor região de interesse varia significativamente de pessoa para pessoa. Em relação ao melhor método, embora sejam mais previsíveis, ainda existem diferenças importantes: alguns são projetados para serem mais robustos em situações de movimento, enquanto outros apresentam melhor desempenho em condições mais estáveis. Ainda assim, o comportamento do participante durante a aferição é uma variável experimental que influencia o desempenho.

Até aqui, constatou-se que o dispositivo desenvolvido é capaz de aferir, para muitas amostras de um vídeo, valores muito precisos da frequência cardíaca. Contudo, esses valores acabam sendo mascarados por outros que apresentam alta imprecisão. Além disso, ficou claro que a escolha da melhor região de interesse e do melhor método é volátil, dependendo das características experimentais e dos participantes.

Dessa forma, uma solução promissora seria uma abordagem holística, que considere todas as amostras, seguida por uma seleção das melhores aferições baseada em algum critério de qualidade. Em outras palavras, a abordagem proposta consiste em prever quais amostras teriam maior probabilidade de produzir resultados precisos, utilizando indicadores

de qualidade para orientar essa seleção.

Para avaliar a qualidade dos sinais capturados, foram implementados quatro tipos de indicadores de qualidade de sinal (Signal Quality Indicators - SQI). O primeiro indicador, denominado SQI1, é baseado no método já proposto na Seção 3.4.3 e demonstrado na Equação 3.6.

Os outros três indicadores foram desenvolvidos utilizando a métrica de relação sinal-ruído (Signal-to-Noise Ratio - SNR). Essa abordagem foi escolhida com base no estudo de [Elgendi, Martinelli e Menon \(2024\)](#), que aponta o SNR como um dos índices de qualidade de sinal mais eficazes para a rPPG, oferecendo melhor desempenho na distinção entre sinais de alta e baixa qualidade.

Os próximos indicadores de qualidade de sinal foram calculados utilizando a função `scipy.stats.signaltonoise` da biblioteca SciPy, que avalia a relação sinal-ruído dos dados. Cada SQI foi definido com base em uma abordagem específica de análise do sinal:

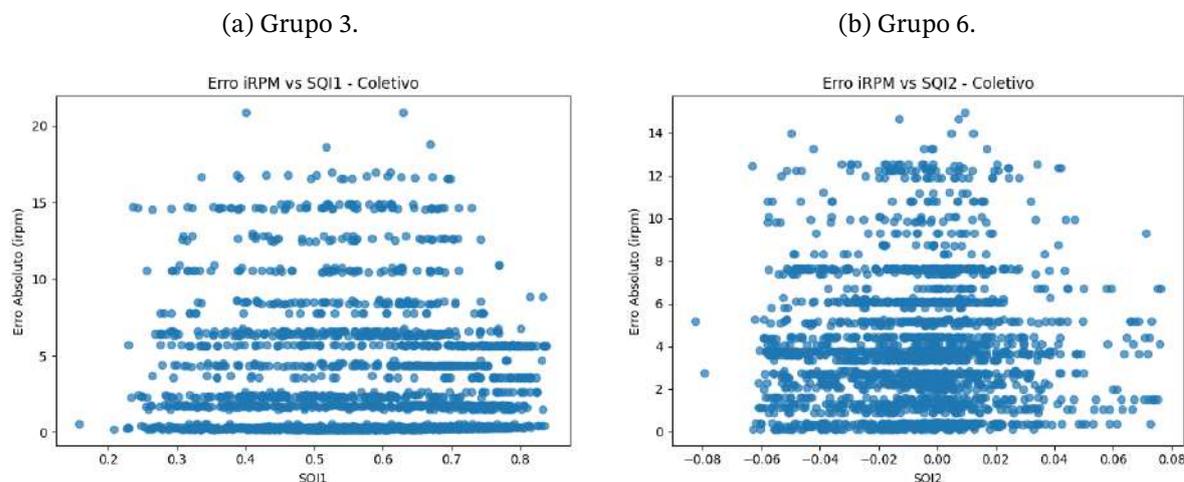
1. SQI2: Este indicador realiza a análise do SNR considerando o sinal completo, retornando uma métrica global que reflete a qualidade média do sinal ao longo de toda sua extensão.
2. SQI3: Neste caso, o SNR foi calculado em uma janela deslizante de 5 segundos. O indicador retorna o maior valor de SNR encontrado, refletindo os trechos do sinal onde a qualidade é mais elevada.
3. SQI4: Também utilizando uma janela de 5 segundos, este indicador retorna o menor valor absoluto de SNR dentro do intervalo analisado. Essa métrica destaca os momentos de menor qualidade no sinal, servindo como uma referência para identificar os trechos mais ruidosos.

Essa abordagem, ao combinar análises globais e localizadas, permite uma avaliação mais detalhada da qualidade do sinal, identificando tanto os momentos de maior confiabilidade quanto aqueles mais suscetíveis a ruídos e interferências.

A seguir, será apresentada a relação entre os indicadores de qualidade de sinal e os erros das amostras, com foco exclusivo na frequência cardíaca. Essa escolha foi feita porque, ao relacionar os SQIs com a frequência respiratória, os gráficos resultantes não apresentaram dados suficientemente claros para uma análise precisa da eficácia desses indicadores nesse contexto. Como é possível ver na figura 4.4.

A análise da frequência cardíaca, por outro lado, demonstrou padrões mais consistentes e interpretáveis, permitindo avaliar de forma mais confiável a influência dos SQIs sobre a precisão das medições. Essa abordagem destaca a aplicabilidade dos indicadores no contexto da frequência cardíaca, enquanto reforça a necessidade de metodologias adicionais para a análise da frequência respiratória.

Figura 4.4 – Distribuição do erro absoluto da frequência respiratória das amostras do Indicador SQI1 e SQI2.



Fonte: Autores

As figuras 4.5, 4.6, 4.7 e 4.8 mostram como os erros das amostras se distribuem de acordo com os indicadores de qualidade utilizados. Embora apresentem dados apenas dos vídeos do grupo 3, o comportamento observado para cada indicador foi semelhante nos outros grupos, permitindo que as conclusões feitas possam ser generalizadas, como será discutido mais adiante.

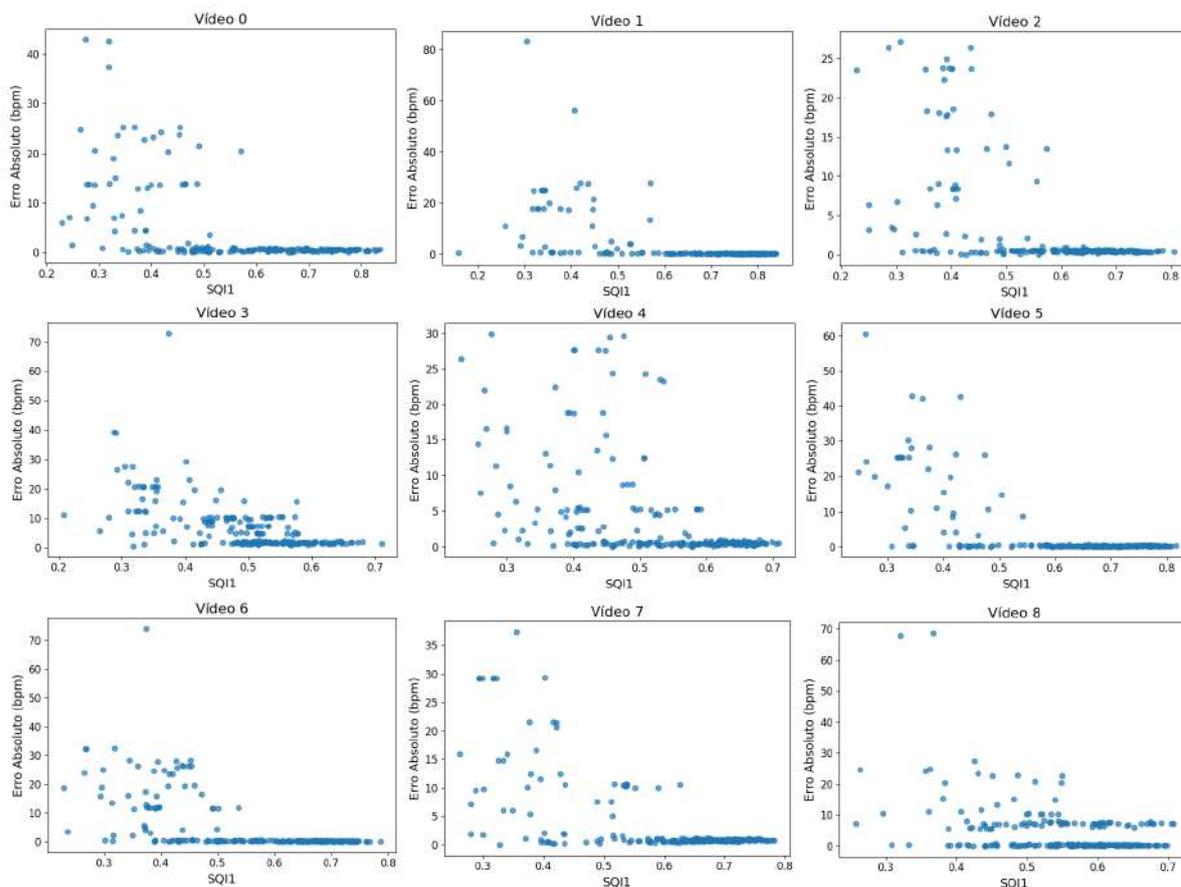
Nota-se que, para os indicadores SQI2 e SQI3, não foi identificado nenhum padrão específico que permita distinguir claramente amostras boas de amostras ruins. Por outro lado, no caso dos indicadores SQI1 e SQI4, observa-se que as amostras tendem a se concentrar em regiões onde o indicador de qualidade é maior. Isso sugere que a probabilidade de uma amostra ser considerada boa aumenta à medida que o valor do indicador cresce.

Apesar dessa correlação ser evidente em muitos casos, há exceções que precisam ser consideradas. Para o SQI1, por exemplo, no vídeo 8 do grupo 3, mesmo com o aumento do indicador de qualidade, ainda é possível observar uma concentração significativa de amostras com erros elevados. Já no caso do SQI4, embora não haja uma forte aglomeração de amostras com erros grandes na região onde o indicador é mais alto, vídeos como 3 e 6 mostram que nem sempre a amostra com o maior indicador terá o menor erro. Além disso, há relativamente poucas amostras boas com um indicador de qualidade elevado.

Esses fatores indicam que, caso o SQI4 seja utilizado como limiar para decidir se uma aferição é válida ou deve ser refeita, pode ser significativamente mais difícil alcançar uma medição que atenda aos critérios desejados.

Para demonstrar que esse comportamento é consistente em todos os grupos, foram gerados gráficos que ilustram como o erro absoluto médio varia à medida que cada indicador de qualidade é utilizado para descartar amostras que, teoricamente, seriam consideradas

Figura 4.5 – Distribuição do erro absoluto das amostras de acordo com o indicador SQI1 para vídeos do grupo 3.



Fonte: Autores

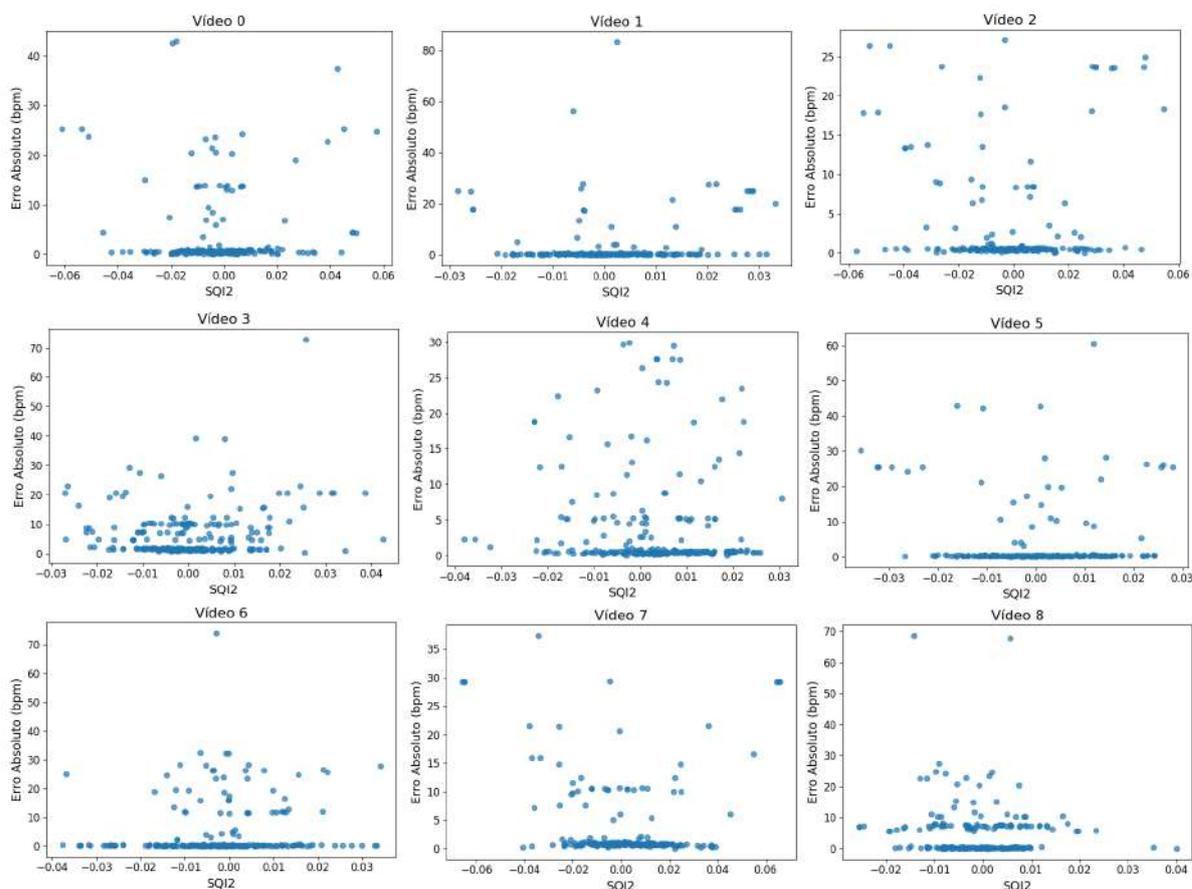
ruins. Nesse processo, eliminam-se as amostras com os menores valores dos indicadores de qualidade, sob a premissa de que essas amostras possuem maior incerteza em relação ao resultado da aferição.

As figuras 4.9, 4.10, 4.11 e 4.12 apresentam os resultados do uso dos indicadores de qualidade como limiares para eliminar amostras.

Observando o gráfico relativo ao SQI3, na figura 4.11, nota-se que o valor médio do erro diminui à medida que excluímos amostras com valores do índice menores que 0,12. Todavia, quando o limiar continua aumentando, o erro médio volta a subir, indicando que amostras boas estão sendo descartadas, aumentando, assim, a proporção de amostras ruins. Com um limiar muito elevado, maior que 0,250, o valor do erro médio cai abaixo de 0,5 bpm. Ainda assim, surge outro problema: apenas uma amostra possui valor de qualidade maior que o limiar. Isso implica que, ao considerar um limiar de 0,250, teríamos uma chance de 1 em 12.444 de realizar uma aferição válida, o que é inviável do ponto de vista prático.

O mesmo comportamento é observado na figura 4.10, agora para o SQI2. Observa-se uma queda do erro até um limiar próximo a -0,01, seguida de um drástico aumento

Figura 4.6 – Distribuição do erro absoluto das amostras de acordo com o indicador SQI2 para vídeos do grupo 3.



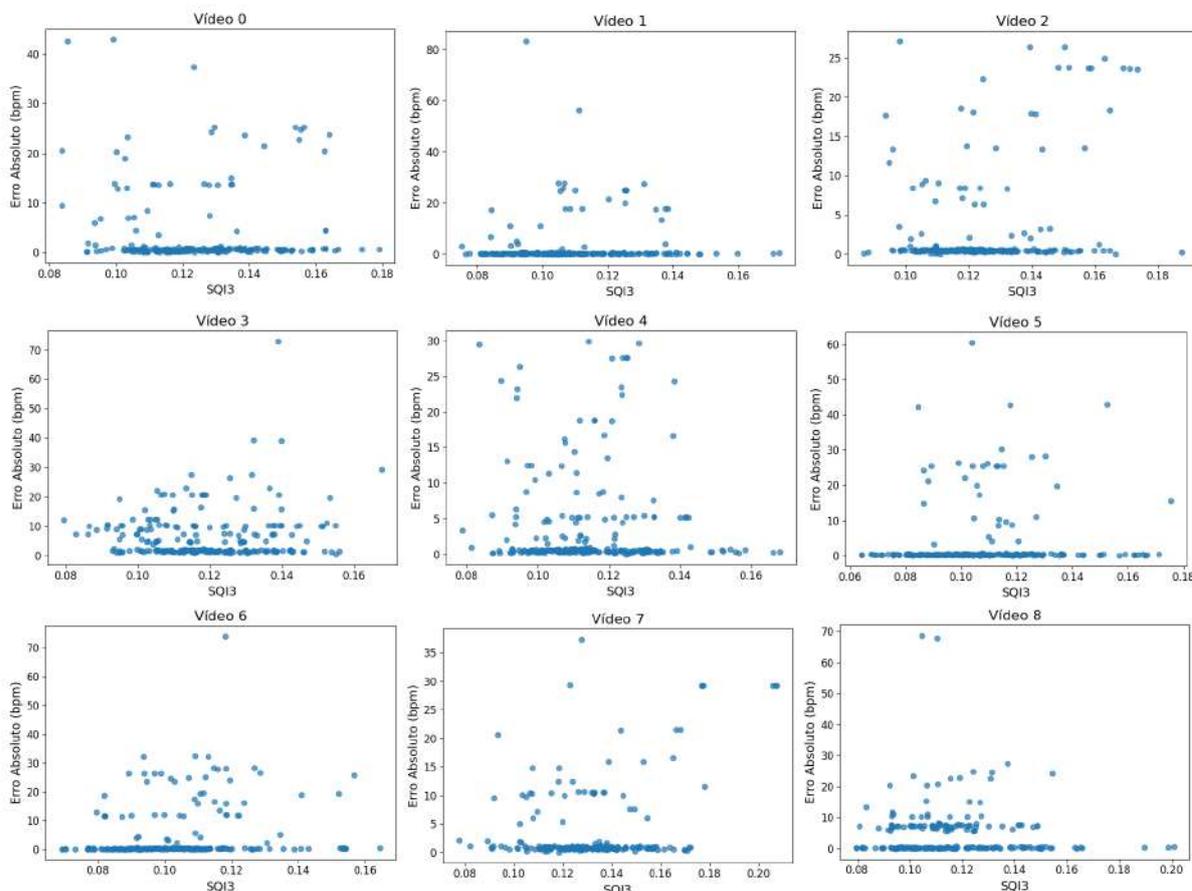
Fonte: Autores

para limiares maiores. Ao final, o erro cai abaixo de 1 bpm, mas apenas 36 amostras são consideradas.

Já nos gráficos do erro em função do limiar de SQI1 e SQI4, observam-se resultados mais consistentes. Nota-se que o erro absoluto apresenta uma tendência clara de diminuição com o aumento do limiar do indicador. Para o SQI4, no limiar que produz o primeiro erro médio abaixo de 1 bpm, são consideradas 145 amostras, correspondendo a apenas 1,17% de todas as amostras. Portanto, esse limiar também é inviável como parâmetro de descarte de um teste. Por outro lado, para o caso do SQI1, mostrado na figura 4.9, quando o limiar é aumentado até que o erro caia abaixo de 1 bpm, observa-se que 8.675 amostras são consideradas, o que corresponde a 69,71% de todas as amostras. Com um limiar de 0,6, ainda são consideradas no mínimo 7.361 amostras, com um valor de erro de aproximadamente 0,75 bpm. Isso sugere que, ao descartar todos os testes com SQI1 abaixo de 0,6, teríamos uma chance de 59% de obter uma aferição válida, o que é viável.

Uma observação importante é que o índice de qualidade, embora tenda a selecionar os melhores resultados quando utilizado como limiar, não é totalmente confiável. A distribuição

Figura 4.7 – Distribuição do erro absoluto das amostras de acordo com o indicador SQI3 para vídeos do grupo 3.

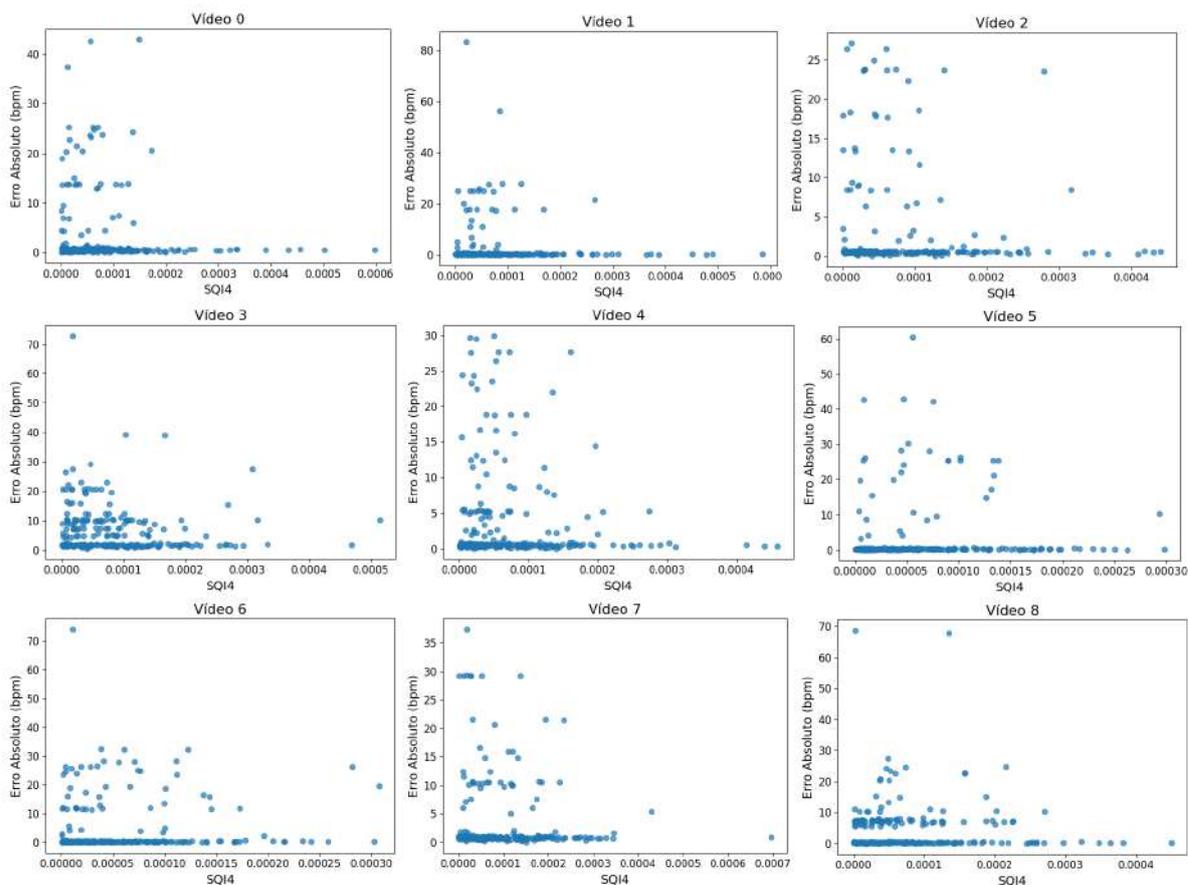


Fonte: Autores

dos erros no vídeo 8 do grupo 3, mostrada na figura 4.5, evidencia que, em alguns casos, o erro pode ser elevado mesmo quando o indicador de qualidade SQI1 é alto. O mesmo comportamento é observado para o SQI4, como ilustrado nos gráficos dos vídeos 6 e 3 na figura 4.8. Esse comportamento, em que um erro alto ocorre para um indicador de qualidade bom, foi observado em alguns poucos vídeos. Isso justifica o aumento do erro à medida que o limiar se aproxima de seus valores máximos. No caso do SQI1, por exemplo, nota-se um aumento do erro após o limiar ultrapassar o valor de 0,8. Apesar disso, o aumento foi pequeno inicialmente e, quando se tornou expressivo, ultrapassando 1 bpm, apenas uma amostra era considerada na análise.

Diante das análises realizadas, a escolha adotada foi utilizar o SQI1 como limiar para descartar amostras previstas como ruins. Essa decisão foi fundamentada no comportamento consistente do SQI1, que apresentou uma clara tendência de redução do erro absoluto médio à medida que o limiar era aumentado, permitindo selecionar as amostras de maior qualidade de forma prática e eficiente. Além disso, a proporção de amostras válidas para limiares como 0,6 mostrou-se viável, garantindo uma taxa de 59% de aferições precisas com um erro médio

Figura 4.8 – Distribuição do erro absoluto das amostras de acordo com o indicador SQI4 para vídeos do grupo 4.



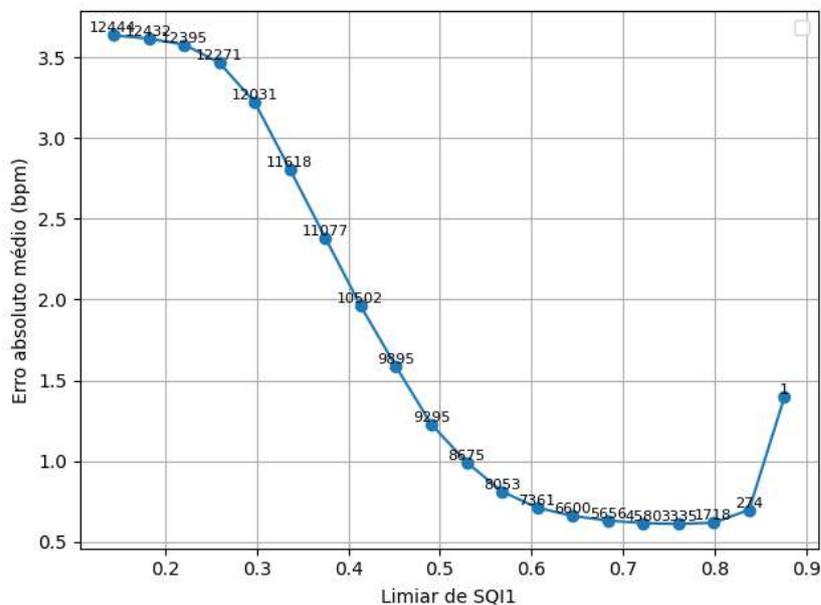
Fonte: Autores

de aproximadamente 0,75 bpm, mesmo considerando as variações experimentais observadas nos dados.

As Tabelas 4.9 e 4.10 apresentam, com valores numéricos, como o erro varia à medida que o limiar SQI1 é adotado. Em ambos os casos, o termo NaN, na última linha referente ao desvio padrão, indica que apenas uma amostra permanecia ao se adotar o respectivo limiar. Observa-se também que o comportamento do aumento do erro para limiares muito altos está presente nas amostras do grupo 4. Tanto o erro quanto seu desvio padrão diminuem com o aumento do limiar. Isso sugere que a seletividade não é aleatória, mas sim que há uma maior concentração de amostras boas na região onde o SQI1 é elevado, um fato já evidenciado pela dispersão observada na Figura 4.5.

Até o momento, a análise sobre a redução do erro considerou todas as amostras de um determinado grupo ou de vários grupos. Como cada vídeo possui 244 amostras, isso implica que as amostras restantes após a aplicação do limiar podem pertencer tanto a vários vídeos quanto a apenas alguns. Essa situação levanta a hipótese de que um único vídeo com aferições de alta qualidade poderia ter um peso desproporcional na redução do erro médio,

Figura 4.9 – Variação do erro absoluto médio para todos os vídeos dos grupos 3, 4, 5 e 6 utilizando o SQI1 como limiar. O número em cada ponto indica a quantidade de amostras consideradas a partir do seu respectivo limiar.



Fonte: Autores

Tabela 4.9 – Erros absolutos médios e seus desvios padrão para diferentes limiares de SQI1 para os vídeos do grupo 3.

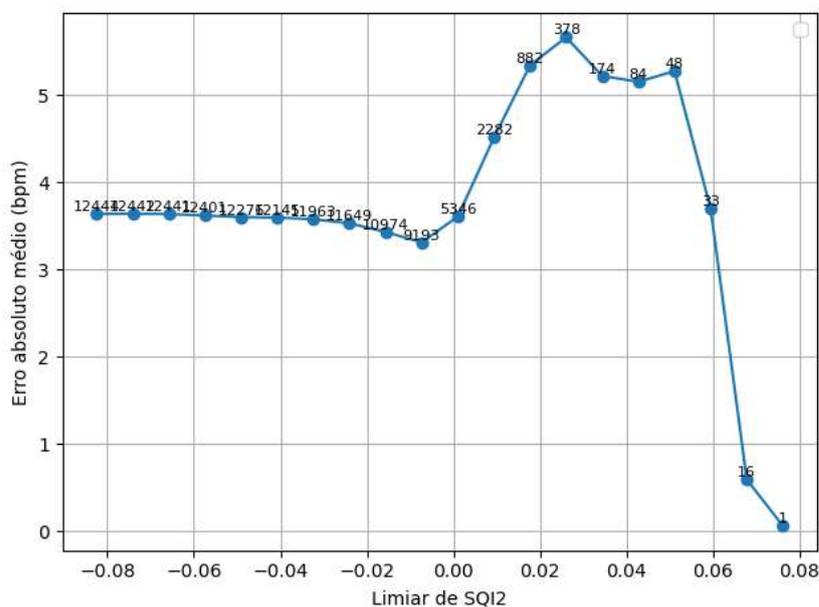
Limiar de SQI1	Erro absoluto BPM (bpm)	Desvio padrão (bpm)
0,1582	4,1187	7,9608
0,2262	3,7906	7,5703
0,2942	3,0983	6,5009
0,3623	2,1865	4,6966
0,4303	1,4737	3,3895
0,4983	0,7558	1,9161
0,5663	0,4424	0,7611
0,6343	0,3369	0,4917
0,7023	0,2221	0,1855
0,7703	0,0771	NaN

o que sugeriria uma baixa generalidade da metodologia empregada.

Para ilustrar, suponha que, entre os 51 vídeos analisados, todos apresentem tanto amostras boas, com altos valores de SQI1, quanto amostras ruins. Nesse cenário, cada vídeo individualmente possuiria uma grande variação na qualidade de suas amostras. Assim, qualquer vídeo poderia fornecer uma boa aferição ao aplicarmos o indicador de qualidade para selecionar as amostras mais promissoras.

Por outro lado, considere um caso alternativo em que 10 dos 51 vídeos possuam a maioria de suas amostras com alta qualidade, enquanto os outros 41 vídeos apresentem

Figura 4.10 – Variação do erro absoluto médio para todos os vídeos dos grupos 3, 4, 5 e 6 utilizando o SQI2 como limiar. O número em cada ponto indica a quantidade de amostras consideradas a partir do seu respectivo limiar.



Fonte: Autores

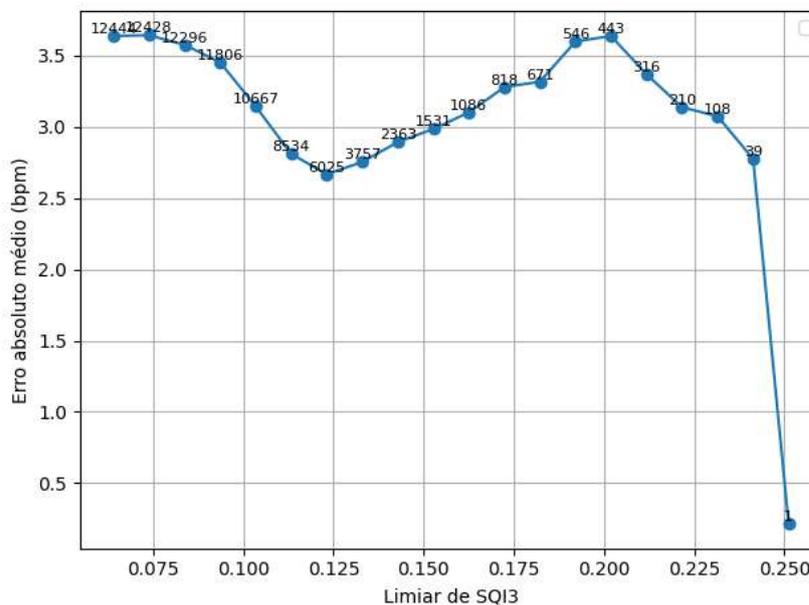
Tabela 4.10 – Erros absolutos médios e seus desvios padrão para diferentes limiares de SQI1 para os vídeos do grupo 4.

Limiar de SQI1	Erro absoluto BPM (bpm)	Desvio padrão (bpm)
0,2445	5,5230	10,5351
0,3098	4,7930	8,4550
0,3751	3,9971	6,8029
0,4404	3,0656	5,1886
0,5057	1,9569	3,5968
0,5710	1,2316	2,3001
0,6363	0,7777	0,9142
0,7016	0,5861	0,6071
0,7670	0,3376	0,2228
0,8323	0,7018	NaN

predominantemente amostras de qualidade mediana ou baixa. Nesse cenário, ao utilizarmos o indicador de qualidade para selecionar as melhores amostras, apenas aqueles 10 vídeos resultariam em aferições úteis. Os outros 41 vídeos, por sua vez, precisariam ser descartados, indicando uma baixa generalidade da metodologia empregada.

Felizmente, os gráficos de dispersão dos 51 vídeos mostram que todos possuem amostras de boa qualidade, possíveis de serem obtidas. O verdadeiro desafio, portanto, está em aprimorar o critério de seleção dessas amostras. Apesar de a grande maioria dos vídeos gerar bons resultados com a seleção pelo SQI1, alguns ainda apresentam amostras ruins

Figura 4.11 – Variação do erro absoluto médio para todos os vídeos dos grupos 3, 4, 5 e 6 utilizando o SQI3 como limiar. O número em cada ponto indica a quantidade de amostras consideradas a partir do seu respectivo limiar.



Fonte: Autores

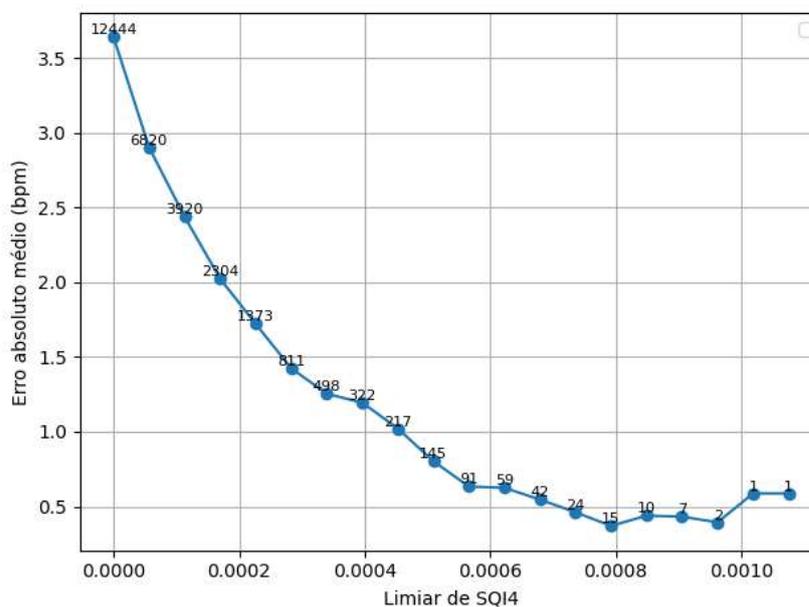
com altos valores no indicador de qualidade, sugerindo que há espaço para melhorar os resultados obtidos.

Uma forma de tornar a análise mais alinhada com o uso prático do dispositivo é refazer a análise da variação do erro médio, restringindo a análise a uma única amostra por vídeo. Essa amostra seria aquela com o maior valor de SQI1 em cada vídeo. Isso simularia o cenário em que o valor considerado como aferição do dispositivo corresponde à amostra com o melhor indicador de qualidade.

Adicionalmente, poderia ser aplicado um limiar para excluir vídeos em que todas as amostras apresentem baixos valores de SQI1, ou seja, desconsiderar aferições que, teoricamente, foram muito ruidosas. Essa abordagem reflete com mais fidelidade o comportamento esperado para o uso proposto do dispositivo.

A figura 4.13 mostra como o valor do erro médio varia ao adotar essa última metodologia. Nota-se que, mesmo considerando apenas uma amostra por vídeo, o erro médio permanece baixo. Quando nenhum limiar é aplicado, ou seja, a aferição do vídeo é definida pela amostra com o maior SQI1, independentemente do valor, o erro já é inferior a 1 bpm. À medida que o limiar aumenta, o erro médio diminui. Isso indica que os vídeos com amostras de menor SQI1 são também aqueles com erros superiores à média, e, ao serem considerados aferições inválidas, a precisão do sistema melhora. Essa tendência persiste, com oscilações locais, até um limiar de aproximadamente 0,82.

Figura 4.12 – Variação do erro absoluto médio para todos os vídeos dos grupos 3, 4, 5 e 6 utilizando o SQI4 como limiar. O número em cada ponto indica a quantidade de amostras consideradas a partir do seu respectivo limiar.



Fonte: Autores

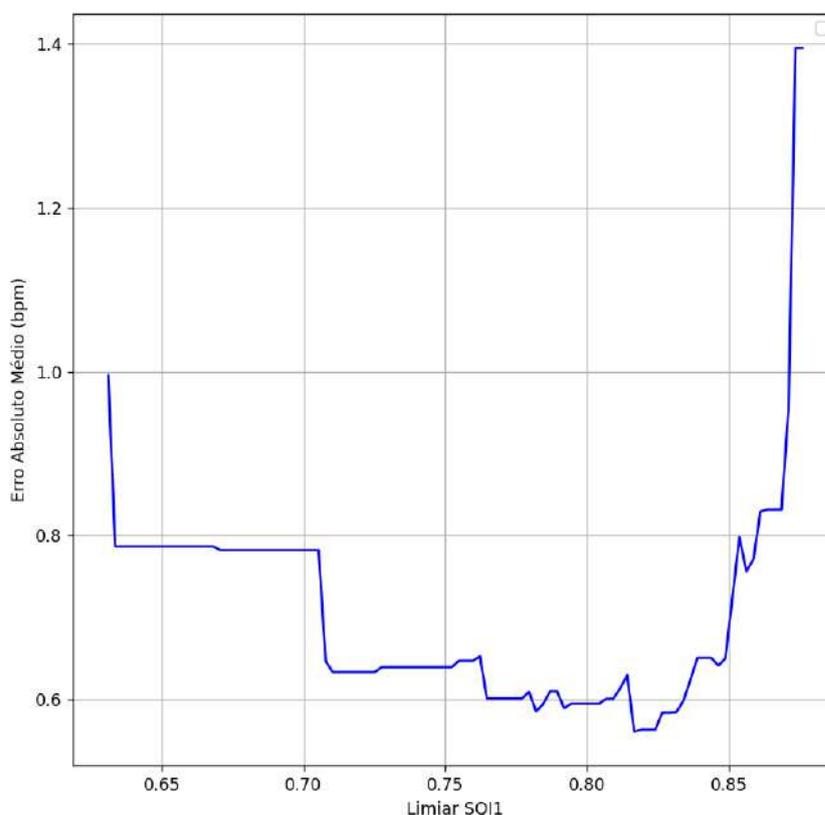
A partir desse ponto, muitos vídeos com bons resultados começam a ser invalidados pelo aumento do limiar, o que faz com que o erro médio volte a crescer. Essa elevação, que ao final atinge cerca de 1,4 bpm, evidencia que o critério de seleção baseado no SQI1 ainda não é perfeito. Embora funcione bem em uma análise inicial, ele ainda permite que algumas amostras imprecisas sejam consideradas válidas.

Os resultados dos experimentos sugerem que, além de focar no desenvolvimento de um método ou patch ideal, uma abordagem complementar e eficaz é a de saber identificar quando uma medição foi precisa ou não. Essa análise com base no SQI1 demonstrou ser uma estratégia promissora para melhorar a confiabilidade das aferições. Contudo, os resultados também apontam que há margem para aprimoramentos no critério de seleção, especialmente para reduzir ainda mais os casos em que amostras imprecisas são aceitas, sem tornar o critério de validade rigoroso o suficiente a ponto de tornar impraticável a obtenção de uma aferição válida.

4.4 Sincronia ECG-PPG

A sincronia entre a curva PPG, também conhecida como curva BVP, e a curva gerada pelo ECG foi utilizada como uma ferramenta fundamental para validar os testes realizados. O sinal PPG reflete as variações no volume de sangue nos tecidos periféricos, estando diretamente relacionado à atividade cardíaca capturada pelo ECG. Dessa forma, verificar

Figura 4.13 – Variação do erro médio da frequência cardíaca, sem considerar amostras repetidas para um mesmo vídeo, de acordo com o limiar SQI1.



Fonte: Autores

se as oscilações na curva PPG coincidem temporalmente com os batimentos cardíacos registrados no ECG é essencial para assegurar que o fenômeno capturado pela câmera está intrinsecamente associado ao ciclo cardíaco.

Essa validação é particularmente importante devido à susceptibilidade do sinal PPG a interferências externas. Oscilações na iluminação ambiente, ruídos de origem eletromagnética e ajustes automáticos da câmera podem introduzir artefatos no sinal, que, à primeira vista, podem ser confundidos com o ciclo cardíaco. No entanto, ao comparar a curva PPG com a referência confiável fornecida pelo ECG, é possível determinar se as oscilações observadas correspondem efetivamente às variações no volume sanguíneo associadas ao ciclo cardíaco ou se são decorrentes de interferências externas.

Outro aspecto crítico dessa análise é a identificação de atrasos ou distorções entre a curva PPG e o ECG. Esses atrasos são esperados, pois o sinal PPG depende da propagação da onda de pulso arterial até os tecidos periféricos.

O método de sincronização utilizado para essa análise foi um flash luminoso, empregado como ponto de referência para marcar o início da captura dos sinais. Embora essa técnica tenha sido escolhida pela sua simplicidade, observou-se que o sinal luminoso não se

comportou como um pulso instantâneo, mas apresentou uma transição lenta, dificultando a identificação precisa do momento de acionamento. Essa característica introduziu incertezas na determinação do atraso entre as curvas PPG e ECG, limitando a precisão da análise. Apesar dessa limitação, o objetivo primário do experimento era validar a sincronia entre os dois sinais, sendo a medição do atraso uma análise complementar. Como será discutido adiante, mesmo com métodos de sincronização mais confiáveis, desafios permanecem na medição precisa do atraso entre as curvas.

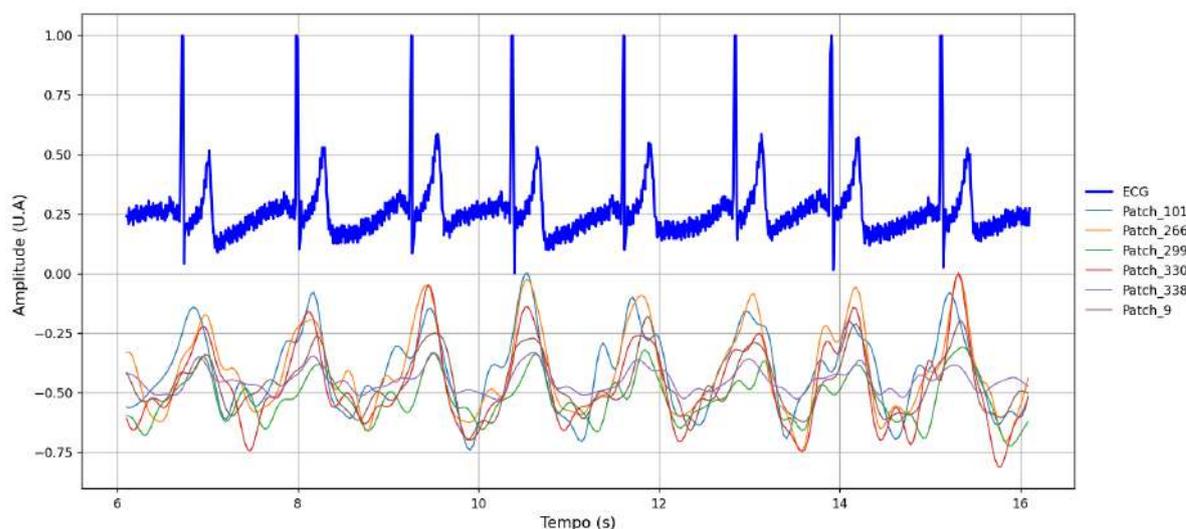
O atraso entre os sinais ECG e PPG não possui um valor fixo, pois é influenciado por uma série de fatores fisiológicos e ambientais. Um dos principais fatores é a rigidez arterial, conforme discutido na subseção 2.1.2. A rigidez arterial, associada a condições como hipertensão e envelhecimento vascular, afeta diretamente a propagação da onda de pulso pelo sistema arterial. Em indivíduos com maior rigidez arterial, a capacidade de distensão das artérias é reduzida, resultando em uma propagação mais rápida da onda de pulso e, conseqüentemente, em um atraso menor entre os sinais ECG e PPG. Esse fenômeno destaca o potencial do atraso como um marcador fisiológico para avaliação da saúde vascular.

A respiração é outro fator significativo. Durante o ciclo respiratório, alterações no volume torácico e na pressão intratorácica afetam tanto a pressão arterial quanto a velocidade de propagação da onda de pulso. Durante a inspiração, por exemplo, o aumento do retorno venoso e a redução da pressão intratorácica podem modificar o tempo necessário para a propagação da onda de pulso, introduzindo oscilações cíclicas no atraso entre os sinais ECG e PPG. Além disso, o estado emocional e fisiológico do indivíduo desempenha um papel crucial na dinâmica desse atraso. Emoções intensas, como ansiedade ou estresse, ativam o sistema nervoso simpático, resultando em alterações na frequência cardíaca e no tônus vascular. Essas mudanças modulam o tempo de trânsito da onda de pulso e podem causar variações significativas no atraso entre as curvas ECG e PPG. Essas alterações refletem a interação entre fatores autonômicos e emocionais com a dinâmica cardiovascular, destacando a complexidade dos mecanismos que governam o atraso entre esses sinais (Jobbágy; Csordás; Mersich, 2007).

A Figura 4.14 apresenta a sincronia entre múltiplos sinais de PPG obtidos a partir de diferentes patches e o sinal gerado por um ECG. Para facilitar a visualização, a amplitude foi expressa em unidades arbitrárias. Observa-se que os sinais dos patches tendem a se concentrar em uma região próxima, mas não estão completamente sincronizados. Além disso, há variações nas distâncias relativas entre os picos ao longo do tempo. Essa discrepância é esperada, considerando a dinâmica do fluxo sanguíneo no corpo humano. Ainda que os picos dos sinais não coincidam perfeitamente, como evidenciado na figura, espera-se que a diferença seja mínima. Estudos prévios indicam que a diferença entre os picos do ECG e do PPG encontra-se tipicamente na ordem de milissegundos (Unursaikhan *et al.*, 2021), um nível de precisão elevado que excede o alcance da metodologia empregada neste estudo. Notam-se também sinais com ruídos, que introduzem deformações quando comparados à curva PPG

ideal, aferida diretamente em contato com a pele. Apesar das limitações, o experimento obteve sucesso ao demonstrar que as oscilações dos sinais dos patches acompanham o sinal do ECG, embora possam apresentar defasagens.

Figura 4.14 – Comparação da sincronia entre a curva ECG e as curvas PPG obtidas por diferentes patches.

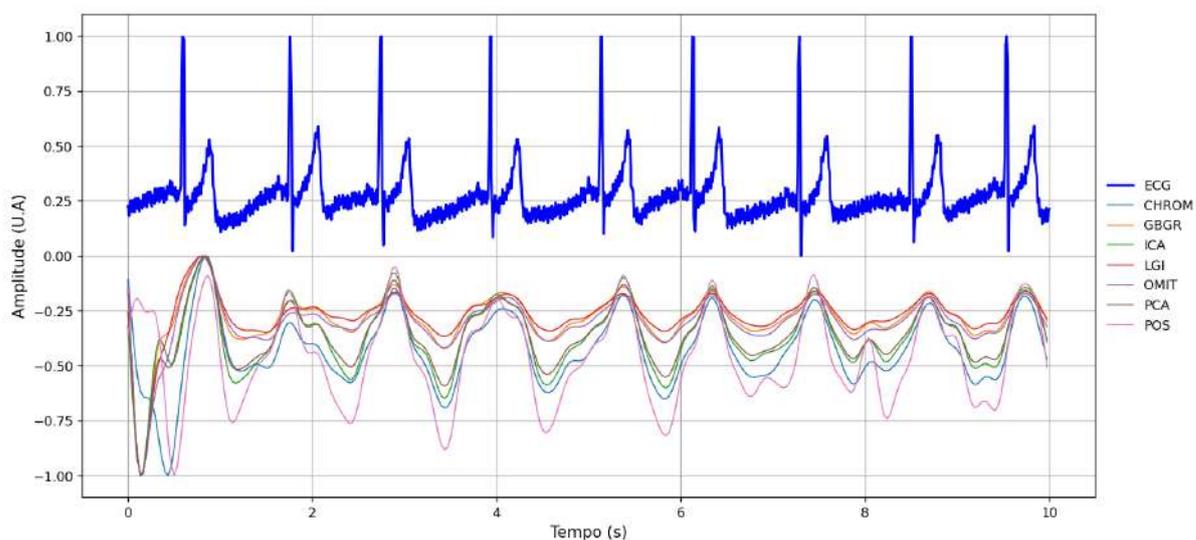


Fonte: Autores

A Figura 4.15 apresenta uma análise semelhante à da Figura 4.14, mas com a variação de métodos de obtenção dos sinais, mantendo-se um único patch fixo. Percebe-se que, neste caso, as curvas apresentam maior conformidade em comparação ao cenário anterior, indicando que o formato do sinal PPG varia pouco em função do método escolhido, dado um patch específico. As principais divergências entre as curvas, observadas no início do gráfico, são atribuídas à influência do sinal luminoso usado para a sincronização. Cada método processa esse ruído de forma distinta, resultando em discrepâncias iniciais nas curvas. Entretanto, essas inconsistências são atenuadas ao longo do tempo, reafirmando a robustez dos métodos avaliados para obter sinais confiáveis.

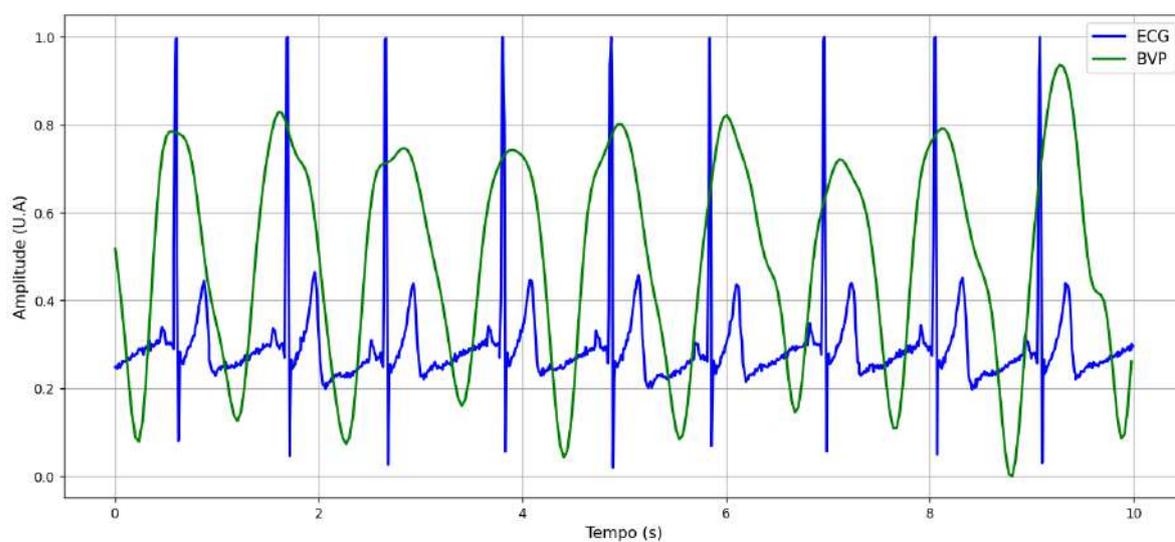
Um aspecto destacado nas figuras anteriores e mais evidente na Figura 4.16 é a variação temporal da distância relativa entre os picos das curvas ECG e PPG. Ao expandir a amplitude temporal da análise, identifica-se que essas variações se assemelham a oscilações cíclicas, sugerindo que a distância entre os picos não é fixa, mas flutuante. Esse comportamento não é exclusivo deste experimento e já foi documentado na literatura (Unursaikhan *et al.*, 2021), reforçando a hipótese de que flutuações cíclicas refletem características dinâmicas do sistema cardiovascular humano, possivelmente associadas à respiração.

Figura 4.15 – Comparação da sincronia entre a curva ECG e as curvas PPG obtidas por diferentes métodos utilizando o mesmo patch.



Fonte: Autores

Figura 4.16 – Sobreposição das curvas ECG e PPG para análise detalhada da sincronia. A curva PPG foi obtida utilizando o patch 10 e o método GREEN.



Fonte: Autores

5 Conclusão

5.1 Ilação do trabalho

Os objetivos deste trabalho incluíram o desenvolvimento de um sistema não invasivo para a medição das frequências cardíaca e respiratória utilizando a técnica de rPPG. O foco principal foi direcionado à aplicabilidade prática do sistema, especialmente na avaliação de motoristas, mas também em ambientes clínicos ou outras situações que exijam o monitoramento preciso e não invasivo dessas frequências.

Assim, com base nos resultados no capítulo 4, é possível concluir que o sistema desenvolvido demonstrou avanços significativos em termos de precisão e robustez. Foi observado que determinadas regiões faciais, como a testa e bochechas, são mais adequadas para a captura do sinal rPPG, além da região de melhor precisão variar conforme o indivíduo. O que deixa claro a importância de uma escolha criteriosa dos patches na configuração do sistema.

Ao considerar a escolha do melhor método e da região facial para cada participante, foi possível alcançar uma precisão extremamente alta nas estimativas de frequência cardíaca. Para o participante 1, obteve-se um erro absoluto de apenas 0,016 BPM, utilizando o método CHROM aplicado ao patch de número 280, localizado na região da bochecha direita. Já para o participante 2, o erro absoluto foi ainda menor, de 0,001 BPM, alcançado com o método GREEN aplicado ao patch de número 4, situado na região do nariz.

No caso da frequência respiratória, o menor erro absoluto registrado foi de 0,191 iRPM para o participante 1, utilizando o método CHROM aplicado ao patch de número 10, localizado na região da testa. Para o participante 2, o menor erro absoluto foi de 0,451 iRPM, alcançado com o método GRGB, aplicado ao patch de número 101, situado na região da bochecha direita. Esses resultados reforçam a importância de uma seleção criteriosa dos patches faciais para maximizar a precisão das estimativas.

Esse achado destaca como diferentes regiões faciais possuem características específicas que podem influenciar a qualidade do sinal captado, dependendo da métrica a ser medida. Assim, a combinação entre método e localização do patch desempenha um papel fundamental no desempenho do sistema, evidenciando a necessidade de estratégias adaptativas para diferentes indivíduos e condições de aplicação.

Com isso em mente, foram implementados quatro tipos de indicadores de qualidade de sinal (SQI) para orientar a seleção das melhores regiões faciais. Essa abordagem proposta tem como objetivo prever, de forma antecipada, quais amostras possuem maior probabilidade de gerar resultados precisos. A partir das regiões selecionadas com base nesses indicadores,

a frequência cardíaca é estimada, resultando em um aumento significativo na precisão geral do dispositivo.

O uso de SQIs para análise da frequência cardíaca mostrou-se uma alternativa mais eficaz em comparação à seleção de regiões faciais e de métodos PPG. Entre os índices avaliados, o SQI1 apresentou os melhores resultados, demonstrando-se aplicável para esse propósito. Por outro lado, embora o SQI4 seja capaz de identificar amostras de boa qualidade, ele também descarta muitas amostras viáveis, o que o torna impraticável em situações de campo, já que o operador precisaria realizar centenas de testes para obter um resultado válido. Os demais SQIs, por sua vez, não apresentaram resultados expressivos em relação à capacidade de selecionar medições com baixo nível de ruído e alta precisão.

A frequência respiratória, no entanto, não pôde ser associada diretamente à abordagem baseada nos SQIs, uma vez que a relação entre esses indicadores e a precisão das estimativas não apresentou dados suficientemente claros para uma análise robusta de sua eficácia. Esse resultado pode ser atribuído ao erro propagativo associado ao dispositivo desenvolvido para a aferição da frequência respiratória real, conforme discutido anteriormente.

Esse erro propagativo compromete a confiabilidade das medições de referência, dificultando a avaliação precisa da correlação entre os SQIs e a qualidade das estimativas da frequência respiratória. Assim, torna-se evidente a necessidade de aprimorar tanto o dispositivo de referência quanto os métodos de análise para validar o uso de indicadores de qualidade de sinal nesse contexto de forma mais consistente.

Observou-se também que a precisão na estimativa das frequências cardíaca e respiratória, considerando todos os patches faciais, apresentou um erro absoluto de 2,81 BPM para a frequência cardíaca e 3,02 iRPM para a frequência respiratória no caso dos participantes 1 e 2, respectivamente. Esses resultados indicam que, embora ambas as frequências sejam derivadas do mesmo sinal rPPG, a componente DC, responsável pela estimativa da frequência respiratória, não exerce uma influência significativa na qualidade da componente AC, utilizada para a estimativa da frequência cardíaca.

Além dos resultados apresentados, foi observado que o participante 3, que possui pele escura, apresentou o pior desempenho em termos de precisão das estimativas. Esse resultado destaca uma limitação importante, destacada anteriormente, que reforça que os algoritmos de fotopletiografia remota tendem a apresentar maior imprecisão em indivíduos de pele escura.

Em relação à sincronização entre o sinal rPPG e o ECG, embora a técnica escolhida tenha introduzido uma limitação significativa ao gerar certa incerteza, o objetivo primário de validar a sincronia entre os dois sinais foi alcançado. Contudo, a realização de uma análise complementar para medir precisamente o atraso entre os sinais não foi viável.

A partir dos sinais de cada patch, observou-se a tendência a se concentrar em um local próximo, mas não estão completamente sincronizados. Isso ocorre por conta da dinâmica

do fluxo sanguíneo no corpo humano, que foi discutida em seções anteriores. E ainda com deformações geradas por ruídos, foi possível demonstrar que as oscilações dos sinais dos patches acompanham o sinal do ECG.

Além dos patches, também foi avaliada a sincronização com os sinais gerados pelos métodos, mantendo-se um patch único. Neste caso, observou-se que as curvas apresentaram uma maior conformidade em comparação ao cenário anterior, assim indicando que o formato do sinal PPG varia pouco em função do método escolhido.

Uma divergência nas curvas dos métodos foi detectada no início dos gráficos, sendo atribuída à influência do sinal luminoso utilizado para a sincronização. Esse sinal luminoso, ao ser incorporado ao processo de coleta, gerou um ruído que foi processado de maneira diferente por cada método. No entanto, essas inconsistências foram atenuadas ao longo do tempo, o que reafirma a robustez dos métodos avaliados e sua capacidade de lidar com perturbações iniciais sem comprometer a precisão da estimativa a longo prazo.

Além disso, foi observada uma variação temporal na distância relativa entre os picos do sinal ECG e o sinal PPG. Essa variação, quando analisada em detalhes, revelou um padrão de oscilações cíclicas, sugerindo que a distância entre os picos não é fixa, mas sim flutuante. Esse comportamento reforça a hipótese de que as flutuações cíclicas refletem características dinâmicas do sistema cardiovascular humano.

5.2 Perspectivas futuras

A evolução do projeto aponta para uma série de melhorias estratégicas no hardware e software, necessárias para superar as limitações observadas e explorar plenamente o potencial do dispositivo desenvolvido. As etapas futuras visam não apenas corrigir as deficiências identificadas, mas também ampliar a aplicabilidade e a robustez do sistema. No âmbito do hardware, os refinamentos pretendem garantir maior autonomia operacional, precisão na coleta de dados e flexibilidade de uso, enquanto no software, o foco estará na eficiência computacional, na exploração de novos algoritmos e na implementação de funcionalidades avançadas. Essa integração de melhorias permitirá ao dispositivo atender a cenários mais complexos e desafiadores, consolidando-o como uma ferramenta versátil e eficiente para pesquisa e aplicações práticas.

5.2.1 Hardware

O desenvolvimento do dispositivo apresentou avanços significativos, mas também revelou pontos que necessitam de refinamento para aprimorar tanto sua eficiência quanto sua usabilidade em etapas futuras. Um dos principais desafios encontrados foi relacionado à autonomia operacional. A falha na bateria do protótipo, que inicialmente permitia o funcionamento independente, comprometeu sua praticidade. Assim, uma das prioridades

no refinamento do hardware será reestabelecer a funcionalidade da bateria, garantindo uma fonte de energia confiável que permita maior flexibilidade em ambientes de teste sem depender de conexões externas.

Outro aspecto relevante refere-se às fontes luminosas utilizadas nos experimentos. Os melhores resultados foram obtidos quando essas fontes estavam posicionadas próximas ao rosto dos participantes, sugerindo que a intensidade e o ângulo da iluminação desempenham um papel crucial na qualidade dos sinais captados. Uma solução futura seria integrar essas fontes luminosas diretamente ao protótipo, garantindo que a iluminação necessária seja sempre adequada e reduzindo a dependência de configurações externas. Essa abordagem não apenas melhorará a consistência dos resultados, mas também tornará o dispositivo mais compacto e funcional.

Adicionalmente, foram observadas dificuldades na regulação de inclinação e altura do dispositivo durante os testes. Essas limitações impactaram negativamente a agilidade e a precisão na configuração inicial. Para superar esses desafios, planeja-se uma reestruturação da carcaça do dispositivo. O novo design deverá permitir ajustes mais rápidos e precisos, aumentando a eficiência operacional e promovendo uma melhor experiência tanto para os usuários quanto para os pesquisadores responsáveis pela calibração.

Além disso, devido às dificuldades enfrentadas durante a análise dos resultados relacionados à frequência respiratória, especialmente pelo impacto do erro propagativo gerado pelo dispositivo desenvolvido, ficou evidente a necessidade de melhorias. Esse erro comprometeu a precisão das estimativas, destacando a importância de se investir em um dispositivo dedicado exclusivamente à detecção da frequência respiratória ou, alternativamente, no aprimoramento do dispositivo atual.

No que diz respeito à capacidade computacional, a utilização da Raspberry Pi como unidade de processamento demonstrou ser um gargalo em algumas tarefas mais complexas. Embora tenha sido uma solução prática para o estágio atual do projeto, seu desempenho limitado ressalta a necessidade de considerar alternativas mais robustas. Um passo futuro importante seria a substituição da Raspberry Pi por um dispositivo com maior capacidade de processamento. Essa atualização possibilitará a execução mais eficiente de algoritmos avançados e a análise em tempo real de grandes volumes de dados, potencializando o desempenho geral do sistema.

Por fim, uma melhoria significativa na operabilidade do dispositivo pode ser alcançada com a incorporação de câmeras que operem fora do espectro RGB, como câmeras infravermelhas. Essas câmeras operam melhor em ambientes escuros. Tal adição proporcionaria maior versatilidade ao protótipo, permitindo que ele funcione de forma eficiente em uma gama mais ampla de ambientes e condições, ampliando assim seu potencial de aplicação.

Em resumo, o refinamento do hardware envolve uma série de melhorias estruturais e

funcionais que visam superar as limitações atuais e preparar o dispositivo para etapas futuras de pesquisa e aplicação prática. Esses ajustes, alinhados com as necessidades identificadas nos testes, garantirão maior confiabilidade, precisão e facilidade de uso, tornando o dispositivo uma ferramenta ainda mais robusta e eficaz.

5.2.2 Software

Durante a etapa inicial deste projeto, grande parte do esforço foi direcionada ao desenvolvimento de um dispositivo de teste funcional, deixando claro que a ampla gama de testes possíveis ainda não foi plenamente explorada. A interface gráfica desenvolvida permitiu a configuração de múltiplos parâmetros, resultando em combinações possíveis na ordem de milhões. Esse cenário destaca a complexidade inerente ao sistema e a necessidade de desenvolver metodologias de teste específicas. Somente com essas metodologias será possível analisar e compreender todas as possíveis interferências que possam afetar o desempenho do dispositivo, garantindo um entendimento mais profundo de suas capacidades e limitações.

Neste estágio, a linguagem de programação Python foi escolhida como a base para o desenvolvimento do software. A escolha foi motivada por sua alta versatilidade e facilidade de uso, que se mostraram fundamentais em um projeto caracterizado por mudanças frequentes no rumo e pela necessidade de integrar diversos dispositivos de hardware. A capacidade do Python de lidar com rápidas iterações e a ampla disponibilidade de bibliotecas facilitou a implementação de protótipos e a realização de testes preliminares.

Entretanto, à medida que o projeto evolui para um estágio mais maduro e os objetivos se tornam mais concretos, considera-se que a migração para a linguagem C seja uma etapa natural. O C oferece maior eficiência e controle, permitindo um melhor aproveitamento dos recursos do hardware. Essa transição possibilitará a execução de tarefas com maior desempenho e permitirá o desenvolvimento de um software otimizado, adequado às demandas crescentes do dispositivo.

Com a perspectiva de introduzir um hardware mais avançado, abre-se também a possibilidade de implementar métodos mais modernos de análise de sinais PPG que exigem maior poder computacional, o que se tornará viável com a atualização do hardware. Além disso, a nova infraestrutura permitirá a exibição em tempo real do sinal captado, algo que não foi possível na configuração atual. Essa funcionalidade trará vantagens significativas, tanto para fins de monitoramento quanto para a validação imediata do funcionamento do dispositivo durante os testes.

Em síntese, a evolução do software será pautada por três pilares principais: a migração para uma linguagem mais eficiente, a exploração de metodologias de teste abrangentes e a integração de recursos avançados proporcionados pelo novo hardware. Essas melhorias garantirão que o software acompanhe o crescimento do projeto, tornando-o mais robusto, eficiente e alinhado às necessidades práticas e científicas futuras.

Referências

- AIRES, M. D. M. **Fisiologia**. 5. ed. Rio de Janeiro: Guanabara Koogan, 2018. ISBN 978-85-277-3401-1. Citado nas pp. 30 e 31.
- ALNAEB, M.; ALOBAID, N.; SEIFALIAN, A.; MIKHAILIDIS, D.; HAMILTON, G. Optical techniques in the assessment of peripheral arterial disease. **Current vascular pharmacology**, v. 5, p. 53–9, 02 2007. Citado nas pp. 24, 32 e 42.
- ASTHANA, A.; ZAFEIRIOU, S.; CHENG, S.; PANTIC, M. Incremental face alignment in the wild. *In: 2014 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2014. p. 1859–1866. Citado na p. 46.
- BAL, U. Non-contact estimation of heart rate and oxygen saturation using ambient light. **Biomedical Optics Express**, v. 6, p. 86–97, 12 2014. Citado na p. 29.
- BALAKRISHNAN, G.; DURAND, F.; GUTTAG, J. Detecting pulse from head motions in video. *In: 2013 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2013. p. 3430–3437. Citado na p. 45.
- BALARAMAN, K.; CLARET, S. P. A. Recent innovations and improvements in remote heart rate and heart disease measuring methods using rgb camera. *In: 2023 International Conference on Circuit Power and Computing Technologies (ICCPCT)*. [S.l.: s.n.], 2023. p. 1690–1696. Citado nas pp. 30, 40 e 57.
- BARANOSKI, G. V.; CHEN, T. F.; KIMMEL, B. W.; MIRANDA, E.; YIM, D. On the noninvasive optical monitoring and differentiation of methemoglobinemia and sulfhemoglobinemia. **Journal of Biomedical Optics**, Society of Photo-Optical Instrumentation Engineers, v. 17, n. 9, p. 097005–097005, 2012. Citado na p. 39.
- BASTOS, F. I. P. M.; VASCONCELLOS, M. T. L. d.; BONI, R. B. D.; REIS, N. B. d.; COUTINHO, C. F. d. S. *et al.* **III Levantamento Nacional sobre o uso de drogas pela população brasileira**. [S.l.], 2017. Citado na p. 18.
- BOCCIGNONE, G.; CONTE, D.; CUCULO, V.; D'AMELIO, A.; GROSSI, G.; LANZAROTTI, R.; MORTARA, E. pyvhr: a python framework for remote photoplethysmography. **PeerJ Computer Science**, PeerJ Inc., v. 8, p. e929, 2022. Citado nas pp. 52 e 53.
- BOUSEFSAF, F.; MAAOUI, C.; PRUSKI, A. Continuous wavelet filtering on webcam photoplethysmographic signals to remotely assess the instantaneous heart rate. **Biomedical Signal Processing and Control**, v. 8, n. 6, p. 568–574, 2013. ISSN 1746-8094. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1746809413000840>. Citado nas pp. 51 e 56.
- BRASIL, R. F. do. **Código de Trânsito Brasileiro**. Presidência da República, Casa Civil, Subchefia para Assuntos Jurídicos, 1997. http://www.planalto.gov.br/ccivil_03/leis/19503.

- htm. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/19503.htm. Citado na p. 19.
- BUDDY, T. Field sobriety test: Dui tests to assess drunk driving. **Verywell Mind**, agosto 11 2023. Disponível em: <https://www.verywellmind.com/field-sobriety-test-67159>. Citado na p. 20.
- BUDIDHA, K. In vivo investigation of ear canal pulse oximetry during hypothermia. **Journal of Clinical Monitoring and Computing**, v. 32, 02 2018. Citado nas pp. 34 e 42.
- CAROPPO, A.; MANNI, A.; RESCIO, G.; SICILIANO, P.; LEONE, A. Vital signs estimation in elderly using camera-based photoplethysmography. **Multimed. Tools Appl.**, Springer Science and Business Media LLC, jan. 2024. Citado na p. 51.
- CASADO, C. Álvarez; LÓPEZ, M. B. **Face2PPG: An unsupervised pipeline for blood volume pulse extraction from faces**. 2023. Disponível em: <https://arxiv.org/abs/2202.04101>. Citado nas pp. 65 e 76.
- CEZARE, M. F. C. C.; TÁRSIS de. A influência da inteligência artificial nos direitos humanos e nos processos jurídicos. **Prospectus (ISSN: 2674-8576)**, v. 2, n. 1, 2020. Citado na p. 21.
- CHAN, E.; CHAN, M.; CHAN, M. Pulse oximetry: Understanding its basic principles facilitates appreciation of its limitations. **Respiratory medicine**, v. 107, 03 2013. Citado na p. 29.
- CHEE, K.; NILSON, D.; PARTRIDGE, R.; HUGHES, A.; SUNER, S.; SUCOV, A.; JAY, G. Finding needles in a haystack: A case series of carbon monoxide poisoning detected using new technology in the emergency department. **Clinical toxicology (Philadelphia, Pa.)**, v. 46, p. 461–9, 07 2008. Citado na p. 39.
- CHEN, X.; CHENG, J.; SONG, R.; LIU, Y.; WARD, R.; WANG, Z. J. Video-based heart rate measurement: Recent advances and future prospects. **IEEE Transactions on Instrumentation and Measurement**, v. 68, n. 10, p. 3600–3615, 2019. Citado nas pp. 25, 30, 32, 40, 41, 43, 44, 45, 46, 56 e 57.
- CHENG, J.; CHEN, X.; XU, L.; WANG, Z. J. Illumination variation-resistant video-based heart rate measurement using joint blind source separation and ensemble empirical mode decomposition. **IEEE Journal of Biomedical and Health Informatics**, v. 21, n. 5, p. 1422–1433, 2017. Citado nas pp. 44, 46 e 57.
- COMMONS, W. **File:Diagram of the human heart (cropped) pt.svg — Wikimedia Commons, the free media repository**. 2023. [Online; accessed 4-julho-2024]. Disponível em: [https://commons.wikimedia.org/w/index.php?title=File:Diagram_of_the_human_heart_\(cropped\)_pt.svg&oldid=830012806](https://commons.wikimedia.org/w/index.php?title=File:Diagram_of_the_human_heart_(cropped)_pt.svg&oldid=830012806). Citado na p. 31.
- CONCI, A.; AZEVEDO, E.; LETA, F. **Computação Gráfica - Teoria e Prática**. [S.l.]: Alta Books, 2022. 352 p. ISBN 978-65-5520-816-0. Citado na p. 47.

- CONSYSTEMS e. **MIPI camera vs USB camera – a detailed comparison**. 2023. Accessed: 2024-08-19. Disponível em: https://www.e-consystems.com/blog/camera/technology/mipi-camera-vs-usb-camera-a-detailed-comparison/?srsltid=AfmBOop-Fz9IyKHcr4qRNQe06a5jpEgfB4PYTd6A7Ddct2osVG_zHUrK. Citado na p. 59.
- CONTRAN, C. N. de T. **Resolução Nº 432, de 23 de janeiro de 2013**. 2013. <https://www.gov.br/prf/pt-br/concurso-2021/resolucoes/R432-13>. Citado na p. 20.
- COULANGE, M.; BARTHELEMY, A.; HUG, F.; THIERRY, A.; HARO, L. de. Reliability of new pulse co-oximeter in victims of carbon monoxide poisoning. **Undersea & hyperbaric medicine : journal of the Undersea and Hyperbaric Medical Society, Inc**, v. 35, p. 107–11, 03 2008. Citado na p. 39.
- DEHKORDI, P.; GARDE, A.; MOLAVI, B.; ANSERMINO, J. M.; DUMONT, G. A. Extracting instantaneous respiratory rate from multiple photoplethysmogram respiratory-induced variations. **Frontiers in Physiology**, v. 9, 2018. ISSN 1664-042X. Disponível em: <https://www.frontiersin.org/journals/physiology/articles/10.3389/fphys.2018.00948>. Citado na p. 37.
- DHANANJAY1710. **pyVHR API Deployment**. 2024. Accessed: 2024-08-28. Disponível em: <https://github.com/dhananjay1710/pyVHR>. Citado na p. 57.
- DORLAS, J. C.; NIJBOER, J. A. Photo-electric plethysmography as a monitoring device in anaesthesia. application and interpretation. **British journal of anaesthesia**, v. 57 5, p. 524–30, 1985. Disponível em: <https://api.semanticscholar.org/CorpusID:13812562>. Citado na p. 38.
- ELGENDI, M.; MARTINELLI, I.; MENON, C. Optimal signal quality index for remote photoplethysmogram sensing. **npj Biosensing**, v. 1, n. 1, p. 5, jun. 2024. ISSN 3004-8656. Disponível em: <https://doi.org/10.1038/s44328-024-00002-1>. Citado na p. 114.
- ELIAKIM, M.; SAPOZNIKOV, D.; WEINMAN, J. Pulse wave velocity in healthy subjects and in patients with various disease states. **American Heart Journal**, v. 82, n. 4, p. 448–457, 1971. ISSN 0002-8703. Disponível em: <https://www.sciencedirect.com/science/article/pii/0002870371902298>. Citado na p. 34.
- ELLIOTT, M. Why is respiratory rate the neglected vital sign? a narrative review. **International Archives of Nursing and Health Care**, ClinMed International Library, v. 2, n. 3, 2016. Citado na p. 22.
- FAHIM, M. H. Three classification models for masked faces. **International Journal of Intelligent Systems and Applications in Engineering**, v. 12, n. 21s, p. 4642–, Mar. 2024. Disponível em: <https://ijisae.org/index.php/IJISAE/article/view/6356>. Citado na p. 50.

- FENG, L.; PO, L.-M.; XU, X.; LI, Y.; MA, R. Motion-resistant remote imaging photoplethysmography based on the optical properties of skin. **IEEE Transactions on Circuits and Systems for Video Technology**, v. 25, n. 5, p. 879–891, 2015. Citado na p. 46.
- FIKRIASTUTI, N.; MUHAIMIN, H. Respiratory rate estimations using three respiratory-induced variations on photoplethysmogram. *In: 2021 International Conference on Electrical Engineering and Informatics (ICEEI)*. [S.l.: s.n.], 2021. p. 1–6. Citado na p. 38.
- FILHO, A. de M.; SCHREIBER, G.; SIEG, J.; MUCH, M.; BARTOSKI, V.; MARCON, C. A. M. Methods to estimate respiratory rate using the photoplethysmography signal. **(HEALTHINF), Brasil**, 2023. Citado nas pp. 38 e 68.
- FINE, J.; BRANAN, K.; RODRIGUEZ, A.; BOONYA-ANANTA, T.; AJMAL; RAMELLA-ROMAN, J.; MCSHANE, M.; COTé, G. Sources of inaccuracy in photoplethysmography for continuous cardiovascular monitoring. **Biosensors**, v. 11, p. 126, 04 2021. Citado na p. 42.
- FOUNDATION, R. P. **Raspberry Pi 4 Model B Specifications**. 2019. Accessed: 2024-08-19. Disponível em: <https://www.raspberrypi.org/documentation/hardware/raspberrypi/bcm2711/README.md>. Citado na p. 58.
- FOUNDATION, R. P. **Picamera2 Documentation**. 2024. Accessed: 2024-08-19. Disponível em: <https://datasheets.raspberrypi.com/camera/picamera2-manual.pdf>. Citado na p. 60.
- GASTEL, M. van; STUIJK, S.; HAAN, G. de. Motion robust remote-ppg in infrared. **IEEE Transactions on Biomedical Engineering**, v. 62, n. 5, p. 1425–1433, 2015. Citado nas pp. 25, 43, 44 e 57.
- GATTO, R. G. **Estimation of instantaneous heart rate using video infrared thermography and ARMA models**. [S.l.]: University of Illinois at Chicago, 2009. Citado na p. 43.
- GHAMARI, M.; NAZERAN, H.; SOLTANPUR, C. A review on wearable photoplethysmography sensors and their potential future applications in health care. **International Journal of Biosensors & Bioelectronics**, v. 4, p. 195–202, 08 2018. Citado nas pp. 25, 34 e 40.
- GHIL, M.; ALLEN, M. R.; DETTINGER, M. D.; IDE, K.; KONDRASHOV, D.; MANN, M. E.; ROBERTSON, A. W.; SAUNDERS, A.; TIAN, Y.; VARADI, F. *et al.* Advanced spectral methods for climatic time series. **Reviews of geophysics**, Wiley Online Library, v. 40, n. 1, p. 3–1, 2002. Citado na p. 51.
- GILLINOV, S.; ETIWY, M.; WANG, R.; BLACKBURN, G.; PHELAN, D.; GILLINOV, A.; HOUGHTALING, P.; JAVADIKASGARI, H.; DESAI, M. Variable accuracy of wearable heart rate monitors during aerobic exercise. **Medicine & Science in Sports & Exercise**, v. 49, p. 1, 03 2017. Citado na p. 42.

- Google AI. **Mediapipe Face Landmarker - Google AI Edge**. 2024. Disponível em: https://ai.google.dev/edge/mediapipe/solutions/vision/face_landmarker?hl=pt-br. Citado nas pp. 63 e 64.
- GOVINDASWAMI, B.; JEGATHEESAN, P.; SONG, D. Oxygen saturation screening for critical congenital heart disease. **Neoreviews**, American Academy of Pediatrics, v. 13, n. 12, p. e724–e731, 2012. Citado na p. 30.
- GULER, S.; OZTURK, O.; GOLPARVAR, A.; DOGAN, H.; YAPICI, M. Effects of illuminance intensity on the green channel of remote photoplethysmography (rppg) signals. **Physical and Engineering Sciences in Medicine**, v. 45, 08 2022. Citado nas pp. 32 e 44.
- HAAN de G. G.; LEEST van A. A. Improved motion robustness of remote-ppg by using the blood volume pulse signature. **Physiological Measurement**, v. 35, p. 1913 – 1926, 2014. Disponível em: <https://api.semanticscholar.org/CorpusID:4524951>. Citado nas pp. 56, 65 e 76.
- HAAN, G. de; JEANNE, V. Robust pulse rate from chrominance-based rppg. **IEEE Transactions on Biomedical Engineering**, v. 60, n. 10, p. 2878–2886, 2013. Citado nas pp. 44, 47, 55, 57 e 76.
- HAMMER, A.; SCHERPF, M.; SCHMIDT, M.; ERNST, H.; MALBERG, H.; MATSCHKE, K.; DRAGU, A.; MARTIN, J.; BOTA, O. Camera-based assessment of cutaneous perfusion strength in a clinical setting. **Physiological Measurement**, IOP Publishing, v. 43, n. 2, p. 025007, mar 2022. Disponível em: <https://dx.doi.org/10.1088/1361-6579/ac557d>. Citado nas pp. 32 e 44.
- HARTLEY, J. Respiratory rate 2: anatomy and physiology of breathing. **Nursing Times [online]**, v. 114, n. 6, p. 43–44, 2018. Citado na p. 22.
- HASSAN, M. A.; MALIK, A.; SAAD, M. N. M.; FOFI, D.; MERIAUDEAU, F. Effect of motion artifact on digital camera based heart rate measurement. *In: Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.: s.n.], 2017. v. 2017. Citado nas pp. 25, 26, 45 e 46.
- HAUGG, F.; ELGENDI, M.; MENON, C. Grgb rppg: An efficient low-complexity remote photoplethysmography-based algorithm for heart rate estimation. **Bioengineering**, v. 10, n. 2, 2023. ISSN 2306-5354. Disponível em: <https://www.mdpi.com/2306-5354/10/2/243>. Citado nas pp. 51, 66, 67, 76 e 81.
- HE, K.; GKIOXARI, G.; DOLLÁR, P.; GIRSHICK, R. Mask r-cnn. *In: Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2017. p. 2961–2969. Citado na p. 49.
- HERTZMAN, A. B. Observations on the finger volume pulse recorded photoelectrically. **Am. J. Physiol.**, v. 119, p. 334–335, 1937. Citado na p. 32.

- IQBAL, T.; ELAHI, A.; GANLY, S.; WIJNS, W.; SHAHZAD, A. Photoplethysmography-based respiratory rate estimation algorithm for health monitoring applications. **Journal of Medical and Biological Engineering**, v. 46, n. 2, p. 100–110, 2022. Citado na p. 36.
- JAYASINGHE, J.; KATSIGIANNIS, S.; MALASINGHE, L. Comparative study of face tracking algorithms for remote photoplethysmography. *In: 2023 International Conference on Electrical, Computer and Energy Technologies (ICECET)*. [S.l.: s.n.], 2023. p. 1–7. Citado nas pp. 50 e 62.
- JEANNE, V.; ASSELMAN, M.; BRINKER, B. den; BULUT, M. Camera-based heart rate monitoring in highly dynamic light conditions. *In: 2013 International Conference on Connected Vehicles and Expo (ICCVE)*. [S.l.: s.n.], 2013. p. 798–799. Citado nas pp. 43, 44 e 57.
- JEONG, I. C.; YOON, H.; KANG, H.; YEOM, H. Effects of skin surface temperature on photoplethysmograph. **Journal of healthcare engineering**, v. 5, p. 429–438, 12 2014. Citado nas pp. 34 e 42.
- JO, E.-J.; MUN, H.; KIM, M.-G. Homogeneous immunosensor based on luminescence resonance energy transfer for glycated hemoglobin (hba1c) detection using upconversion nanoparticles. **Analytical Chemistry**, v. 88, 02 2016. Citado na p. 39.
- JOBBÁGY, ; CSORDÁS, P.; MERSICH, A. Blood pressure measurement at home. *In: ____*. [S.l.: s.n.], 2007. v. 14, p. 3453–3456. ISBN 978-3-540-36839-7. Citado na p. 125.
- KAMAL, A.; HARNESS, J.; IRVING, G.; MEARN, A. Skin photoplethysmography — a review. **Computer Methods and Programs in Biomedicine**, v. 28, n. 4, p. 257–269, 1989. ISSN 0169-2607. Disponível em: <https://www.sciencedirect.com/science/article/pii/0169260789901594>. Citado na p. 32.
- KARLEN, W.; RAMAN, S.; ANSERMINO, J. M.; DUMONT, G. A. Multiparameter respiratory rate estimation from the photoplethysmogram. **IEEE Transactions on Biomedical Engineering**, v. 60, n. 7, p. 1946–1953, 2013. Citado nas pp. 37 e 38.
- KIM, V.; BENDITT, J. O.; WISE, R. A.; SHARAFKHANEH, A. Oxygen therapy in chronic obstructive pulmonary disease. **Proceedings of the American Thoracic Society**, American Thoracic Society, v. 5, n. 4, p. 513–518, 2008. Citado na p. 30.
- KING, D. E. Dlib-ml: A machine learning toolkit. **The Journal of Machine Learning Research**, JMLR. org, v. 10, p. 1755–1758, 2009. Citado na p. 49.
- KIYATKIN, E. A. Respiratory depression and brain hypoxia induced by opioid drugs: Morphine, oxycodone, heroin, and fentanyl. **Neuropharmacology**, v. 151, p. 219–226, 2019. ISSN 0028-3908. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0028390818306245>. Citado na p. 29.
- KRISHNASWAMY, A.; BARANOSKI, G. V. G. A biophysically-based spectral model of light interaction with human skin. **Computer Graphics Forum**, v. 23, 2004. Disponível em: <https://api.semanticscholar.org/CorpusID:5746906>. Citado na p. 34.

- KUMAR, M.; VEERARAGHAVAN, A.; SABHARVAL, A. **DistancePPG: Robust non-contact vital signs monitoring using a camera**. 2015. Disponível em: <https://arxiv.org/abs/1502.08040>. Citado na p. 57.
- KVIESIS-KIPGE, E.; RUBĪNS, U. Remote photoplethysmography device with adaptive illumination for skin microcirculation assessment. *In: SPIE. Biophotonics—Riga 2020*. [S.l.], 2020. v. 11585, p. 33–36. Citado na p. 43.
- KWON, S.; KIM, J.; LEE, D.; PARK, K. Roi analysis for remote photoplethysmography on facial video. *In: 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.: s.n.], 2015. p. 4938–4941. Citado nas pp. 50 e 51.
- LAM, A.; KUNO, Y. Robust heart rate measurement from video using select random patches. *In: Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. [S.l.: s.n.], 2015. Citado na p. 40.
- LAURIE, J.; HIGGINS, N.; PEYNOT, T.; ROBERTS, J. Dedicated exposure control for remote photoplethysmography. **IEEE Access**, PP, p. 1–1, 06 2020. Citado nas pp. 43, 45 e 56.
- LEE, D.; KIM, J.; KWON, S.; PARK, K. Heart rate estimation from facial photoplethysmography during dynamic illuminance changes. *In: 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.: s.n.], 2015. p. 2758–2761. Citado na p. 44.
- LEE, I.; PARK, N.; LEE, H.; HWANG, C.; KIM, J.; PARK, S. Systematic review on human skin-compatible wearable photoplethysmography sensors. **Applied Sciences**, v. 11, p. 2313, 03 2021. Citado nas pp. 25, 28, 29, 32 e 39.
- LEWANDOWSKA, M.; RUMIŃSKI, J.; KOCEJKO, T.; NOWAK, J. Measuring pulse rate with a webcam — a non-contact method for evaluating cardiac activity. *In: 2011 Federated Conference on Computer Science and Information Systems (FedCSIS)*. [S.l.: s.n.], 2011. p. 405–410. Citado nas pp. 45 e 76.
- LEWANDOWSKA, M.; RUMIŃSKI, J.; KOCEJKO, T.; NOWAK, J. Measuring pulse rate with a webcam — a non-contact method for evaluating cardiac activity. *In: 2011 Federated Conference on Computer Science and Information Systems (FedCSIS)*. [S.l.: s.n.], 2011. p. 405–410. Citado na p. 54.
- LI, X.; CHEN, J.; ZHAO, G.; PIETIKÄINEN, M. Remote heart rate measurement from face videos under realistic situations. *In: 2014 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2014. p. 4264–4271. Citado nas pp. 34, 40, 44, 46 e 57.
- LIN, Y.-C.; CHOU, N.-K.; LIN, G.-Y.; LI, M.-H.; LIN, Y.-H. A real-time contactless pulse rate and motion status monitoring system based on complexion tracking. **sensors**, MDPI, v. 17, n. 7, p. 1490, 2017. Citado na p. 57.

- LISTER, T.; WRIGHT, P.; CHAPPELL, P. Optical properties of human skin. **Journal of biomedical optics**, v. 17, p. 90901–1, 09 2012. Citado na p. 39.
- LIU, X.; FROMM, J.; PATEL, S.; MCDUFF, D. **Multi-Task Temporal Shift Attention Networks for On-Device Contactless Vitals Measurement**. 2021. Disponível em: <https://arxiv.org/abs/2006.03790>. Citado na p. 52.
- LOCHNER, C.; KHAN, Y.; PIERRE, A.; ARIAS, A. All-organic optoelectronic sensor for pulse oximetry. **Nature communications**, v. 5, p. 5745, 12 2014. Citado na p. 33.
- LTD, R. P. **Raspberry Pi 4 Model B Product Brief**. [S.l.], 2024. Publicado em abril de 2024. Disponível em: <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/specifications/?variant=raspberry-pi-4-model-b-4gb>. Acesso em: 16/08/2024. Citado na p. 58.
- LUGARESI, C.; TANG, J.; NASH, H.; MCCLANAHAN, C.; UBOWEJA, E.; HAYS, M.; ZHANG, F.; CHANG, C.-L.; YONG, M. G.; LEE, J.; CHANG, W.-T.; HUA, W.; GEORG, M.; GRUNDMANN, M. **MediaPipe: A Framework for Building Perception Pipelines**. 2019. <https://arxiv.org/abs/1906.08172>. Google Research. Citado nas pp. 47, 48 e 50.
- MAESTRE-RENDON, J. R.; RIVERA-ROMAN, T. A.; FERNANDEZ-JARAMILLO, A. A.; PAREDES, N. E. G.; OLMEDO, J. J. S. A non-contact photoplethysmography technique for the estimation of heart rate via smartphone. **Applied Sciences**, v. 10, n. 1, 2020. ISSN 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/10/1/154>. Citado na p. 50.
- MAJUMDAR, S.; EURICH, D.; GAMBLE, J.-M.; SENTHILSELVAN, A.; MARRIE, T. Oxygen saturations less than 92outpatients with pneumonia: A population-based cohort study. **Clinical infectious diseases : an official publication of the Infectious Diseases Society of America**, v. 52, p. 325–31, 02 2011. Citado na p. 30.
- MakerPortal. **MPS20N0040D Pressure Sensor Calibration with Arduino**. 2024. Disponível em: <https://makersportal.com/blog/2020/6/4/mps20n0040d-pressure-sensor-calibration-with-arduino>. Citado nas pp. 97, 98 e 100.
- MEJÍA-MEJÍA, E.; ALLEN, J.; BUDIDHA, K.; EL-HAJJ, C.; KYRIACOU, P. A.; CHARLTON, P. H. 4 - photoplethysmography signal processing and synthesis. In: ALLEN, J.; KYRIACOU, P. (Ed.). **Photoplethysmography**. Academic Press, 2022. p. 69–146. ISBN 978-0-12-823374-0. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780128233740000153>. Citado na p. 37.
- MEREDITH, D. J.; CLIFTON, D.; CHARLTON, P.; BROOKS, J.; PUGH, C. W.; TARASSENKO, L. Photoplethysmographic derivation of respiratory rate: a review of relevant physiology. **Journal of Medical Engineering & Technology**, v. 35, n. 1-2, p. 1–7, 2011. Citado na p. 36.

- MEREGE, F.; ROCHA, A. da; BAPTISTA, G.; MIRANDA, G.; VITENA, G.; SILVA, M. J. da; JÚNIOR, E.; MIOSSO, C. Photoplethysmography-based detection of acute signals of intoxication by alcohol and other abuse drugs in drivers: Part i – viability study. *In: Proceedings of the Brazilian Biomedical Engineering Conference (CBEB)*. Ribeirã Preto, S.P., Brazil: [s.n.], 2024. Accepted for Publication. Citado nas pp. 18 e 20.
- Microcontrollerslab. **AD8232 ECG Module with Arduino – Heart Rate Monitor**. 2024. Disponível em: <https://microcontrollerslab.com/ad8232-ecg-module-pinout-interfacing-with-arduino-applications-features/>. Citado nas pp. 95 e 96.
- MILLASSEAU, S.; GUIGUI, F.; KELLY, R.; PRASAD, K.; COCKCROFT, J.; RITTER, J.; CHOWIENCZYK, P. Noninvasive assessment of the digital volume pulse : Comparison with the peripheral pressure pulse. **Hypertension**, v. 36, p. 952–6, 01 2001. Citado na p. 32.
- MILLASSEAU, S.; KELLY, R.; RITTER, J.; CHOWIENCZYK, P. Determination of age-related increases in large artery stiffness by digital pulse contour analysis. **Clinical science (London, England : 1979)**, v. 103, p. 371–7, 10 2002. Citado nas pp. 32, 33, 34 e 35.
- MONKARESI, H.; CALVO, R. A.; YAN, H. A machine learning approach to improve contactless heart rate monitoring using a webcam. **IEEE Journal of Biomedical and Health Informatics**, v. 18, n. 4, p. 1153–1160, 2014. Citado na p. 56.
- MONTAGNA, W.; KLIGMAN, A. M.; CARLISLE, K. S. Overview of skin. *In: ____*. **Atlas of Normal Human Skin**. New York, NY: Springer New York, 1992. p. 3–5. ISBN 978-1-4613-9202-6. Disponível em: https://doi.org/10.1007/978-1-4613-9202-6_2. Citado nas pp. 26 e 32.
- MULAI, E. M. Q. **Anatofisiologia Cardíaca**. Dissertação (Mestrado) — Universidade da Beira Interior (Portugal), 2019. Citado na p. 30.
- MURRAY, W. B.; FOSTER, P. A. The peripheral pulse wave: information overlooked. **Journal of clinical monitoring**, Springer, v. 12, p. 365–377, 1996. Citado na p. 38.
- NICOLO, A.; MASSARONI, C.; SCHENA, E.; SACCHETTI, M. The importance of respiratory rate monitoring: From healthcare to sport and exercise. **Sensors**, MDPI, v. 20, n. 21, p. 6396, 2020. Citado na p. 22.
- NIKOLAIEV, S.; TELENYK, S.; TYMOSHENKO, Y. Non-contact video-based remote photoplethysmography for human stress detection. **Journal of Automation, Mobile Robotics and Intelligent Systems**, v. 14, n. 2, p. 63–73, 2023. Citado na p. 49.
- NITZAN, M.; BABCHENKO, A.; FAIB, I.; DAVIDSON, E.; ADLER, D. Assessment of changes in arterial compliance by photoplethysmography. *In: 21st IEEE Convention of the Electrical and Electronic Engineers in Israel. Proceedings (Cat. No.00EX377)*. [S.l.: s.n.], 2000. p. 351–354. Citado na p. 34.

- Organização Pan-Americana da Saúde. **Uso de drogas e segurança no trânsito**. Brasília, DF: Organização Pan-Americana da Saúde, 2018. Licença: CC BY-NC-SA 3.0 IGO. Citado nas pp. 18 e 19.
- PARK, J.; SEOK, H.; KIM, S.-S.; SHIN, H. Photoplethysmogram analysis and applications: An integrative review. **Frontiers in Physiology**, v. 12, 03 2022. Citado nas pp. 25, 32, 33, 34 e 38.
- PEREIRA, T.; TRAN, N.; GADHOUMI, K.; PELTER, M.; DO, D.; LEE, R.; COLORADO, R.; MEISEL, K.; HU, X. Photoplethysmography based atrial fibrillation detection: a review. **npj Digital Medicine**, v. 3, 12 2020. Citado na p. 34.
- PHAM, T.; LAU, Z. J.; CHEN, S. H. A.; MAKOWSKI, D. Heart rate variability in psychology: A review of hrv indices and an analysis tutorial. **Sensors**, v. 21, n. 12, 2021. ISSN 1424-8220. Disponível em: <https://www.mdpi.com/1424-8220/21/12/3998>. Citado na p. 21.
- PILZ, C. S.; ZAUNSEDER, S.; KRAJEWSKI, J.; BLAZEK, V. Local group invariance for heart rate estimation from face videos in the wild. *In: 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. [S.l.: s.n.], 2018. p. 1335–13358. Citado nas pp. 56, 64 e 76.
- PIRZADA, P.; MORRISON, D.; DOHERTY, G.; DHASMANA, D.; HARRIS-BIRTILL, D. Automated remote pulse oximetry system (arpos). **Sensors**, v. 22, n. 13, 2022. ISSN 1424-8220. Disponível em: <https://www.mdpi.com/1424-8220/22/13/4974>. Citado na p. 41.
- PIRZADA, P.; WILDE, A.; DOHERTY, G. H.; HARRIS-BIRTILL, D. Remote photoplethysmography (rppg): A state-of-the-art review. **medRxiv**, Cold Spring Harbor Laboratory Press, 2023. Disponível em: <https://www.medrxiv.org/content/early/2023/10/12/2023.10.12.23296882>. Citado na p. 28.
- PIRZADA, P.; WILDE, A.; HARRIS-BIRTILL, D. Remote photoplethysmography for heart rate and blood oxygenation measurement: a review. **IEEE Sensors Journal**, p. 1–1, 2024. Citado nas pp. 24, 25, 27, 30, 39, 40, 41, 42, 43, 45, 52, 53 e 57.
- PLÜDDEMANN, A.; THOMPSON, M.; HENEGHAN, C.; PRICE, C. Pulse oximetry in primary care: Primary care diagnostic technology update. **The British journal of general practice : the journal of the Royal College of General Practitioners**, v. 61, p. 358–9, 05 2011. Citado na p. 29.
- POH, M.-Z.; MCDUFF, D. J.; PICARD, R. W. Non-contact, automated cardiac pulse measurements using video imaging and blind source separation. **Opt. Express**, Optica Publishing Group, v. 18, n. 10, p. 10762–10774, May 2010. Disponível em: <https://opg.optica.org/oe/abstract.cfm?URI=oe-18-10-10762>. Citado nas pp. 46, 51, 54 e 76.

- PREMKUMAR, S.; HEMANTH, D. J. Intelligent remote photoplethysmography-based methods for heart rate estimation from face videos: A survey. **Informatics**, v. 9, n. 3, 2022. ISSN 2227-9709. Disponível em: <https://www.mdpi.com/2227-9709/9/3/57>. Citado nas pp. 41 e 49.
- QAWQZEH, Y.; REAZ, M. B. I.; ALI, M. The analysis of ppg morphology: Investigating the effects of aging on arterial compliance. **Measurement Science Review**, v. 12, p. 266–271, 12 2012. Citado na p. 38.
- QI, H.; WANG, Z. J.; MIAO, C. Non-contact driver cardiac physiological monitoring using video data. In: **2015 IEEE China Summit and International Conference on Signal and Information Processing (ChinaSIP)**. [S.l.: s.n.], 2015. p. 418–422. Citado na p. 51.
- RALSTON, A.; WEBB, R.; RUNCIMAN, W. Potential errors in pulse oximetry: I. pulse oximeter evaluation. **Anaesthesia**, Wiley-Blackwell, v. 46, n. 3, p. 202–206, mar. 1991. ISSN 0003-2409. Citado na p. 42.
- RAY, D.; COLLINS, T.; WOOLLEY, S. I.; PONNAPALLI, P. V. S. A review of wearable multi-wavelength photoplethysmography. **IEEE Reviews in Biomedical Engineering**, v. 16, p. 136–151, 2023. Citado nas pp. 24, 26, 27, 28, 33, 34 e 41.
- REDMON, J.; FARHADI, A. Yolov3: An incremental improvement. **arXiv**, 2018. Citado na p. 48.
- REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster r-cnn: Towards real-time object detection with region proposal networks. **Advances in neural information processing systems**, v. 28, 2015. Citado na p. 49.
- RIBEIRO, L. S.; DAMACENA, G. N.; JUNIOR, P. R. B. d. S.; SZWARCOWALD, C. L. O hábito de beber e dirigir no brasil: Pesquisa nacional de saúde, 2013 e 2019. **Revista de Saúde Pública**, SciELO Brasil, v. 56, p. 115, 2023. Citado na p. 18.
- RICHARDSON, M.; WALLACE, S. **Getting Started with Raspberry Pi**. [S.l.]: O’Reilly Media, Inc., 2012. Citado na p. 59.
- RODRIGUES, K.; PEREIRA, M.; PÁDUA, F. Detecção em tempo real da frequência cardíaca de pessoas por meio da análise de variações temporais em vídeos. **e-xacta**, v. 9, p. 49, 06 2016. Citado nas pp. 32, 40 e 56.
- ROUAST, P.; ADAM, M.; CHIONG, R.; CORNFORTH, D.; LUX, E. Remote heart rate measurement using low-cost rgb face video: A technical literature review. **Frontiers of Computer Science (electronic)**, v. 12, p. 858–872, 09 2018. Citado na p. 25.
- RUKASHA, T.; WOOLLEY, S.; KYRIACOU, T.; COLLINS, T. Evaluation of wearable electronics for epilepsy: A systematic review. **Electronics**, v. 9, p. 968, 06 2020. Citado na p. 38.

- SELVARAJU, V.; SPICHER, N.; WANG, J.; GANAPATHY, N.; WARNECKE, J. M.; LEONHARDT, S.; SWAMINATHAN, R.; DESERNO, T. M. Continuous monitoring of vital signs using cameras: A systematic review. **Sensors**, v. 22, n. 11, 2022. ISSN 1424-8220. Disponível em: <https://www.mdpi.com/1424-8220/22/11/4097>. Citado na p. 43.
- SHAN, L.; YU, M. Video-based heart rate measurement using head motion tracking and ica. *In: 2013 6th International Congress on Image and Signal Processing (CISP)*. [S.l.: s.n.], 2013. v. 01, p. 160–164. Citado na p. 46.
- SHCHERBINA, A.; MATTSSON, C. M.; WAGGOTT, D.; SALISBURY, H.; CHRISTLE, J. W.; HASTIE, T.; WHEELER, M. T.; ASHLEY, E. A. Accuracy in wrist-worn, sensor-based measurements of heart rate and energy expenditure in a diverse cohort. **Journal of Personalized Medicine**, v. 7, n. 2, 2017. ISSN 2075-4426. Disponível em: <https://www.mdpi.com/2075-4426/7/2/3>. Citado na p. 42.
- SHELLEY, K. Photoplethysmography: Beyond the calculation of arterial oxygen saturation and heart rate. **Anesthesia and analgesia**, v. 105, p. S31–6, tables of contents, 01 2008. Citado na p. 34.
- SHELLEY, K. H.; JABLONKA, D. H.; AWAD, A. A.; STOUT, R. G.; REZKANNA, H.; SILVERMAN, D. G. What is the best site for measuring the effect of ventilation on the pulse oximeter waveform? **Anesthesia and analgesia**, v. 103, n. 2, p. 372–7, table of contents, August 2006. ISSN 0003-2999. Disponível em: <https://doi.org/10.1213/01.ane.0000222477.67637.17>. Citado na p. 34.
- SHI, P.; HU, S.; ZHU, Y.; ZHENG, J.; QIU, Y.; CHEANG, P. Insight into the dicrotic notch in photoplethysmographic pulses from the finger tip of young adults. **Journal of medical engineering & technology**, v. 33, p. 628–33, 11 2009. Citado na p. 34.
- SHI, P.; HU, S.; ZHU, Y.; ZHENG, J.; QIU, Y.; CHEANG, P. Insight into the dicrotic notch in photoplethysmographic pulses from the finger tip of young adults. **Journal of medical engineering & technology**, v. 33, p. 628–33, 11 2009. Citado na p. 38.
- SINHAL, R.; SINGH, K. R.; GUPTA, K. O. Color intensity: A study of rppg algorithm for heart rate estimation. *In: 2021 International Conference on Computational Performance Evaluation (ComPE)*. [S.l.: s.n.], 2021. p. 580–584. Citado nas pp. 32 e 44.
- SMELYAKOV, K.; CHUPRYNA, A.; BOHOMOLOV, O.; HUNKO, N. The neural network models effectiveness for face detection and face recognition. *In: 2021 IEEE Open Conference of Electrical, Electronic and Information Sciences (eStream)*. [S.l.: s.n.], 2021. p. 1–7. Citado na p. 50.
- STRICKER, R.; MÜLLER, S.; GROSS, H.-M. Non-contact video-based pulse rate measurement on a mobile service robot. *In: The 23rd IEEE International Symposium on Robot and Human Interactive Communication*. [S.l.: s.n.], 2014. p. 1056–1062. Citado na p. 45.

- SUN, Y.; HU, S.; AZORIN-PERIS, V.; KALAWSKY, R.; GREENWALD, S. E. Noncontact imaging photoplethysmography to effectively access pulse rate variability. **Journal of Biomedical Optics**, SPIE, v. 18, n. 6, p. 061205, 2012. Disponível em: <https://doi.org/10.1117/1.JBO.18.6.061205>. Citado na p. 57.
- SUNER, S.; PARTRIDGE, R.; SUCOV, A.; VALENTE, J.; CHEE, K.; HUGHES, A.; JAY, G. Non-invasive pulse co-oximetry screening in the emergency department identifies occult carbon monoxide toxicity. **The Journal of emergency medicine**, v. 34, p. 441–50, 06 2008. Citado na p. 39.
- TAMURA, T.; MAEDA, Y.; SEKINE, M.; YOSHIDA, M. Wearable photoplethysmographic sensors—past and present. **Electronics**, v. 3, n. 2, p. 282–302, 2014. ISSN 2079-9292. Disponível em: <https://www.mdpi.com/2079-9292/3/2/282>. Citado na p. 36.
- TRAFFORD, J. de; LAFFERTY, K. What does photoplethysmography measure? **Med. Biol. Eng. Comput.**, Springer Nature, v. 22, n. 5, p. 479–480, set. 1984. Citado na p. 32.
- UNAKAFOV, A. M. Pulse rate estimation using imaging photoplethysmography: generic framework and comparison of methods on a publicly available dataset. **Biomedical Physics Engineering Express**, IOP Publishing, v. 4, n. 4, p. 045001, apr 2018. Disponível em: <https://dx.doi.org/10.1088/2057-1976/aabd09>. Citado na p. 52.
- UNURSAIKHAN, B.; TANAKA, N.; SUN, G.; WATANABE, S.; YOSHII, M.; FUNAHASHI, K.; SEKIMOTO, F.; HAYASHIBARA, F.; YOSHIZAWA, Y.; CHOIMAA, L.; MATSUI, T. Development of a novel web camera-based contact-free major depressive disorder screening system using autonomic nervous responses induced by a mental task and its clinical application. **Frontiers in Physiology**, v. 12, p. 642986, 05 2021. Citado nas pp. 125 e 126.
- UPTON, E.; HALFACREE, G. **Raspberry Pi User Guide**. [S.l.]: John Wiley & Sons, 2014. Citado na p. 58.
- VALENCELL. **Optical Heart Rate Monitoring: What You Need to Know**. 2023. Accessed: 2024-07-05. Disponível em: <https://medium.com/@Valencell/optical-heart-rate-monitoring-what-you-need-to-know-d2ceba1e6afd>. Citado na p. 34.
- van Esch, R.; CRAMER, I.; LI, X.; VERSTAPPEN, C.; KLOEZE, C.; van 't Veer, M.; DIERICK, A.; HOMMERSON, S.; MONTENIJ, L.; DEKKER, L.; BOUWMAN, R.; KORSTEN, E.; BERGMANS, J.; STUIJK, S.; ZINGER, S. Video health monitoring for cardiac arrhythmia detection in a real hospital scenario. *In*: PARK, B.; YOSHIDA, H. (Ed.). **Medical Imaging 2023**. United States: SPIE, 2023. (Proceedings of SPIE). Spie Medical Imaging 2023 ; Conference date: 19-02-2023 Through 24-02-2023. Citado na p. 45.
- VANDERLEI, L. C. M.; PASTRE, C. M.; HOSHI, R. A.; CARVALHO, T. D. d.; GODOY, M. F. d. Noções básicas de variabilidade da frequência cardíaca e sua aplicabilidade clínica.

- Brazilian Journal of Cardiovascular Surgery**, SciELO Brasil, v. 24, p. 205–217, 2009. Citado nas pp. 21 e 22.
- VERKRUYSSSE, W.; SVAASAND, L. O.; NELSON, J. S. Remote plethysmographic imaging using ambient light. **Opt. Express**, Optica Publishing Group, v. 16, n. 26, p. 21434–21445, Dec 2008. Disponível em: <https://opg.optica.org/oe/abstract.cfm?URI=oe-16-26-21434>. Citado nas pp. 45, 51, 54 e 76.
- VIEIRA, L. M. A problemática da inteligência artificial e dos vieses algorítmicos: caso compas. *In: **Brazilian Technology Symposium***. [S.l.: s.n.], 2019. v. 1. Citado na p. 21.
- WANG, G. Influence of roi selection for remote photoplethysmography with singular spectrum analysis. *In: **2021 IEEE International Conference on Artificial Intelligence and Industrial Design (AIID)***. [S.l.: s.n.], 2021. p. 416–420. Citado nas pp. 50, 51 e 52.
- WANG, R.; BLACKBURN, G.; DESAI, M.; PHELAN, D.; GILLINOV, L.; HOUGHTALING, P.; GILLINOV, A. Accuracy of wrist-worn heart rate monitors. **JAMA Cardiology**, v. 2, 10 2016. Citado na p. 42.
- WANG, W.; BRINKER, A. C. den; STUIJK, S.; HAAN, G. de. Algorithmic principles of remote ppg. **IEEE Transactions on Biomedical Engineering**, v. 64, n. 7, p. 1479–1491, 2017. Citado nas pp. 55 e 76.
- WANG, W.; BRINKER, A. C. den; STUIJK, S.; HAAN, G. de. Robust heart rate from fitness videos. **Physiological Measurement**, IOP Publishing, v. 38, n. 6, p. 1023, may 2017. Disponível em: <https://dx.doi.org/10.1088/1361-6579/aa6d02>. Citado na p. 43.
- WANG, W.; SHAN, C. Impact of makeup on remote-ppg monitoring. **Biomedical Physics & Engineering Express**, v. 6, 03 2020. Citado nas pp. 41, 43, 44 e 57.
- WANG, W.; STUIJK, S.; HAAN, G. A novel algorithm for remote photoplethysmography: Spatial subspace rotation. **IEEE transactions on bio-medical engineering**, v. 0, p. 1, 12 2015. Citado nas pp. 40, 56, 66 e 76.
- WANG, W.; STUIJK, S.; HAAN, G. de. Exploiting spatial redundancy of image sensor for motion robust rppg. **IEEE Transactions on Biomedical Engineering**, v. 62, n. 2, p. 415–425, 2015. Citado na p. 47.
- WAQAR, M. **Contact-Free Heart Rate Measurement from Human Face Videos and Its Biometric Recognition Application**. Tese (Doutorado) — Aberystwyth University, 2019. Citado na p. 43.
- WEBSTER, J. G. **Design of pulse oximeters**. [S.l.]: Crc Press, 1997. Citado na p. 28.
- WEI, L.; TIAN, Y.; WANG, Y.; EBRAHIMI, T.; HUANG, T. Automatic webcam-based human heart rate measurements using laplacian eigenmap. *In: LEE, K. M.; MATSUSHITA, Y.; REHG, J. M.; HU, Z. (Ed.). **Computer Vision – ACCV 2012***. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 281–292. ISBN 978-3-642-37444-9. Citado na p. 56.

-
- Wikipedia contributors. **Ciclo cardíaco** — **Wikipédia, a enciclopédia livre**. 2024. [Online; acessado em 05-jul-2024]. Disponível em: https://pt.wikipedia.org/wiki/Ciclo_card%C3%ADaco. Citado nas pp. 30 e 31.
- World Health Organization. **Global Health Estimates**. Geneva: World Health Organization, 2016. Citado na p. 18.
- WU, H.-Y.; RUBINSTEIN, M.; SHIH, E.; GUTTAG, J.; DURAND, F.; FREEMAN, W. Eulerian video magnification for revealing subtle changes in the world. **ACM transactions on graphics (TOG)**, ACM New York, NY, USA, v. 31, n. 4, p. 1–8, 2012. Citado na p. 56.
- XU, L.; CHENG, J.; CHEN, X. Illumination variation interference suppression in remote ppg using pls and memd. **Electronics Letters**, v. 53, 12 2016. Citado na p. 34.
- YUAN, Z.; FANG, Z.; CHEN, X.; XU, Z.; CHEN, D.; ZHAO, Z.; XIA, S. A novel reflection pulse oximeter for home health care applications. *In: 2014 Fifth International Conference on Intelligent Systems Design and Engineering Applications*. [S.l.: s.n.], 2014. p. 64–68. Citado na p. 28.
- ZEHAVA, O.-B.; GINO, O.; DANDEKER, L.; SHEFFER, N.; BALTAJE, E.; AHARONSON, V. The feasibility of flat, portable and wireless device for non-invasive peripheral oxygenation measurement over the entire body. **Journal of Biomedical Science and Engineering**, v. 09, p. 147–159, 01 2016. Citado na p. 24.
- ZHANG, Q.; LINDBERG, L.-G.; KADEFORS, R.; JORMA, S. A non-invasive measure of changes in blood flow in the human anterior tibial muscle. **Arbeitsphysiologie**, v. 84, p. 448–452, 05 2001. Citado na p. 34.
- ZHAO, F.; LI, M.; QIAN, Y.; TSIEN, J. Z. Remote measurements of heart and respiration rates for telemedicine. **PLOS ONE**, Public Library of Science, v. 8, n. 10, p. 1–14, 10 2013. Disponível em: <https://doi.org/10.1371/journal.pone.0071384>. Citado nas pp. 25, 43, 44 e 57.

Apêndices

Apêndice A – Tabelas grandes

Tabela A.1 – Resultados dos testes no primeiro protótipo para cada combinação de parâmetros.

AeEnable	AeFlickerMode	AfMode	AwbEnable	NoiseReductionMode	Qualidade
TRUE	FlickerOff	Auto	TRUE	HighQuality	0,586
TRUE	FlickerOff	Continuous	TRUE	Off	0,586
TRUE	FlickerManual	Auto	FALSE	Fast	0,571
TRUE	FlickerOff	Continuous	TRUE	Fast	0,542
TRUE	FlickerOff	Continuous	TRUE	HighQuality	0,535
TRUE	FlickerManual	Continuous	TRUE	Fast	0,512
TRUE	FlickerManual	Auto	TRUE	Fast	0,503
TRUE	FlickerOff	Auto	FALSE	HighQuality	0,501
TRUE	FlickerOff	Auto	FALSE	Fast	0,498
TRUE	FlickerOff	Auto	TRUE	Fast	0,479
TRUE	FlickerManual	Auto	FALSE	HighQuality	0,473
TRUE	FlickerOff	Auto	FALSE	Off	0,458
TRUE	FlickerOff	Continuous	FALSE	HighQuality	0,448
TRUE	FlickerManual	Auto	TRUE	HighQuality	0,433
TRUE	FlickerManual	Continuous	TRUE	Off	0,429
TRUE	FlickerManual	Auto	TRUE	Off	0,424
TRUE	FlickerManual	Continuous	FALSE	HighQuality	0,421
TRUE	FlickerOff	Continuous	FALSE	Off	0,418
TRUE	FlickerOff	Continuous	FALSE	Fast	0,410
TRUE	FlickerOff	Auto	TRUE	Off	0,410
TRUE	FlickerManual	Continuous	FALSE	Fast	0,377
TRUE	FlickerManual	Auto	FALSE	Off	0,367
TRUE	FlickerManual	Continuous	TRUE	HighQuality	0,340
TRUE	FlickerManual	Continuous	FALSE	Off	0,268
FALSE	FlickerOff	Auto	TRUE	Off	0,000
FALSE	FlickerOff	Auto	TRUE	Fast	0,000
FALSE	FlickerOff	Auto	TRUE	HighQuality	0,000
FALSE	FlickerOff	Auto	FALSE	Off	0,000
FALSE	FlickerOff	Auto	FALSE	Fast	0,000
FALSE	FlickerOff	Auto	FALSE	HighQuality	0,000
FALSE	FlickerOff	Continuous	TRUE	Off	0,000
FALSE	FlickerOff	Continuous	TRUE	Fast	0,000
FALSE	FlickerOff	Continuous	TRUE	HighQuality	0,000
FALSE	FlickerOff	Continuous	FALSE	Off	0,000
FALSE	FlickerOff	Continuous	FALSE	Fast	0,000
FALSE	FlickerOff	Continuous	FALSE	HighQuality	0,000
FALSE	FlickerManual	Auto	TRUE	Off	0,000
FALSE	FlickerManual	Auto	TRUE	Fast	0,000
FALSE	FlickerManual	Auto	TRUE	HighQuality	0,000
FALSE	FlickerManual	Auto	FALSE	Off	0,000
FALSE	FlickerManual	Auto	FALSE	Fast	0,000
FALSE	FlickerManual	Auto	FALSE	HighQuality	0,000
FALSE	FlickerManual	Continuous	TRUE	Off	0,000
FALSE	FlickerManual	Continuous	TRUE	Fast	0,000
FALSE	FlickerManual	Continuous	TRUE	HighQuality	0,000
FALSE	FlickerManual	Continuous	FALSE	Off	0,000
FALSE	FlickerManual	Continuous	FALSE	Fast	0,000
FALSE	FlickerManual	Continuous	FALSE	HighQuality	0,000

Fonte: Autores

Tabela A.2 – Melhores combinações de Patch e Método para os 51 vídeos dos grupos 3, 4, 5 e 6

Número do Patch	Método	Erro Médio Absoluto
101	PCA	0.729771
151	CHROM	0.740439
101	GBGR	0.759855
101	POS	0.779582
330	POS	0.793912
36	POS	0.805260
108	POS	0.812676
337	PCA	0.815648
266	PCA	0.822190
266	POS	0.823298
266	GBGR	0.828900
10	PCA	0.830727
10	GBGR	0.831218
36	PCA	0.848663
107	POS	0.849130
109	POS	0.856195
50	PCA	0.866714
151	POS	0.868751
108	CHROM	0.879481
109	CHROM	0.882970
108	PCA	0.893221
330	PCA	0.921175
330	GBGR	0.927120
151	OMIT	0.927494
151	LGI	0.937680
36	CHROM	0.940486
151	GBGR	0.940597
151	PCA	0.941015
336	LGI	0.949062
109	GBGR	0.951085

Fonte: Autores