

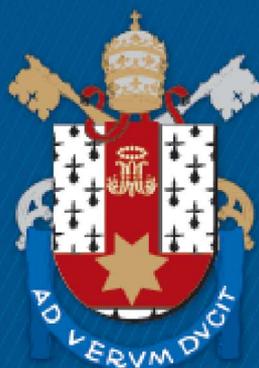
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO DOUTORADO
EM CIÊNCIA DA COMPUTAÇÃO

AYALON ANGELO DE MORAES FILHO

**ANÁLISE DE MÉTODOS PARA INFERÊNCIA DA TAXA DE
RESPIRAÇÃO UTILIZANDO O SINAL DE
FOTOPLETISMOGRAFIA**

Porto Alegre
2022

PÓS-GRADUAÇÃO - *STRICTO SENSU*



Pontifícia Universidade Católica
do Rio Grande do Sul

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

**ANÁLISE DE MÉTODOS PARA INFERÊNCIA DA TAXA
DE RESPIRAÇÃO UTILIZANDO O SINAL DE
FOTOPLETISMOGRAFIA**

AYALON ANGELO DE MORAES FILHO

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Escola Politécnica da Pontifícia Universidade Católica do Rio Grande do Sul como requisito parcial para obtenção do grau de Mestre.

Orientador: Prof. Dr. César Augusto Missio Marcon

Porto Alegre, agosto de 2022.

Ficha Catalográfica

M827a Moraes Filho, Ayalon Angelo de

Análise de Métodos para Inferência da Taxa de Respiração Utilizando o Sinal de Fotopletismografia / Ayalon Angelo de Moraes Filho. – 2022.

96.

Dissertação (Mestrado) – Programa de Pós-Graduação em Ciência da Computação, PUCRS.

Orientador: Prof. Dr. César Augusto Missio Marcon.

1. Saúde. 2. fotopletismografia. 3. estimativa de frequência respiratória. 4. dispositivo vestível. I. Marcon, César Augusto Missio. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da PUCRS com os dados fornecidos pelo(a) autor(a).

Bibliotecária responsável: Clarissa Jesinska Selbach CRB-10/2051

AYALON ANGELO DE MORAES FILHO

**ANÁLISE DE MÉTODOS PARA INFERÊNCIA DA TAXA
DE RESPIRAÇÃO UTILIZANDO O SINAL DE
FOTOPLETISMOGRAFIA**

Esta Dissertação de Mestrado foi submetida como requisito parcial para obtenção do grau de Mestre apresentada ao Programa de Pós-Graduação em Ciência da Computação da Escola Politécnica da Pontifícia Universidade Católica do Rio Grande do Sul

Sancionada em agosto de 2022.

MEMBROS DO COMITÊ:

Prof. Dr. Rafael Reimann Baptista (GERONBIO/PUCRS)

Prof. Dr. Fernando Gehm Moraes (PPGCC/PUCRS)

Prof. Dr. César Augusto Missio Marcon (PPGCC/PUCRS - Orientador)

AGRADECIMENTOS

Agradeço ao professor e orientador César Marcon pela atenção e as revisões que contribuíram muito para o desenvolvimento deste trabalho.

Agradeço aos meus familiares e amigos pelo apoio durante essa jornada de dois anos de mestrado, bem como ao grupo de pesquisa do LifeSenior pelas discussões envolvendo todos os trabalhos de pesquisa, possibilitando um enriquecimento do conteúdo presente neste trabalho.

Agradeço também ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), o Ministério da Ciência, Tecnologia, Inovações e Comunicações (MCTIC), a Toth LifeCare e a Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS) pelo apoio financeiro, estrutural e tecnológico disponibilizados.

Análise de Métodos para Inferência da Taxa de Respiração Utilizando o Sinal de Fotopletismografia

RESUMO

Academia e indústria têm dedicado grande esforço para a pesquisa e desenvolvimento de dispositivos vestíveis inteligentes aplicados ao monitoramento de saúde. Estes esforços são influenciados principalmente pelos custos crescentes na área da saúde e apoiados por avanços em nanotecnologia. No cenário de dispositivos vestíveis, o sensor de fotopletismografia (PPG) é vastamente utilizado para o monitoramento de biossinais, como frequência cardíaca e respiratória, que são influenciados direta ou indiretamente pelo sistema cardiovascular. Este trabalho foca na análise de métodos para estimativa da frequência respiratória, tendo como referência o efeito da respiração na variação do sinal de PPG. O trabalho descreve, implementa, e analisa comparativamente seis métodos para estimar a frequência respiratória. Esses métodos têm como fundamento a captura da frequência respiratória empregando Transformada Rápida de Fourier, Decomposição de Modo Empírico, bem como a extração de características fisiológicas induzidas pela respiração no sinal de PPG, analisando a respiração modulada em amplitude, frequência e variações de intensidade. As eficácias dos métodos foram calculadas empregando sinais de PPG disponíveis em bancos de dados sintéticos, construídos por equações matemáticas, e reais, coletados de pacientes durante o atendimento hospitalar. A análise realizada permite compreender e mitigar desafios subjacentes ao processo de estimar a frequência respiratória por PPG, bem como, avaliar o melhor método a ser empregado para um cenário de monitoramento por dispositivos vestíveis.

Palavras-chave: Saúde, fotopletismografia, estimativa de frequência respiratória, dispositivo vestível.

Analysis of Methods for Inferring the Respiration Rate Using the Photoplethysmography Signal

ABSTRACT

Academia and industry have dedicated significant effort to the research and development of smart wearable devices applied to health monitoring. These efforts are primarily influenced by rising healthcare costs and are supported by nanotechnology advances. Regarding the wearable device scenario, the photoplethysmography (PPG) sensor is widely used for monitoring biosignals, such as heart and breathing rates, which are directly or indirectly influenced by the cardiovascular system. This work focuses on analyzing methods for estimating the respiratory rate, considering the effect of breathing on the PPG signal variation. We describe, implement, and examine six methods for estimating respiratory rate. These methods are based on capturing the breathing rate using Fast Fourier Transform, Empirical Mode Decomposition, as well as extracting physiological characteristics induced by breathing in the PPG signal, analyzing the modulated breathing in amplitude, frequency, and intensity variations. The efficacies of the methods were calculated using PPG signals available in synthetic databases, constructed by mathematical equations, and real ones collected from patient monitoring during hospital care. The analysis allows us to understand and mitigate the challenges underlying the process of estimating respiratory rate by PPG and evaluate the best method for a wearable device monitoring scenario.

Keywords: Health, photoplethysmography, respiratory rate estimation, wearable device.

LISTA DE ABREVIATURAS

AC	Alternating Current
AM	Amplitude Modulation
API	Application Program Interface
APS-PPG	Área do Pulso do Sinal PPG
ASR	Arritmia Sinusal Respiratória
AWS	Amazon Web Services
BIDMC	Beth Israel Deaconess Medical Center
BLE	Bluetooth Low Energy
bpm	batimentos por minuto
BR/EDR	Bluetooth Basic Rate/Enhanced Data Rate
BW	Baseline Wander
CEEMD	Complimentary Ensemble Empirical Mode Decomposition
CEEMDAN	Complete Ensemble Empirical Mode Decomposition with Adaptive Noise
DC	Direct Current
DWT	Discrete Wavelet Transform
ECG	EletroCardioGramma
EEMD	Ensemble Empirical Mode Decomposition
EMD	Empirical Mode Decomposition
FFT	Fast Fourier Transform
FIR	Finite Impulse Response
FM	Frequency Modulation
FR	Frequência Respiratória
ICEEMDAN	Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise
IMF	Intrinsic Mode Function
IQR	Índice de Qualidade Respiratória
IQS	Índice de Qualidade de Sinal
ISM	Industrial, Scientific and Medical
LED	Light-Emitting Diode
mAh	miliampere-hora
PPG	PhotoPlethysmoGraphy

RIAV	Respiratory-Induced Amplitude Variation
RIFV	Respiratory-Induced Frequency Variation
RIIV	Respiratory-Induced Intensity Variation
rpm	respirações por minuto
SFFDP	Smart Fusion of Frequency Domain Peak
SpO ₂	Saturação de oxigênio
VFC	Variabilidade da Frequência Cardíaca
Wi-Fi	Wireless Fidelity

LISTA DE TABELAS

Tabela 1.	Sumário com as principais características dos trabalhos relacionados.....	50
Tabela 2.	Variação do erro de estimativa de frequência respiratória com o tamanho da janela de observação. Os resultados foram obtidos com o método FFT e um sinal de PPG modulado em RIIV.	62
Tabela 3.	Estimativa de frequência respiratória obtida com o Método FFT, considerando modulações RIIV, RIAV e RIAF em sinais de PPG.....	64
Tabela 4.	Estimativas da frequência respiratória calculadas pelos Métodos RIIV, RIAV e RIFV, considerando sinais de PPG modelados em linha de base, amplitude e frequência.	65
Tabela 5.	Estimativa da frequência respiratória obtida com o método EMD; sinais de PPGs modulados em linha de base, amplitude e frequência.....	67
Tabela 6.	Método EMD aplicado em uma janela de observação de 60 s, para estimativas de frequências respiratórias considerando 20 pessoas presentes no banco de dados BIDMC.	78
Tabela 7.	Trecho do arquivo do banco de dados RRest-syn, ilustrando os sinais de PPG e ECG, bem como a taxa de amostragem.....	87
Tabela 8.	Exemplificação do formato de um arquivo “##_signal.csv” do banco de dados CapnoBase, contendo os sinais de CO ₂ , PPG e ECG.	89
Tabela 9.	Trecho do dataset BDMIC, referente ao arquivo “bidmc_##_Signals.csv”.	91

LISTA DE FIGURAS

Figura 1.	Proposta inicial do sistema de monitoramento de saúde LifeSenior (Fonte: [4]).....	19
Figura 2.	Versão comercial do sistema de monitoramento de saúde LifeSenior (Fonte: [7]).....	19
Figura 3.	Dispositivo vestível do projeto LifeSenior (Fonte: Adaptado [4]).	20
Figura 4.	Interfaces do aplicativo LifeSenior Mobile (Fonte: [8]).....	23
Figura 5.	Interfaces do aplicativo LifeSenior Cloud (Fonte: [8]).....	23
Figura 6.	Descrição da tecnologia subjacente à fotopleletismografia (Fonte: adaptada de [19]).....	26
Figura 7.	Posicionamento do emissor e detector óptico para medição de PPG nos modos de transmissão e refletância (Fonte: adaptada de [19]).	26
Figura 8.	Uma onda de pulso típica do sinal de PPG (Fonte:[20]).	27
Figura 9.	Classes de forma de onda de pulso, mostrando variações do sinal de PPG, conforme idade do indivíduo avaliado (Fonte:[20]).....	27
Figura 10.	Induções da respiração no sensor de PPG, considerando as modulações de linha de base (RIIV), amplitude (RIAV) e frequência (RIFV) (Fonte: baseado em [23]).....	30
Figura 11.	Indução da respiração no sensor de PPG considerando a modulação em área do pulso do sinal (Fonte: baseado em [32]).	30
Figura 12.	Etapas dos algoritmos para estimar a FR a partir dos sinais de ECG ou PPG (Fonte: [2]).....	31
Figura 13.	Etapas do algoritmo proposto por Khreis et al. [36] (Fonte: [36]).	43
Figura 14.	Extração de sinais respiratórios tendo como base o sinal PPG com modulações RIIV e RIAV (Fonte: [39]).....	44
Figura 15.	Estimativas de frequência respiratória nos domínios tempo e frequência (Fonte: [39]).	45

Figura 16.	Aplicação da FFT em um sinal de PPG com modulação do tipo RIAV (Fonte: Autor).	48
Figura 17.	(a) Sinal de PPG e (b) correspondente aplicação do método FFT com identificação das frequências relevantes (Fonte: Autor).	53
Figura 18.	Procedimento iterativo para obtenção da frequência respiratória através do método EMD (Fonte: Autor).	54
Figura 19.	Métodos RIIV, RIAV e RIFV para a exploração da FR (Fonte: Autor).	55
Figura 20.	Sinais respiratórios dispostos no tempo extraídos pelos métodos RIIV (6 rpm), RIAV (12 rpm) e RIFV (24 rpm) (Fonte: Autor).	56
Figura 21.	Etapas das análises de eficácia dos métodos de estimativa de frequência respiratória realizadas sobre os dados contidos no Synthetic Dataset (Fonte: Autor).	60
Figura 22.	Sinais de PPG presentes no banco de dados sintéticos, com modulação em intensidade, amplitude e frequência (Fonte: Autor).	61
Figura 23.	Avaliação do erro absoluto ocasionado pelas modulações em linha de base, amplitude e frequência nos métodos FFT, RIIV, RIAV, RIFV e EMD. Intervalo de FR em (a) [4, 60] e (b) [4, 40] (Fonte: Autor).	68
Figura 24.	Avaliação do erro relativo ocasionado pelas modulações em linha de base, amplitude e frequência nos métodos FFT, RIIV, RIAV, RIFV e EMD. Intervalo de FR em [4, 60] (Fonte: Autor).	69
Figura 25.	Avaliação do erro absoluto dos métodos FFT, RIIV, RIAV, RIFV e EMD frente devido às modulações de linha de base, amplitude e frequência. Intervalo de FR em [4, 60] (Fonte: Autor).	69
Figura 26.	Etapas da análise realizada no banco de dados reais (Fonte: Autor).	70
Figura 27.	Exemplo de dados de um paciente do banco de dados CapnoBase contendo (a) sinal de PPG, (b) sinal respiratório	

	de referência (CO ₂), e (c) valores de referência da frequência respiratória. A amostragem está cortada em 120 s para facilitar a visualização (Fonte: Autor).	72
Figura 28.	Exemplo de dados de um paciente do banco de dados CapnoBase contendo um forte ruído que se sobrepõe aos sinais de (a) PPG e (b) CO ₂ , bem como aos (c) valores de referência da FR (Fonte: Autor).....	73
Figura 29.	Erro percentual médio obtido para os métodos FFT, RIIV, RIAV, RIFV, EMD e Fusão, utilizando dados do CapnoBase e janelas de observação deslizantes de 30 s e 60 s (Fonte: Autor).	74
Figura 30.	Erro percentual médio computado com os métodos FFT, RIIV, RIAV, RIFV, EMD e Fusão, tendo como entrada dados do BIDMC e janelas de observação deslizantes de 30 s e 60 s (Fonte: Autor).	75
Figura 31.	Erro percentual médio computado com todos os métodos, tendo como entrada ambos os bancos de dados e janelas de observação deslizantes de 30 s e 60 s (Fonte: Autor).	76
Figura 32.	Análise global da eficácia de todos os métodos para ambos bancos de dados e janelas de observação (Fonte: Autor).	76
Figura 33.	Exemplificação do efeito de um artefato na captura da estimativa de FR de uma amostra do banco de dados BIDMC; (a) mostra uma janela de observação de 60 s salientando o artefato e uma região sem ruído; (b) FFT aplicada à janela de (a); (c) zoom da região sem ruído; (d) FFT aplicada na região sem ruído (Fonte: Autor).	77
Figura 34.	Sinais de PPG e ECG sem modulação e modulados com BW, AM e FM (Fonte: [54]).	86
Figura 35.	Ilustração das formas de onda dos sinais de CO ₂ , ECG e PPG contidos no banco de dados CapnoBase (Fonte: [55]).	88
Figura 36.	Exemplos dos sinais de pneumografia de impedância, ECG e PPG disponibilizados no BIDMC, que foram amostrados simultaneamente (Fonte: [56]).....	90

SUMÁRIO

1.	Introdução	16
1.1	Objetivo Geral.....	17
1.2	Objetivos Específicos.....	17
1.3	Motivação	17
2.	Arquitetura do Sistema LifeSenior	19
2.1	Dispositivo Vestível.....	20
2.2	Bluetooth Low Energy (BLE).....	22
2.3	LifeSenior Mobile	22
2.4	LifeSenior Cloud	23
2.5	Aplicabilidade da Pesquisa Proposta neste Trabalho no LifeSenior.....	24
3.	Fundamentação Teórica.....	25
3.1	Fundamentos de Fotopletismografia.....	25
3.2	Análise do Sinal de Fotopletismografia	26
3.3	Fatores que Afetam o Sinal de Fotopletismografia.....	27
3.3.1	Local de Medição.....	28
3.3.2	Força de Contato entre Sensor e Local de Medição	28
3.3.3	Artefatos de Movimento	28
3.4	Relação da Respiração com a Fotopletismografia	29
3.5	Etapas de Algoritmos que Estima a Frequência Respiratória.....	31
3.5.1	Extração de Sinais Respiratórios.....	31
3.5.2	Fusão de Sinais Respiratórios.....	32
3.5.3	Estimativa da FR.....	33
3.5.4	Fusão das Estimativas de FR.....	34
3.5.5	Avaliação da Qualidade da Estimativa de FR	34
4.	Trabalhos Relacionados	36
4.1	Toward a Robust Estimation of Respiratory Rate from Pulse Oximeters	36
4.2	Selection of Empirical Mode Decomposition Techniques for Extracting Breathing Rate from PPG	37
4.3	Derivation of Respiration Rate from Ambulatory ECG and PPG using Ensemble Empirical Mode Decomposition: Comparison and Fusion.....	37

4.4	Ensemble Empirical Mode Decomposition with Principal Component Analysis: A Novel Approach for Extracting Respiratory Rate and Heart Rate from Photoplethysmographic Signal	38
4.5	Estimation of Breathing Rate from the Photoplethysmography Using Respiratory Quality Indexes	39
4.6	A Robust Fusion Model for Estimating Respiratory Rate from Photoplethysmography and Electrocardiography	39
4.7	Respiratory Rate Estimation from the Photoplethysmogram Combining Multiple Respiratory-induced Variations Based on SQI	39
4.8	Reliable Respiratory Rate Extraction using PPG.....	40
4.9	PPG Derived Respiratory Rate Estimation in Daily living Conditions.....	41
4.10	Efficient Respiratory Rate Extraction on a Smartwatch	41
4.11	Breathing Rate Estimation using Kalman Smoother with Electrocardiogram and Photoplethysmogram.....	42
4.12	Breathing Rate Estimation Methods from PPG Signals, on CapnoBase Database	43
4.13	Respiratory Rate Estimation using the Photoplethysmogram: Towards the Implementation in Wearables	44
4.14	Respiratory Rate Estimations using Three Respiratory-Induced Variations on Photoplethysmogram	45
4.15	Continuous Measurement of Respiratory Rate via Single-Wavelength Reflective Photoplethysmography	46
4.16	PPG-Based Respiratory Rate Monitoring Using Hybrid Vote-Aggregate Fusion Technique	46
4.17	Design and validation of a respiratory rate estimation algorithm based on photoplethysmography (PPG) signal.....	46
4.18	A New Framework to Estimate Breathing Rate from Electrocardiogram, Photoplethysmogram, and Blood Pressure Signals.....	47
4.19	Modulation Model of the Photoplethysmography Signal for Vital Sign Extraction.....	47
4.20	Discussões	49
5.	Métodos para Cálculo da Frequência Respiratória.....	52
5.1	Empregando a Transformada Rápida de Fourier – Método FFT	52
5.2	Emprego do Modo Empírico para Decompor o Sinal de PPG – Método EMD	53

5.3	Exploração das Variações de Frequência, Amplitude e Intensidade Induzidas pela Respiração - Métodos RIIV, RIAV e RIFV	55
5.4	Fusão de estimativas de FR - Método de Fusão	57
6.	Resultados Experimentais	59
6.1	Descrição Sucinta dos Bancos de Dados	59
6.2	Resultados Experimentais Obtidos com Dados Sintéticos	60
6.2.1	Configuração dos Experimentos com Dados Sintéticos.....	60
6.2.2	Resultados Experimentais Obtidos com Dados Sintéticos.....	60
6.2.3	Integração dos Dados e Conclusões Parciais	67
6.3	Resultados Experimentais Obtidos com Dados Reais	70
6.3.1	Configuração dos Experimentos com Dados Reais	70
6.3.2	Equalização dos Bancos de Dados CapnoBase e BIDMC	72
6.3.3	Resultados Experimentais Obtidos com Dados Sintéticos.....	73
6.3.4	Conclusões Parciais	77
7.	Conclusões e Trabalhos Futuros	79
8.	Referências Bibliográficas	81
9.	Apêndice A – RRest-syn Dataset	86
10.	Apêndice B - CapnoBase IEEE TBME Respiratory Rate Benchmark	88
11.	Apêndice C - BIDMC PPG and Respiration Dataset.....	90
12.	Apêndice D – Código com Métodos para Calcular a Frequência Respiratória Proveniente do Sinal de PPG.....	92

1. INTRODUÇÃO

O envelhecimento da população, a disponibilidade de conectividade de banda larga móvel e o desenvolvimento de tecnologias sofisticadas impulsionaram a adoção de métodos personalizados, digitais ou remotos do monitoramento de pacientes. Este processo foi ainda mais acelerado com o surgimento da pandemia de coronavírus que aumentou a pressão sobre as instalações hospitalares limitadas, requerendo que os provedores de serviços médicos acelerassem a pesquisa e implementação de novas tecnologias para monitoramento da saúde fora do hospital [1], principalmente no próprio lar do paciente.

Inovações em sensores permitem que sinais vitais sejam medidos com precisão de grau clínico em ambiente residencial. Dispositivos vestíveis estão mais acessíveis, possibilitando o monitoramento domiciliar de sinais filológicos, como por exemplo, temperatura corporal, frequência cardíaca, Frequência Respiratória (FR), pressão arterial e saturação do oxigênio.

A FR é um valioso marcador diagnóstico e prognóstico de saúde. Na saúde hospitalar, é um marcador altamente sensível de deterioração aguda. Por exemplo, uma frequência respiratória elevada é um preditor de parada cardíaca e mortalidade intra-hospitalar, e pode indicar disfunção respiratória. Consequentemente, a FR é medida entre quatro e seis horas em pacientes hospitalizados com doença aguda. A frequência respiratória também é usada na triagem da emergência. Na atenção primária, a FR é utilizada na identificação de pneumonia e como marcador de embolia pulmonar. No entanto, a FR geralmente é medida pela contagem manual dos movimentos da parede torácica (fora da terapia intensiva), sendo um processo demorado, impreciso e mal realizado [2].

O sensor óptico de fotoplethysmografia, em inglês *photoplethysmograph* (PPG), é comumente encontrado entre os dispositivos de monitoramento de sinais fisiológicos vestíveis, como oxímetros de pulso, devido à sua simplicidade, baixo custo e por ser uma técnica não invasiva [3]. O sensor de PPG detecta o conteúdo sanguíneo e alterações de volume no sistema microvascular, estando diretamente relacionado ao sistema cardiovascular. Devido aos sistemas cardiovascular e respiratório estarem correlacionados, tanto a academia, quanto a indústria, têm realizado esforços no âmbito de desenvolver algoritmos capazes

de inferir a taxa de respiração proveniente do sinal de PPG.

1.1 Objetivo Geral

O objetivo central deste trabalho é desenvolver, implementar e validar métodos de inferência da taxa de respiração a partir de sinais de PPG. Adicionalmente, o sensor de PPG faz parte do projeto LifeSenior [4], que foca na implementação de um sistema comercial para o monitoramento de pessoas de terceira idade, requerendo a calibração do dispositivo conforme o público-alvo.

1.2 Objetivos Específicos

Para alcançar o objetivo geral deste trabalho, planejamos realizar os seguintes objetivos específicos:

- Analisar trabalhos descritos na literatura e identificar soluções eficazes na inferência da taxa respiratória;
- Explorar métodos de medição utilizando o sensor de PPG, tais como os baseados na decomposição de modo empírico e variações induzidas pela respiração;
- Validar os métodos explorados com bancos de dados de sensoriamento que empregam PPG – utilizamos os bancos de dados CapnoBase [5] e Beth Israel Deaconess Medical Center (BIDMC) [6];
- Comparar o desempenho dos métodos implementados e descrever as vantagens e desvantagens de cada método;
- Obter erro absoluto menor ou igual a 10% da faixa de FR compreendendo os dois bancos de dados.

1.3 Motivação

O grupo LifeSenior¹, na qual este autor está envolvido, está desenvolvendo um sistema para assistência médica remota para idosos. Este sistema emprega um dispositivo vestível, do inglês *wearable*, equipado com

¹ LifeSenior é um projeto em cooperação academia-indústria para o monitoramento remoto de idosos. O Capítulo 2 apresenta um detalhamento deste projeto.

sensores que coletam informações fisiológicas do seu portador. Estas informações devem ser trabalhadas para permitir a inferência de sinais vitais.

O *wearable* inclui um sensor de PPG que permite coletar informações fisiológicas diretamente relacionados ao sistema cardiovascular. Por sua vez, a análise dos sinais de PPG permite explorar informações direta ou indiretamente relacionadas ao sistema cardiovascular. Esta abordagem permite extrair mais informações, sem a necessidade de acrescentar novos sensores ao dispositivo, economizando espaço físico, processamento e reduzindo custos financeiros. Entre as informações que podem ser extraídas do sensor de PPG estão o nível de oxigenação do sangue, e as frequências tanto cardíaca, quanto respiratória – esta última informação é o foco de pesquisa deste trabalho.

2. ARQUITETURA DO SISTEMA LIFESENIOR

O sistema LifeSenior teve origem no projeto intitulado “LifeSenior – Monitor contínuo de situações emergenciais”, que foi submetido à “Chamada Pública MCTI/SECIS/FINEP/FNDCT - Viver Sem Limite - 01/2015”, sendo esta submissão fruto de uma cooperação entre a PUCRS e a empresa Toth Lifecare. A Figura 1 descreve abstratamente a primeira arquitetura do sistema de monitoramento de saúde denominado LifeSenior; esta arquitetura inclui um dispositivo vestível (*wearable*), rede e *backend* Sigfox, sistema de nuvem e aplicativo idealizado.

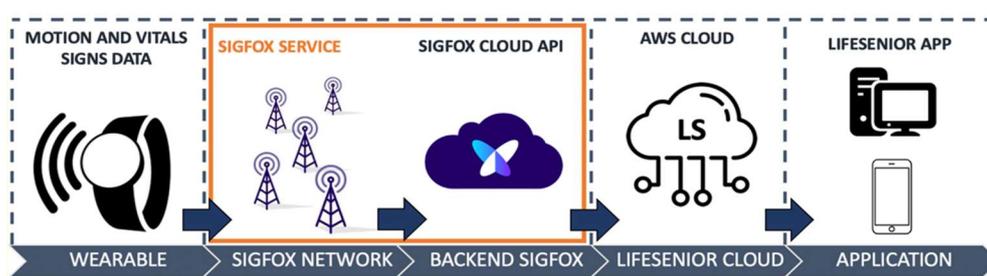


Figura 1. Proposta inicial do sistema de monitoramento de saúde LifeSenior (Fonte: [4]).

Durante o desenvolvimento do projeto, o sistema de comunicação entre o *wearable* e a nuvem evoluiu de SigFox para a tecnologia Bluetooth Low Energy (BLE), que permite uma maior vazão de dados, atendendo a mudanças de requisitos do projeto LifeSenior. Conseqüentemente, a arquitetura descrita na Figura 1 evoluiu para a arquitetura ilustrada na Figura 2, sendo inserido um sistema concentrador conectado (potencialmente um smartphone) via BLE com o dispositivo vestível. Por sua vez, este concentrador se conecta com a nuvem através de tecnologias padrão de telefonia ou rede Wi-Fi (Wireless Fidelity).

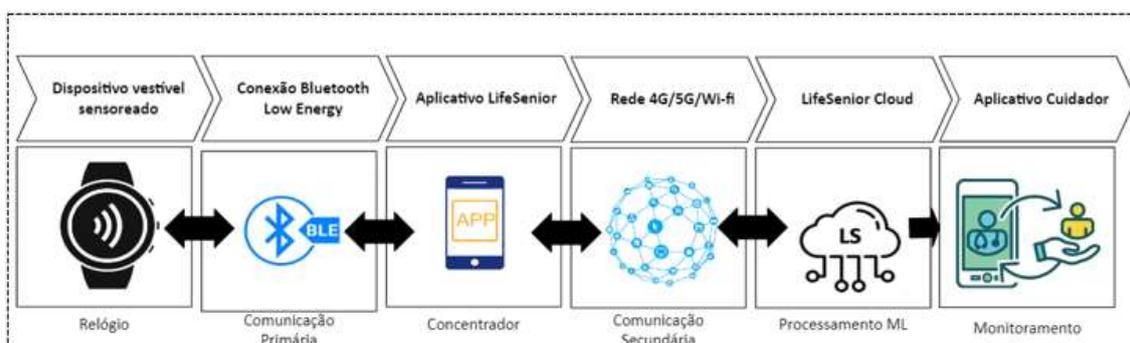


Figura 2. Versão comercial do sistema de monitoramento de saúde LifeSenior (Fonte: [7]).

2.1 Dispositivo Vestível

O dispositivo vestível (*wearable*), ilustrado na Figura 2 e na Figura 3, foi projetado para ser semelhante a um relógio tradicional; o objetivo é alcançar o máximo de informações de monitoramento físico em um equipamento com aspecto e formato que seja a aceito pelo público-alvo.



Figura 3. Dispositivo vestível do projeto LifeSenior (Fonte: Adaptado [4]).

No entanto, este *wearable* é muito mais complexo que simples relógio. Dentro do *wearable*, circuitos dedicados adquirem sinais vitais por meio de diversos sensores, como o de PPG; adicionalmente, o *wearable* contém um sistema de movimentação com foco em aprender a atividade biológica do usuário e detectar situações de risco, tais como uma queda.

O sensor de PPG utiliza uma técnica óptica para detectar alterações do volume sanguíneo no leito microvascular do tecido [10]. O LifeSenior usa o sensor ADPD1080 PPG da Analog Devices [11], que processa periodicamente dados coletados do usuário monitorado. Com base no sinal de PPG, o *wearable* LifeSenior pode extrair a frequência cardíaca independente do movimento do usuário [12], permitindo ao aplicativo traçar uma tendência de variância, essencial para controlar a Variabilidade da Frequência Cardíaca (VFC), sendo usada na estimativa de modulações autonômicas cardíacas [13].

Processando dados do sensor óptico, o dispositivo vestível também estima a saturação de oxigênio (SpO_2) do usuário [14], filtrando os dados de

ruído para fornecer informações de SpO₂ limpas e confiáveis. Uma diminuição no valor de SpO₂ pode indicar uma redução na circulação de oxigênio, o que pode antever problemas respiratórios.

É essencial monitorar regularmente a pressão arterial para prevenir casos de hipertensão e, como resultado, acidentes vasculares cerebrais ou insuficiência cardíaca. O *wearable* LifeSenior fornece uma maneira de monitorar continuamente a pressão arterial por meio de um algoritmo de inteligência artificial que processa dados ópticos obtidos da PPG, estimando valores sistólicos e diastólicos [15].

Por fim, além da frequência cardíaca, pressão arterial e SpO₂, o *wearable* também dispõe de um sistema para estimar a FR do usuário [16], parâmetro fisiológico crucial usado em uma variedade de configurações clínicas do paciente; sendo o cálculo da FR o foco deste trabalho.

Todas as informações fisiológicas obtidas pelo *wearable* LifeSenior são coletadas para monitoramento contínuo, verificando variações anormais ou mudanças rápidas que possam indicar uma situação de risco. Os sinais vitais coletados ajudam o LifeSenior a verificar o estado de saúde do paciente que está sendo monitorado, avisando a família ou uma central de monitoramento de saúde em caso de problemas.

Informações de movimento de idosos são coletadas continuamente usando a solução iNEMO da STMicroelectronics, que inclui acelerômetro de 9 eixos, giroscópio 3D e magnetômetro 3D encapsulados em um único pacote, denominado LSM9DS1 [17].

Além das características técnicas do *wearable* para detectar situações de risco, é fundamental levar em consideração sua usabilidade. Em particular, o tempo entre as cargas da bateria, que é um problema devido às dificuldades que os idosos têm na usabilidade de componentes eletrônicos. O *wearable*, LifeSenior tem como meta um tempo estimado entre cargas de cerca de 30 dias. Isto implica em utilizar placa de todos os componentes com baixo consumo de energia, display de baixa energia e bateria com alta capacidade (na versão atual do *wearable*, um lítio recarregável de 100 mAh -bateria de íons) [4].

O *wearable* dispõe de um display de e-paper para mostrar as informações sensorizadas. Esta tecnologia tem a vantagem de consumir energia apenas na atualização do display, o que significa que a informação estática permanece na

tela sem consumir energia. A versão atual do *wearable* utiliza o e-paper ET011TT3 do fabricante E-INK. Na maioria das partes, este display é composto de materiais plásticos e associado à possibilidade de “desligar” o display sem prejudicar a visão e atender a alguns requisitos de comunicação de radiofrequência.

2.2 Bluetooth Low Energy (BLE)

O Bluetooth de Baixa Energia, do inglês Bluetooth Low Energy (BLE), foi otimizado para aumentar a taxa de transferência de dados e ter um consumo de energia ultrabaixo. Sendo projetada para operar na banda Industrial, Científica e Médica, em inglês Industrial, Scientific and Medical (ISM), inserida no intervalo de frequência de 2,4–2,5 GHz, o mesmo intervalo de frequência que o Bluetooth Basic Rate/Enhanced Data Rate (BR/EDR) e o Wi-Fi. O BLE tem um consumo de corrente, em média, entre 1,5 e 2 vezes menor que as tecnologias concorrentes sem fio [7].

A substituição do Sigfox para a tecnologia BLE ocorreu por esta tecnologia atender ao requisito de baixo consumo de energia, suportar grande vazão de dados e ser facilmente encontrada na maioria dos *smartwatches* e *smartphones* atuais.

2.3 LifeSenior Mobile

A Figura 4 ilustra algumas telas do aplicativo LifeSenior Mobile que pode ser iniciado com login de “Paciente” e “Cuidador”. A parte referente a “Paciente” contém as operações adequadas para o idoso que está sendo monitorado e deve ser instalada no dispositivo pessoal do usuário ficando próximo do *wearable*. A parte referente a “Cuidador” contém as informações fisiológicas do idoso, recebendo diversas notificações, tal como quando o idoso apresentar uma queda. Parte das informações, como frequência respiratória, cardíaca e movimentação podem estar presentes tanto na operação do tipo “Paciente”, quanto “Cuidador”.

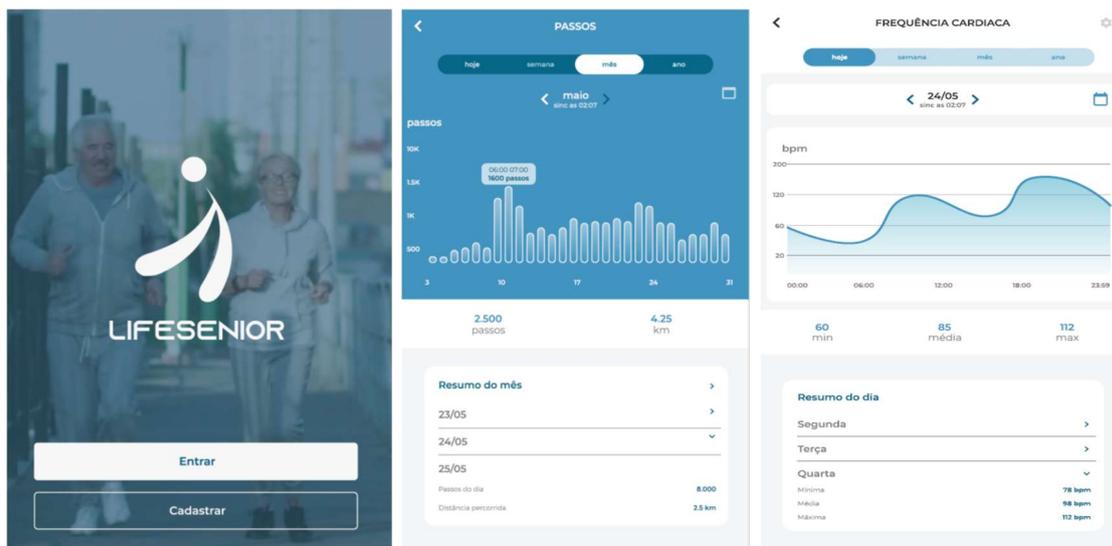


Figura 4. Interfaces do aplicativo LifeSenior Mobile (Fonte: [8]).

O dispositivo mobile faz o papel de concentrador comunicando com o dispositivo vestível através da tecnologia BLE. Adicionalmente, o LifeSenior Mobile tem uma comunicação com o LifeSenior Cloud, de forma que remotamente seja possível interagir com o dispositivo vestível.

2.4 LifeSenior Cloud

A Figura 5 ilustra uma tela do LifeSenior Cloud com o monitoramento parcial, localização e um aviso de detecção de queda de um paciente.



Figura 5. Interfaces do aplicativo LifeSenior Cloud (Fonte: [8]).

A versão atual do LifeSenior Cloud gerencia as mensagens recebidas de todos os dispositivos vestíveis com um serviço em nuvem fornecido pela Amazon Web Services (AWS) [9]. Qualquer nova mensagem recebida na rede é identificada por um número de dispositivo exclusivo e se correlaciona com a lista de parceiros, redirecionando a mesma para a nuvem do cliente. O LifeSenior Cloud armazena todas as mensagens recebidas de cada dispositivo, notificando o aplicativo sempre que necessário.

2.5 Aplicabilidade da Pesquisa Proposta neste Trabalho no LifeSenior

A pesquisa aqui proposta está diretamente relacionada ao firmware que será implementado no dispositivo vestível do projeto LifeSenior, uma vez que este dispositivo implementa um sensor de PPG para coletar sinais vitais do paciente. Especificamente, este trabalho foca em estimar a Frequência Respiratória (FR) a partir de dados coletados com o sensor de PPG. A estimativa de FR é explorada com diversos métodos descritos na literatura, requerendo uma análise da eficácia e eficiência de forma a verificar alguns custos de implementação, mas principalmente, a qualidade das estimativas providas pelo dispositivo. O objetivo final é selecionar e validar um método com banco de dados que compreendem sinal de PPG e respiratório de referência para futuramente ser embarcado no dispositivo vestível.

3. FUNDAMENTAÇÃO TEÓRICA

Este capítulo aborda conceitos teóricos fundamentais para a compreensão do trabalho, compreendendo a técnica associada à PPG, os componentes do sinal, bem como a correlação do sinal de PPG com a obtenção da frequência respiratória.

3.1 Fundamentos de Fotopletismografia

Fotopletismografia, em inglês PhotoPlethysmoGraphy (PPG), é uma técnica de biomonitoramento óptico de baixo custo e não invasiva, usada para medir as alterações do volume de sangue que ocorrem no leito do tecido microvascular sob a pele; estas alterações ocorrem devido à natureza pulsátil do sistema circulatório [18].

Por ser uma técnica óptica, PPG requer uma fonte de luz e um fotodetector. A luz que atravessa o tecido biológico pode ser absorvida por diferentes substâncias, incluindo pigmentos na pele, ossos e sangue arterial e venoso. A maioria das alterações no fluxo sanguíneo ocorre principalmente nas artérias e arteríolas; e.g., as artérias contêm mais volume de sangue durante a fase sistólica do ciclo cardíaco do que durante a fase diastólica. Os sensores de PPG detectam opticamente mudanças no volume do fluxo sanguíneo (ou seja, mudanças na intensidade da luz detectada) no leito microvascular do tecido, por meio de reflexão ou transmissão através do tecido [19].

A Figura 6 mostra um exemplo de uma forma de onda de PPG, consistindo em componentes de corrente contínua, em inglês Direct Current (DC), e corrente alternada, em inglês Alternating Current (AC). O componente DC corresponde ao sinal óptico transmitido ou refletido, detectado no tecido; este componente depende da estrutura do tecido e do volume médio de sangue tanto arterial quanto venoso. O componente AC mostra mudanças no volume de sangue que ocorrem entre as fases sistólica e diastólica do ciclo cardíaco; a frequência fundamental do componente AC depende da frequência cardíaca e é sobreposta ao componente DC [19].

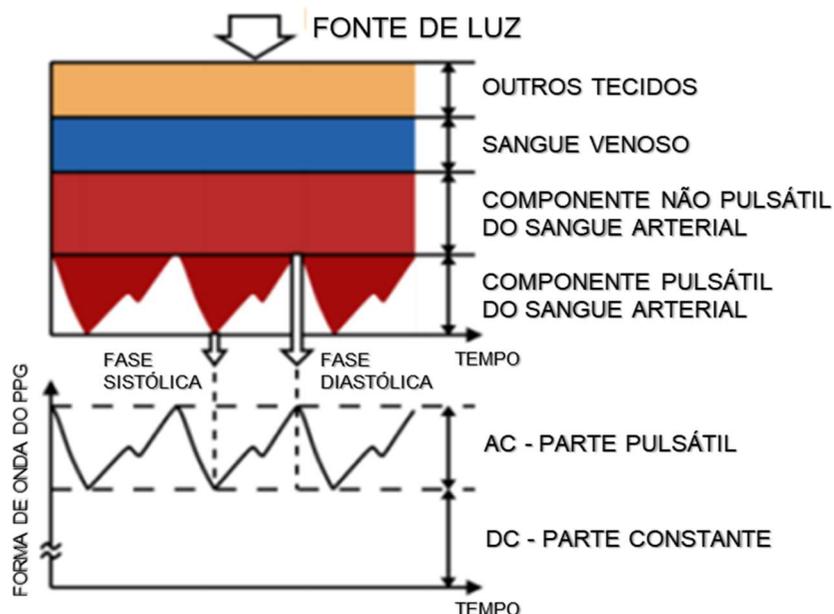


Figura 6. Descrição da tecnologia subjacente à fotopletismografia (Fonte: adaptada de [19]).

A Figura 7 mostra os modos básicos de transmissão e refletância empregados para extrair informação do sinal de PPG. Na medição por transmissão, o diodo emissor ilumina o corpo e o detector absorve a luz do outro lado do emissor; este tipo de medição é geralmente utilizado no dedo ou ouvido. A medição por refletância utiliza o princípio da reflexão da luz do corpo; sendo comumente aplicada na testa ou no pulso [19].

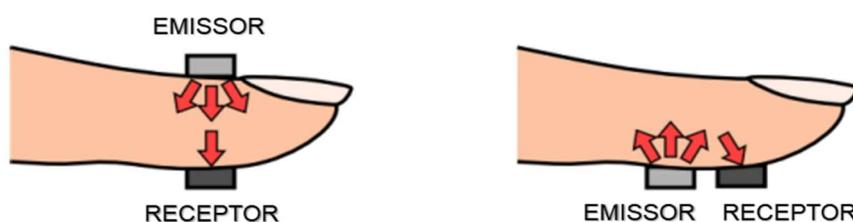


Figura 7. Posicionamento do emissor e detector óptico para medição de PPG nos modos de transmissão e refletância (Fonte: adaptada de [19]).

3.2 Análise do Sinal de Fotopletismografia

O sinal de PPG exibe um padrão aproximadamente periódico, consistindo em uma onda de pulso arterial para cada batimento cardíaco. A onda de pulso se assemelha a onda de pressão arterial, embora existam diferenças importantes no contorno da forma de onda. A Figura 8 mostra que cada onda de pulso de PPG consiste em duas fases - anacrótica (Anacrotic Phase) e

catacrótica (Catacrotic Phase), correspondendo a subida e descida do sinal, respectivamente.

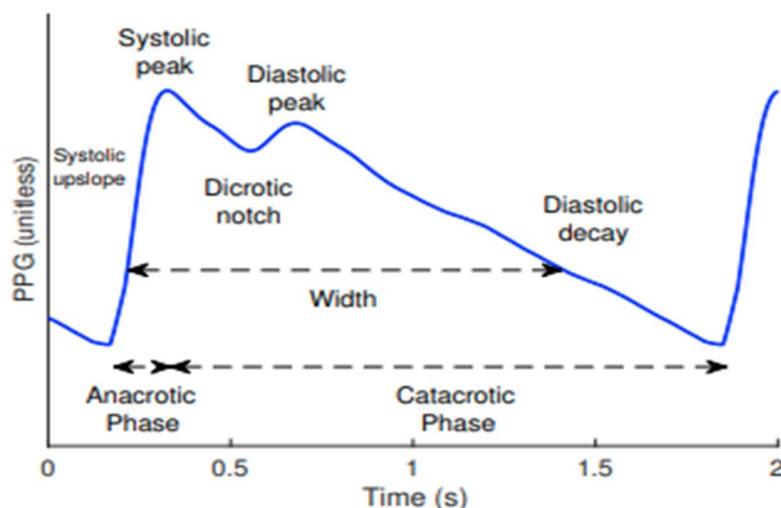


Figura 8. Uma onda de pulso típica do sinal de PPG (Fonte:[20]).

A morfologia da onda de pulso de PPG é influenciada pelo (i) coração que leva em consideração características da ejeção cardíaca, incluindo frequência cardíaca, ritmo cardíaco e volume sistólico; (ii) circulação, incluindo propriedades cardiovasculares como rigidez arterial e pressão sanguínea; (iii) processos fisiológicos adicionais, incluindo respiração e sistema nervoso autônomo, que podem ser afetados pelo estresse; e (iv) doenças [20]. O envelhecimento saudável apresenta mudanças na forma de onda do pulso de PPG, onde sujeitos jovens geralmente exibem um pico diastólico (Class 1) que diminui com a idade (classes mais altas), conforme Figura 9.

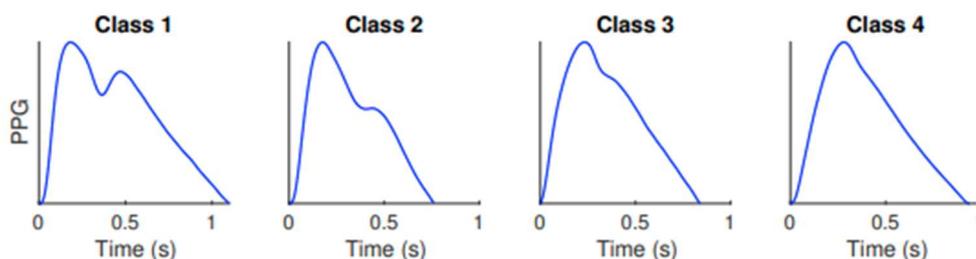


Figura 9. Classes de forma de onda de pulso, mostrando variações do sinal de PPG, conforme idade do indivíduo avaliado (Fonte:[20]).

3.3 Fatores que Afetam o Sinal de Fotopletismografia

A qualidade do sinal de PPG depende do comprimento de onda da luz, local de medição, i.e., local de fixação do sensor, força de contato, artefatos de

movimento, respiração do indivíduo que está sendo medido e temperatura ambiente [21]. Esses fatores geram vários tipos de ruídos aditivos (artefatos) que podem estar contidos nos sinais de PPG, afetando características do sinal e, por este motivo, são brevemente descritos nesta seção.

3.3.1 LOCAL DE MEDIÇÃO

A localização do LED (*Light-Emitting Diode*), que é a fonte de luz do PPG, e do fotodetector são um importante fator de projeto que afeta a qualidade do sinal de PPG e a robustez contra artefatos de movimento. Portanto, locais de medição adequados devem ser localizados para otimizar o desempenho do sensor. Os sensores de PPG clínicos comerciais geralmente usam dedos das mãos, lóbulo da orelha e testa [21], devido à alta amplitude do sinal que pode ser alcançada em comparação com outros locais, sendo que a localização do PPG no dedo não é adequada para detecção contínua, porque a maioria das atividades diárias envolve o uso das mãos [21].

O sensor de PPG do tipo relógio de pulso para medição de oximetria é desenvolvido e comercializado por diversas empresas. Embora seja fácil de usar, esse dispositivo geralmente não é comum em ambientes clínicos devido a problemas técnicos, que reduzem a qualidade das medidas [21].

3.3.2 FORÇA DE CONTATO ENTRE SENSOR E LOCAL DE MEDIÇÃO

A forma de onda do sinal de PPG é afetada pela força de contato entre o sensor e o local de medição, devido à rigidez arterial e reatividade vascular. Uma pressão moderada pode melhorar a qualidade do sinal de PPG, enquanto que uma pressão insuficiente resulta em contato inadequado e, conseqüentemente, baixa amplitude do sinal AC. No entanto, a obtenção do sinal de PPG sob condições de pressão excessiva pode levar a baixa amplitude do sinal AC e formas de onda distorcidas, causadas pela artéria ocluída [21].

3.3.3 ARTEFATOS DE MOVIMENTO

A flutuação na linha de base é um artefato de baixa frequência no PPG; esta flutuação surge da respiração, sistema nervoso simpático, temperatura ou

movimento do sujeito. Artefatos de movimento são causados devido a vibrações, movimentos do sujeito ou mau contato do sensor fotodetector com a pele. Estes artefatos provocam deslocamentos do sensor, resultando em medidas distorcidas do sinal de PPG captado [22]. Em muitos casos é difícil remover artefatos de movimento, já que a banda de frequência se sobrepõe à banda do sinal de PPG que está na faixa de 0,5 a 4 Hz; conseqüentemente, a sobreposição torna impraticável a separação das bandas de interferência e sinal por técnicas clássicas de processamento de sinal. Por isso, a remoção de artefatos de movimento tem sido o tema de diversas pesquisas [22].

3.4 Relação da Respiração com a Fotopletismografia

As variações da pressão intratorácica induzidas pela respiração são transmitidas às veias centrais, gerando uma variação na pressão arterial que pode ser detectada pelo espectro do sinal de PPG. A Figura 10 ilustra que a respiração pode induzir variações no sinal de PPG de três maneiras [23]:

- Variação da intensidade induzida pela respiração, em inglês *Respiratory-Induced Intensity Variation* (RIIV) - Alterações no retorno venoso, devido a mudanças na pressão intratorácica ao longo do ciclo respiratório, causam uma modulação da linha de base (i.e., a componente contínua - DC) do sinal de PPG. Durante a inspiração, diminuições na pressão intratorácica resultam em pequena diminuição na 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. Ou seja, RIIV é referente à **modulação da respiração na linha de base**;
- Variação da amplitude induzida pela respiração, em inglês *Respiratory-Induced Amplitude Variation* (RIAV) - Durante a inspiração, o volume sistólico do ventrículo esquerdo diminui devido às mudanças na pressão intratorácica, levando à diminuição da amplitude do pulso. O oposto acontece durante a expiração. Ou seja, RIAV é referente à **modulação da respiração em amplitude**;
- Variação de frequência cardíaca induzida pela respiração, em inglês *Respiratory-Induced Frequency Variation* (RIFV) - A frequência cardíaca

varia ao longo do ciclo respiratório, aumentando durante a inspiração e diminuindo durante a expiração. Esse fenômeno conhecido como Arritmia Sinusal Respiratória (ASR) se deve principalmente à regulação autônômica da frequência cardíaca durante a respiração. Ou seja, RIFV é referente à **modulação da respiração em frequência**.

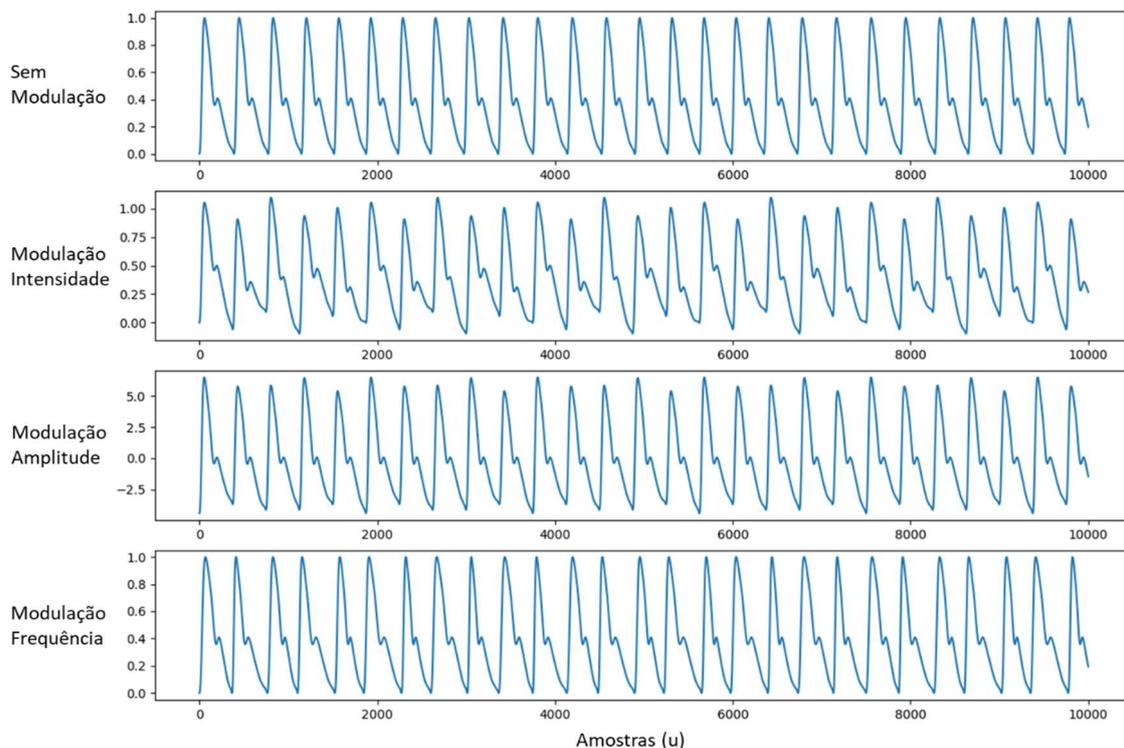


Figura 10. Induções da respiração no sensor de PPG, considerando as modulações de linha de base (RIIV), amplitude (RIAV) e frequência (RIFV) (Fonte: baseado em [23]).

Existem outras variações da pressão intratorácica induzidas pela respiração que geram variações no fluxo sanguíneo, podendo ser detectadas no sinal de PPG, tal como a variação da Área do Pulso do Sinal de PPG (APS-PPG), descrita no trabalho de Yang et al. [32] e ilustrada na Figura 11. Todavia, RIIV, RIAV e RIFV são as modulações mais comuns encontradas na literatura.

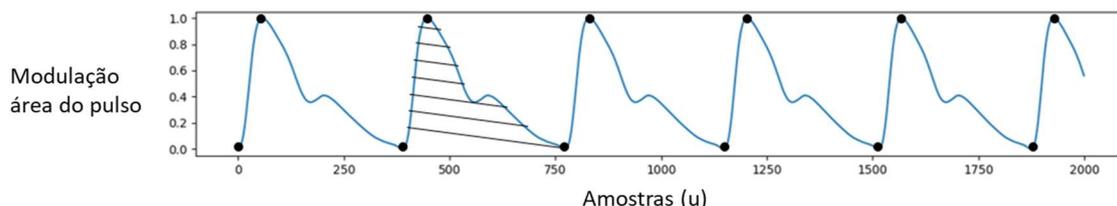


Figura 11. Indução da respiração no sensor de PPG considerando a modulação em área do pulso do sinal (Fonte: baseado em [32]).

3.5 Etapas de Algoritmos que Estima a Frequência Respiratória

Charlton et al. [2] apresentam uma revisão da literatura de algoritmos que obtêm a frequência respiratória a partir de sinais de EletroCardioGramma (ECG) ou PPG. Os autores identificaram 196 publicações descrevendo algoritmos aplicados para medir frequência respiratória, sendo a primeira de 1971 e apenas mais nove foram publicadas até 1998. De 1999 até 2017, a taxa de publicação aumentou de forma praticamente constante para 20 publicações por ano mostrando o crescente interesse da comunidade na pesquisa destes algoritmos.

Os autores descrevem que os algoritmos contêm em geral até cinco etapas, conforme ilustra a Figura 12; estas etapas estão descritas a seguir:

- Extração de sinais respiratórios – consiste em extrair um ou mais sinais dominados pela modulação respiratória;
- Fusão de sinais respiratórios – vários sinais respiratórios podem ser fundidos para dar um sinal respiratório; esta é uma etapa opcional;
- Estimativa da frequência respiratória – consiste em estimar a FR a partir de uma janela de sinal respiratório;
- Fusão das estimativas de FR: várias estimativas de frequências respiratórias podem ser unidas para obter uma estimativa acurada; esta é uma etapa opcional;
- Avaliação da qualidade do resultado: usada para rejeitar ou mitigar estimativas imprecisas; esta é uma etapa opcional.



Figura 12. Etapas dos algoritmos para estimar a FR a partir dos sinais de ECG ou PPG (Fonte: [2]).

3.5.1 EXTRAÇÃO DE SINAIS RESPIRATÓRIOS

Os sinais de PPG são primariamente de origem cardíaca, com modulações respiratórias secundárias de magnitudes muito mais baixas. As técnicas para extração de um sinal respiratório são baseadas em **filtragem** ou **características fisiológicas** [2].

O passo inicial, comum a todas as técnicas de extração de um sinal respiratório, é a eliminação de frequências muito baixas; ou seja, remover as frequências inferiores à taxa respiratória. Para tanto, os algoritmos normalmente implementam uma filtragem passa-alta com frequência de corte entre 0,03 e 0,05 Hz [24].

Técnicas baseadas em **filtragem** para extração de um sinal respiratório são realizadas em uma única etapa; algumas destas técnicas estão descritas abaixo [2] e [24]:

- *Filtragem passa-banda* entre 4 e 60 rpm, para eliminar sinais fora do intervalo de frequências respiratórias plausíveis;
- *Decomposição de modo empírico*, em inglês Empirical Mode Decomposition (EMD), para extrair um sinal respiratório como um modo de oscilação particular dado pela função de modo intrínseco, em inglês Intrinsic Mode Function (IMF);
- *Decomposição do sinal usando a transformada de onda discreta*, em inglês Discrete Wavelet Transform (DWT);
- *Extração da oscilação respiratória* usando análise de componentes principais;
- Filtragem do sinal usando a função de *correntopia centrada* [24].

Técnicas para extração de um sinal respiratório baseadas em **características fisiológicas** iniciam eliminando ruídos de altas frequências por filtragem passa-baixa com frequências corte de 10 a 35 Hz e, seguindo de uma extração de característica específica que depende de cada técnica. Exemplos de técnicas baseadas em características fisiológicas do sinal de respiração foram descritas na Seção 3.4.

3.5.2 FUSÃO DE SINAIS RESPIRATÓRIOS

O segundo estágio é a fusão de múltiplos sinais respiratórios para fornecer um sinal respiratório a partir do qual a FR pode ser estimada. Sinais respiratórios podem ser obtidos extraíndo vários sinais simultaneamente (usando diversos métodos de extração) ou segmentando um sinal respiratório em janelas (muitas vezes sobrepostas) e tratando estes como sinais individuais. As técnicas para fusão de múltiplos sinais respiratórios são descritas abaixo:

- *Média espectral* - calcula o espectro médio a partir dos espectros de potência individuais de sinais respiratórios;
- *Média espectral condicionada por pico* - apenas espectros com picos suficientes são incluídos. Um espectro é qualificado quando tem uma proporção de sua potência dentro de um intervalo em torno da frequência correspondente à potência máxima ou a estimativa da FR anterior;
- *Uso de uma rede neural* com múltiplos sinais de entrada para identificar períodos de inspiração e expiração.

Esta etapa é opcional e visa aumentar a precisão e robustez das estimativas de FR.

As técnicas de fusão de sinais respiratórios simultâneos resultam em um único sinal respiratório com conteúdo respiratório aprimorado e frequência espúria reduzida. Essas técnicas, como a média espectral, podem melhorar a precisão do algoritmo de FR, mesmo além da precisão alcançada usando o sinal respiratório com a modulação respiratória mais forte.

As técnicas de fusão geralmente incorporam avaliação de qualidade, excluindo do cálculo sinais que exibem pouca modulação respiratória. A avaliação da qualidade pode impedir que uma FR seja calculada se não houver modulação respiratória suficiente, o que é apropriado ao monitorar continuamente a FR para detectar anormalidades.

3.5.3 ESTIMATIVA DA FR

A terceira etapa dos algoritmos estima a frequência respiratória tendo como entrada uma janela de um sinal respiratório e como saída um valor estimado de FR. As técnicas utilizadas para esta etapa, atuam nos domínios tempo e frequência.

As técnicas no domínio tempo envolvem a detecção de respirações individuais, seguidas pelo cálculo de média de FR. Estas técnicas têm a vantagem de não exigir uma FR quase estacionária, embora sejam suscetíveis à detecção de respiração espúria, devido à morfologia anormal do sinal respiratório.

As técnicas no domínio frequência envolvem a identificação do componente de frequência relacionado à respiração, normalmente por meio de

análise espectral ou identificação da frequência dominante instantânea.

3.5.4 FUSÃO DAS ESTIMATIVAS DE FR

Técnicas de fusão de múltiplas estimativas de frequência respiratória podem ser usadas para melhorar a robustez da estimativa final. Várias abordagens têm sido usadas para fundir estimativas de FR simultâneas derivadas de diferentes sinais respiratórios. Estas FRs podem ser fundidas usando a média, mediana ou modo, opcionalmente após a exclusão de valores atípicos. A qualidade da estimativa final pode então ser avaliada a partir do desvio padrão das estimativas individuais. As estimativas também podem ser combinadas ponderando as frequências respiratórias de acordo com suas variâncias [24].

3.5.5 AVALIAÇÃO DA QUALIDADE DA ESTIMATIVA DE FR

As técnicas de avaliação da qualidade da estimativa de frequência respiratória são opcionais e se dividem em duas categorias: Índices de Qualidade de Sinal (IQSs) e Índices de Qualidade Respiratória (IQRs).

IQS é usado para identificar segmentos de dados do sinal de PPG com baixa qualidade, que normalmente são rejeitados com base na suposição de que as FRs derivadas deles provavelmente são imprecisas. Um segmento de sinal é considerado de alta ou baixa qualidade comparando o coeficiente de correlação médio para esse segmento com um limiar determinado empiricamente. Além disso, a qualidade do sinal pode ser avaliada usando vários detectores de batimentos, com concordância entre os detectores indicando alta qualidade. As características batimento a batimento também foram analisadas para identificar sinais de entrada de baixa qualidade, incluindo intervalos batimento a batimento, e amplitudes de pulso.

IQR é usado para avaliar a qualidade dos sinais respiratórios extraídos; uma vez que a presença ou ausência de modulações respiratórias de PPG varia com base em fatores como sexo, idade, condições de saúde pré-existentes, nível de hidratação, posição, e o valor da própria frequência respiratória. Os IQRs avaliam a qualidade dos sinais respiratórios com base na regularidade dos picos respiratórios e na periodicidade da forma de onda respiratória.

Charlton et al. [24] descrevem que os IQRs retornam um intervalo de valores (geralmente entre 0 e 1) em oposição a um resultado binário. Uma das considerações importantes na implementação do IQR é o compromisso entre a retenção de dados e a precisão aprimorada da estimativa. Resultados recentes, usando IQRs para fundir estimativas de FR de múltiplas modulações de PPG, mostraram que IQRs aumentam a retenção de dados e diminuem o erro de estimativa em comparação com os métodos de fusão existentes.

4. TRABALHOS RELACIONADOS

Este capítulo apresenta um levantamento bibliográfico referente a algoritmos de obtenção da frequência respiratória através do sinal de PPG, tendo como referência as seguintes bases de dados:

- IEEE Xplore (<https://ieeexplore.ieee.org/>);
- Springer Nature (<https://link.springer.com/>);
- Elsevier (<https://www.sciencedirect.com/>).

Para a busca foram utilizadas as palavras-chave: “*Breathing Rate*”, “*Respiratory Rate*” e “*Photoplethysmography*” e filtrados artigos de 2017 até 2021 para conter informações atualizadas referente aos temas. Os artigos foram analisados com a finalidade de identificar técnicas utilizadas para calcular a FR, a obter a curva de PPG e calcular o desempenho do algoritmo empregado. Como resultado, foram obtidos 455 artigos que foram filtrados pelo título e abstract de forma a identificar os documentos que continham relação com a pesquisa aqui proposta, restando 19 artigos que são detalhados a seguir.

4.1 Toward a Robust Estimation of Respiratory Rate from Pulse Oximeters

Pimentel et al. [25] propuseram um algoritmo que extrai três modulações referentes às características respiratórias (RIIV, RIFV e RIAV) detectando picos e vales do sinal de PPG. Os autores empregam duas métricas para melhorar a qualidade dos dados obtidos. A primeira métrica usa o índice de qualidade de sinal (IQS) para identificar artefatos e, potencialmente, períodos de baixa qualidade do sinal de PPG. A métrica é composta por um limiar de histerese usado para determinar a menor flutuação a ser considerada; amostras com flutuações abaixo desse limite são consideradas como linhas planas que devem ser ignoradas. A segunda métrica analisa os batimentos detectados por dois detectores de pico; estes picos são considerados coincidentes se ocorrem dentro de uma janela de 150 ms. Amostras que não satisfazem estes limiares são descartadas e nenhuma FR é estimada para aquela janela.

Os autores obtiveram as séries temporais de respiração com uma modelagem autorregressiva e calcularam a FR com a mediana das amplitudes

do espectro de potência das séries temporais. Os resultados experimentais foram alcançados utilizando os bancos de dados CapnoBase [5] e BIDMC [6].

4.2 Selection of Empirical Mode Decomposition Techniques for Extracting Breathing Rate from PPG

Motin, Karmakar e Palaniswami [31] apresentaram variações de algoritmos baseados na decomposição de modo empírico, em inglês *Empirical Mode Decomposition* (EMD), que é amplamente utilizado para decompor sinais não lineares e não estacionários. A EMD decompõe uma série temporal em um conjunto finito de monocomponentes de média zero, denominado função de modo intrínseco, em inglês *Intrinsic Mode Function* (IMF). As variantes de EMD são complementares; e.g., (i) a *EMD do conjunto*, em inglês *Ensemble EMD* (EEMD), (ii) a *EEMD complementar*, em inglês *Complimentary EEMD* (CEEMD), (iii) a *CEEMD com ruído adaptativo*, em inglês *CEEMD Adaptive Noise* (CEEMDAN) e (iv) a *CEEMDAN aprimorada*, em inglês *Improved CEEMDAN* (ICEEMDAN).

A obtenção correta dos IMFs requer detectar e descartar os IMFs devido a artefatos e atividade cardíaca; apenas IMFs com frequências entre 0,05 e 0,75 Hz (3 a 45 respirações por minuto - rpm) são selecionados para estimar a FR. Após a determinação do IMF predominante, a FR é estimada empregando a Transformada Rápida de Fourier, em inglês *Fast Fourier Transform* (FFT), no sinal de PPG. Os testes de desempenho dos algoritmos foram realizados com os bancos de dados MIMIC [28] e CapnoBase, contendo indivíduos com atividade respiratória espontânea e de controle. Entre os modelos híbridos apresentados, os algoritmos ICEEMDAN e EEMD apresentam as melhores eficácias, com resultados comparativamente precisos.

4.3 Derivation of Respiration Rate from Ambulatory ECG and PPG using Ensemble Empirical Mode Decomposition: Comparison and Fusion

Orphanidou [26] propôs uma técnica que emprega EEMD para identificar o “modo” de respiração a partir dos sinais de RIFV e RIAV extraídos de sinais de

PPG, que podem estar potencialmente corrompidos por ruído. Inicialmente a técnica identifica os momentos que ocorrem os picos de PPG, usando um detector de pico de três pontos com limiares estatísticos, assim, derivando uma série temporal modelada em amplitude (RIAV) interpolando os picos identificados. Posteriormente, a técnica aplica EEMD no sinal interpolado para remover os ruídos presentes, e soma os sinais das funções de modo intrínseco 2 e 3 (IMF2 e IMF3), por serem mais propensos a conter o “modo” de respiração. Por fim, o resultado da FR é estimado medindo o número de cruzamentos em zero tanto para a modulação em frequência (RIFV) quanto amplitude (RIAV).

Os autores avaliaram o desempenho da técnica com um banco de dados desenvolvido especificamente para investigar a adequação de sensores vestíveis comerciais. A FR foi estimada empregando janelas de observação de 1 min para cada amostra do banco de dados.

4.4 Ensemble Empirical Mode Decomposition with Principal Component Analysis: A Novel Approach for Extracting Respiratory Rate and Heart Rate from Photoplethysmographic Signal

Motin, Karmakar e Palaniswami [27] utilizam um algoritmo com EEMD para estimar a frequência respiratória do sinal de PPG. A EEMD foi usada para decompor cada época de um sinal de PPG em uma série de IMFs. Por sua vez, os IMFs com frequência dominante inferior a 0,05 Hz ou superior a 0,75 Hz foram considerados como artefatos e eliminados; os IMFs com frequência dominante dentro do intervalo [0,05, 0,75] Hz (faixa de frequência de respiração típica de adultos jovens) foram selecionados para serem processados posteriormente.

A próxima etapa do algoritmo extrai componentes principais dos IMFs resultando em uma única componente contendo informações respiratórias. Por fim, o algoritmo aplica uma FFT na componente respiratória para obter a frequência dominante do sinal; este sinal é multiplicado por 60 para obter a frequência respiratória em respirações por minuto (rpm). As análises da abordagem proposta neste experimento utilizaram os bancos de dados MIMIC e CapnoBase.

4.5 Estimation of Breathing Rate from the Photoplethysmography Using Respiratory Quality Indexes

Khreis and Carrault [29] propuseram um algoritmo fundamentado nas características fisiológicas da respiração que extrai as modulações RIAV, RIIV e RIFV do sinal de PPG. O algoritmo detecta picos e vales no domínio do tempo, sendo composto pelos seguintes passos: (i) estimativa do Índice de Qualidade Respiratória (IQR) para cada modulação individual, (ii) retenção da modulação com maior IQR e, finalmente, (iii) estimativa da FR, computando o número de picos ou vales no domínio do tempo da modulação com maior IQR. Os autores avaliaram os passos propostos no algoritmo utilizando o banco de dados CapnoBase.

4.6 A Robust Fusion Model for Estimating Respiratory Rate from Photoplethysmography and Electrocardiography

Birrenkott et al. [30] propuseram um modelo para detectar picos e vales do sinal de PPG, fundamentado na extração das modulações RIIV, RIAV e RIFV. O algoritmo proposto filtra os sinais usando um circuito passa-banda Butterworth de quinta ordem ajustado para selecionar a faixa de frequência no intervalo $[0,083, 1]$ Hz (equivalendo a uma frequência respiratória entre 5 e 60 rpm). O algoritmo aplica IQRs baseados em FFT, autocorrelação e autorregressão. IQRs são métricas utilizadas para validar a frequência respiratória medida em cada uma das modulações; conseqüentemente, o algoritmo considera como FR, valor estimado pela modulação como maior IQR. A análise do algoritmo foi realizada nos bancos de dados MIMIC e CapnoBase.

4.7 Respiratory Rate Estimation from the Photoplethysmogram Combining Multiple Respiratory-induced Variations Based on SQI

Yang et al. [32] propuseram um algoritmo fundamentado nas características fisiológicas da respiração que inicia usando filtros passa-baixa para eliminar interferências de ruídos de alta frequência do sinal de PPG. O

algoritmo avalia a qualidade do sinal com estatísticas de ordem superior, análise morfológica, e correspondência de modelos.

Na etapa seguinte, o algoritmo obtém uma forma de onda respiratória reconstruída a partir de quatro modulações: RIAV, RIFV, RIIV e APS-PPG. Então, o algoritmo calcula as frequências respiratórias das modulações utilizando modelagem autorregressiva, que estima o espectro de potência das séries temporais de respiração.

Por fim, o algoritmo proposto calcula os desvios padrão dos quatro valores de frequência respiratória, descartando amostras onde esse desvio é superior a 3 rpm e calcula a FR final pela média dos valores de frequência respiratória com desvio padrão menor ou igual a 3 rpm.

Os autores não descrevem o nome do banco de dado empregado para avaliar o algoritmo, mas deixam a entender que foi um banco de dados desenvolvido para finalidade específica do trabalho proposto.

4.8 Reliable Respiratory Rate Extraction using PPG

Pollreisz e Nejad [33] propõem o algoritmo *Smart Fusion of Frequency Domain Peak* (SFFDP), que inicia pré-processando os dados brutos do sinal PPG com filtragem passa-banda para remover ruídos fora do intervalo de frequência de interesse.

Após a filtragem, o algoritmo SFFDP extrai as modulações RIIV, RIAV e RIFV, e estima as FRs de cada modulação como sendo a frequência dominante na faixa de 0,033 a 2 Hz (intervalo de 2 a 120 rpm).

A última etapa do algoritmo é a fusão dos valores de FR estimados; primeiramente é calculado para cada janela de observação, o Desvio Padrão (DP) das FRs estimadas com as modulações RIIV, RIAV e RIFV. Se o DP for inferior a 4 rpm, o SFFDP calcula o valor médio de todas as FRs e considera este o valor final da fusão. Caso apenas duas estimativas de FR tiverem um DP abaixo de 4 rpm e esse valor for inferior ao DP de todas as três estimativas, o valor médio dessas duas estimativas é calculado e definido como o valor final de FR da técnica de fusão. Se todos os DPs excederem 4 rpm, o valor da FR será definido como NaN, sendo necessária uma nova avaliação em uma janela de observação futura.

O conjunto de dados utilizado na análise é composto por 41 amostras de quatro voluntários saudáveis do sexo masculino, com idades entre 26 e 29 anos, realizando três tipos diferentes de respiração e movimentos.

4.9 PPG Derived Respiratory Rate Estimation in Daily living Conditions

Motin et al. [34] propuseram obter a frequência respiratória por filtragem; o algoritmo implementado aplica uma fusão inteligente baseada em EEMD. O modelo proposto pode ser dividido em três partes: (a) segmentação de dados e redução de ruído baseado em EEMD; (b) extração de variação induzida pela respiração; e (c) estimativa da FR baseada em fusão inteligente.

Na primeira parte, o EEMD é aplicado ao sinal de PPG, dividindo o mesmo em funções de modo intrínseco. Uma vez que a maioria das informações fisiológicas desejadas do PPG são armazenadas dentro da faixa de frequência de 0 a 25 Hz, o algoritmo assume que são artefatos os IMFs com frequência dominante superior a 25 Hz. IMFs contaminados com artefatos são automaticamente identificados e rejeitados para reconstrução do sinal de PPG.

Na segunda parte, as variações de amplitude (RIAV), frequência (RIFV) e intensidade (RIIV) induzidas pela respiração são extraídas do sinal de PPG reconstruído.

Finalmente, o algoritmo calcula o desvio padrão entre as três frequências respiratórias estimadas; quando este valor é maior que 5 rpm, as amostras são descartadas por serem consideradas ruidosas e quando for igual ou inferior a 5 rpm, a FR é calculada pela média entre os três valores estimados.

Foram analisados dez registros de sinais de PPG de cinco voluntários, enquanto estes realizavam cinco atividades diferentes: sentar, ficar em pé, subir e descer escadas, caminhar e correr.

4.10 Efficient Respiratory Rate Extraction on a Smartwatch

Pollreisz e TaheriNejad [35] estimaram a FR fundamentado em características fisiológicas da respiração. Para tanto, os autores prepararam os dados brutos do sinal de PPG com uma filtragem passa-banda. Esta filtragem

eliminou ruídos fora da faixa de interesse, ajudando a extrair os máximos e mínimos locais do sinal de PPG. O trabalho proposto conta apenas com a modulação RIFV do sinal PPG, que foi calculada pela diferença temporal entre picos consecutivos do sinal. A FR foi obtida como o valor de frequência dominante no intervalo de 0,033 a 2 Hz (correspondendo ao intervalo de frequência respiratória de 2 a 120 rpm). O algoritmo foi analisado com um banco de dados criado pelos autores, contendo quatro voluntários usando um *wearable* de pulso.

4.11 Breathing Rate Estimation using Kalman Smoother with Electrocardiogram and Photoplethysmogram

Khreis et al. [36] desenvolveram um algoritmo para estimar a FR a partir dos sinais de ECG e PPG, com intuito de evitar o uso de sensores incômodos e desconfortáveis para medições diretas. O algoritmo proposto extrai várias formas de onda de respiração derivadas de sinais de ECG ou PPG, com base em modulações RIIV, RIAV e RIFV.

Os autores descrevem que é difícil determinar a combinação ideal dos sinais resultantes para estimativa de FR devido a ruídos e especificidades dos pacientes. Eles propuseram duas abordagens que quantificam a qualidade das formas de onda de modulação usando IQRs:

- Abordagem 1 - Seleciona automaticamente o sinal de modulação com maior IQR para estimativa de FR;
- Abordagem 2 - Rastreia o sinal de respiração usando o suavizador de Kalman para fundir os sinais de modulação com maior IQR.

A estimativa da frequência respiratória no domínio do tempo é obtida pela diferença de tempo entre dois picos consecutivos do sinal respiratório, correspondendo a um ciclo respiratório em segundos; o inverso deste valor é multiplicado por 60 para obter a FR em rpm. O algoritmo contém cinco etapas ilustradas na Figura 13 e descritas a seguir:

- (A) Extração das modulações dos sinais de ECG ou PPG;
- (B) Cálculo dos IQRs para cada tipo de modulação extraída;
- (C) Seleção da modulação (Abordagem 1) com maior IQR;

- (D) Emprego do suavizador de Kalman (Abordagem 2) para mesclar múltiplas FRs;
- (E) Estimativa da FR usando a primeira ou segunda abordagem.

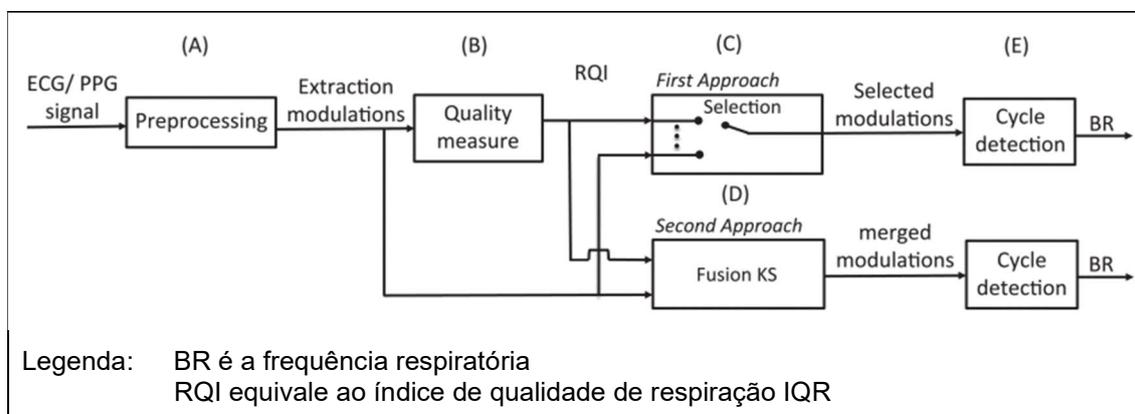


Figura 13. Etapas do algoritmo proposto por Khreis et al. [36] (Fonte: [36]).

Resultados experimentais, obtidos com os bancos de dados CapnoBase e Sherpam [37], mostram que o emprego de IQR acoplado a um algoritmo de fusão aumenta a acurácia das estimativas de frequência respiratória.

4.12 Breathing Rate Estimation Methods from PPG Signals, on CapnoBase Database

Lazzera e Carrault [38] compararam algoritmos de estimativa da frequência respiratória a partir do sinal de PPG, objetivando selecionar o melhor algoritmo dentre os já propostos na literatura.

Empregando o sinal de PPG do banco de dados CapnoBase, em janelas de observação de 32s e 64s, os autores testaram a extração da frequência respiratória com: (i) EMD; (ii) EMD combinado com análise de componentes principais; (iii) DWT; e análises de (iv) RIIV; (v) RIAV; e (vi) RIFV. Todas as estimativas de frequência respiratória foram realizadas no domínio frequência, e o valor da estimativa final da FR foi calculado com as médias dos dois valores mais próximos, pois todos os algoritmos resultaram em mais de uma FR. Os resultados de maior precisão foram alcançados com as modulações RIIV, RIAV e RIFV. Apenas o algoritmo proposto por [36], utilizando filtragem de Kalman e uma abordagem de fusão de dados, superou os demais resultados.

4.13 Respiratory Rate Estimation using the Photoplethysmogram: Towards the Implementation in Wearables

Kozumplik et al. [39] desenvolveram um algoritmo para estimativa da FR fundamentado nas características fisiológicas da respiração com a extração das modulações RIAV e RIFV. O algoritmo foi planejado para ter operação independente de usuário e ser embarcado em dispositivos do tipo *wearable*, que impõe restrições de memória e processamento.

Experimentos com os bancos de dados CapnoBase e BIDMC mostraram que as melhores estimativas de FR foram obtidas com a modulação RIAV. A Figura 14 ilustra os três sinais respiratórios extraídos do sinal de PPG com modulações RIIV e RIAV:

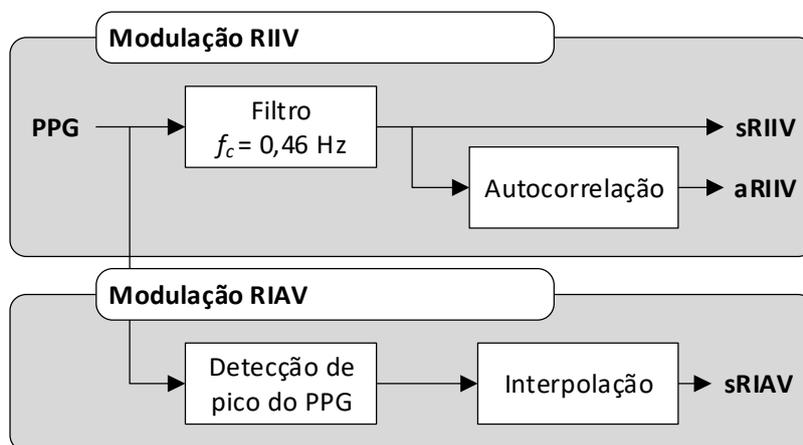


Figura 14. Extração de sinais respiratórios tendo como base o sinal PPG com modulações RIIV e RIAV (Fonte: [39]).

- sRIIV - Sinal respiratório da modulação RIIV, obtido por um *filtro passa-baixa com frequência de corte de 0,46 Hz*;
- aRIIV - Sinal respiratório da modulação RIIV, obtido da *autocorrelação de desvio de sinal de PPG*;
- sRIAV - Sinal respiratório da modulação RIAV, obtido com a *detecção e interpolação de picos do sinal PPG*.

Todos os sinais respiratórios foram reduzidos para uma amostragem de 25 Hz, minimizando a demanda computacional do algoritmo. A Figura 15 descreve que as estimativas de FR foram realizadas nos domínios tempo (empregando a medição das distâncias de pico dos sinais respiratórios sRIIV, aRIIV, sRIAV) e frequência (utilizando a FFT).

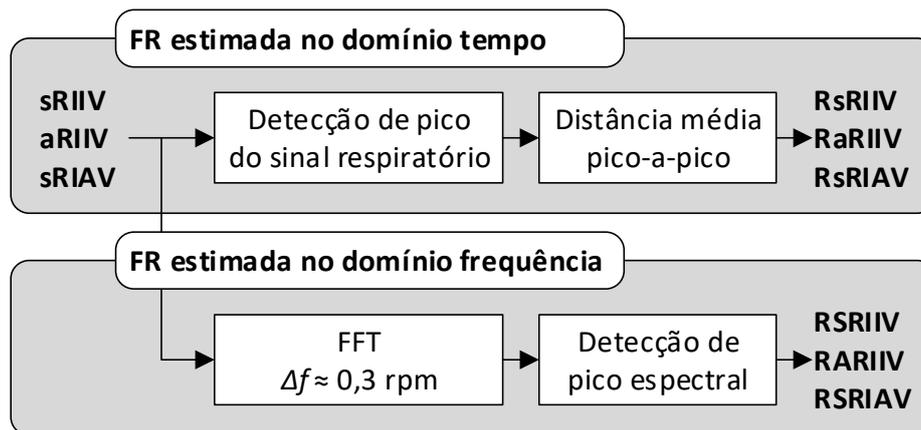


Figura 15. Estimativas de frequência respiratória nos domínios tempo e frequência (Fonte: [39]).

O algoritmo finda com uma técnica de fusão que calcula a frequência respiratória final a partir da mediana dos valores de FR obtidos das 6 amostras (RsRIIV, RaRIIV, RsRIAV, RSRIIV, RARIIV, RSRIAV) em intervalos de observação de 60 s.

Os autores concluíram que as técnicas empregadas são simples, rápidas, eficientes e precisas. Podendo trabalhar em tempo real (com buffer) e usando apenas o sinal de PPG, que hoje em dia é disponibilizado na maioria dos *wearables* voltados para medições da área da saúde.

4.14 Respiratory Rate Estimations using Three Respiratory-Induced Variations on Photoplethysmogram

Fikriastuti e Muhaimin [40] abordaram um algoritmo para estimativa de frequência respiratória fundamentado nas características fisiológicas da respiração. Os dados foram obtidos do CapnoBase com janelas de observação (segmentos) de 32 s, 64 s, 96 s e 128 s. Após a análise de cada segmento, o algoritmo **avança um segundo** e inicia a análise do próximo segmento. Este processo gera uma janela deslizante de segmentos sobre todo o tempo de uma amostra de dados.

O algoritmo detecta picos, vales e artefatos, bem como estima o sinal respiratório empregando as modulações RIIV, RIFV, RIAV. Os autores implementaram duas abordagens que empregam a técnica de fusão, sendo que ambas as técnicas estimam a FR empregando FFTs nos sinais respiratórios.

4.15 Continuous Measurement of Respiratory Rate via Single-Wavelength Reflective Photoplethysmography

O algoritmo proposto por Protopsaltis, Krizea e Gialetis [41] é fundamentado nas características fisiológicas da respiração; ele detecta picos e vales do sinal de PPG para extrair as modulações RIIV, RIFV e RIAV. Os autores utilizam um filtro passa-alta com frequência de corte de 0,2 Hz para remover frequências não respiratórias, e aplicam a FFT em janelas de Hanning para minimizar o lóbulo lateral da resposta de frequência, produzindo gráficos de densidade espectral de potência. Nesta fase, dois espectros de potência consecutivos para cada sinal modulado são combinados para amplificar os picos de potencial, no caso de serem erroneamente mascarados por artefatos de movimento.

Por fim, a frequência dominante dentro da região respiratória plausível é identificada como FR final. O algoritmo foi analisado com dois bancos de dados: (i) um específico, obtido com dois voluntários utilizando um dispositivo vestível desenvolvido pela equipe e (ii) outro público, CapnoBase.

4.16 PPG-Based Respiratory Rate Monitoring Using Hybrid Vote-Aggregate Fusion Technique

Haddad, Boukhyama e Caizzone [42] abordaram um algoritmo que extrai as modulações RIIV, RIFV, RIAV do sinal de PPG. Os sinais resultantes são filtrados com frequências de corte entre 0,067 e 1 Hz (intervalo de FR de 4 a 60 rpm). Os valores de frequência respiratória, obtidos em cada modulação, passam por um algoritmo de fusão que agrega duas das três estimativas ou escolhe uma das três com base na mediana e no desvio padrão dos valores de FR. O trabalho foi analisado com sinais de PPG presentes no CapnoBase.

4.17 Design and validation of a respiratory rate estimation algorithm based on photoplethysmography (PPG) signal

Icazatti, Dell'Aquila e Leber [43] propuseram um algoritmo aplicado ao sinal de PPG que é processado com um filtro linear passa-baixa do tipo resposta

de impulso finito, em inglês Finite Impulse Response (FIR), resultando o sinal respiratório estimado.

O algoritmo emprega um detector de pico para medir a duração de cada ciclo do sinal respiratório estimado. O valor de FR é obtido com base na média das durações dos ciclos presentes em uma janela de observação de 30 segundos.

Os autores avaliaram o algoritmo usando duas bases de dados online disponíveis gratuitamente: (i) BIDMC, que é um subconjunto do banco de dados MIMIC e (ii) Cleveland Children's Sleep and Health Study (CCSHS) [44].

4.18 A New Framework to Estimate Breathing Rate from Electrocardiogram, Photoplethysmogram, and Blood Pressure Signals

Adami et al. [45] implementaram um algoritmo que usa EMD e DWT para extrair sinais respiratórios, aproveitando as informações de domínio tempo e frequência. Em primeiro lugar, o sinal de PPG é pré-processado para eliminar componentes DC e ruídos de alta frequência. Em segundo lugar, os sinais são decompostos em componentes usando DWT e EMD. Finalmente, o algoritmo calcula a densidade espectral de potência das componentes, identificando os componentes correspondentes aos sinais respiratórios.

O algoritmo calcula o IQS ao longo do tempo para cada sinal respiratório, sendo aplicado um Filtro de Kalman para remover ruídos. Subsequentemente, o algoritmo emprega fusão para gerar um único sinal respiratório. Finalmente, a FR é calculada detectando os picos do sinal respiratório obtido.

Os autores validaram a abordagem utilizando as bases de dados públicas MIT-BIH Polysomnographic Database [46] e BIDMC que contêm sinais fisiológicos do mundo real.

4.19 Modulation Model of the Photoplethysmography Signal for Vital Sign Extraction

Chenet al. [47] descreveram um algoritmo fundamentado nas características fisiológicas da respiração que extrai as modulações RIFV e RIAV

do sinal de PPG. Os experimentos foram conduzidos com dois tipos de sinais de PPG coletados de um sensor de contato (um oxímetro) e um sensor de imagem visível sem contato (uma câmera colorida).

Os autores expõem que, para ambos os sensores, a frequência cardíaca é dominante dentro do espectro do sinal de PPG; sendo esta frequência cardíaca guardada por duas componentes de frequência mais fracas em ambos os lados. A diferença do componente de frequência dominante dos componentes de guarda, multiplicada por 60, equivale ao valor da FR em “rpm”.

O algoritmo inicia aplicando a FFT no sinal de PPG, transformando no domínio frequência. Subsequentemente, o algoritmo procurando a componente de frequência dominante, bem como as duas componentes de guarda.

A Figura 16(a) mostra um sinal de PPG sintético com modulação em amplitude (RIAV), contendo 15.000 amostras de 500 Hz; i.e., uma janela de observação de 30 s. O sinal sintético apresenta 40 pulsos do sinal de PPG, que resultam 6 picos de modulação de amplitude dentro da janela de 30 s. Estes 40 pulsos do sinal de PPG representam a Frequência Cardíaca (FC), enquanto que os 6 picos de modulação de amplitude representam a frequência respiratória (FR). Ao expandir a janela de observação para 60 s, obtemos uma FC de 80 bpm (batimentos por minuto) e uma FR de 12 rpm.

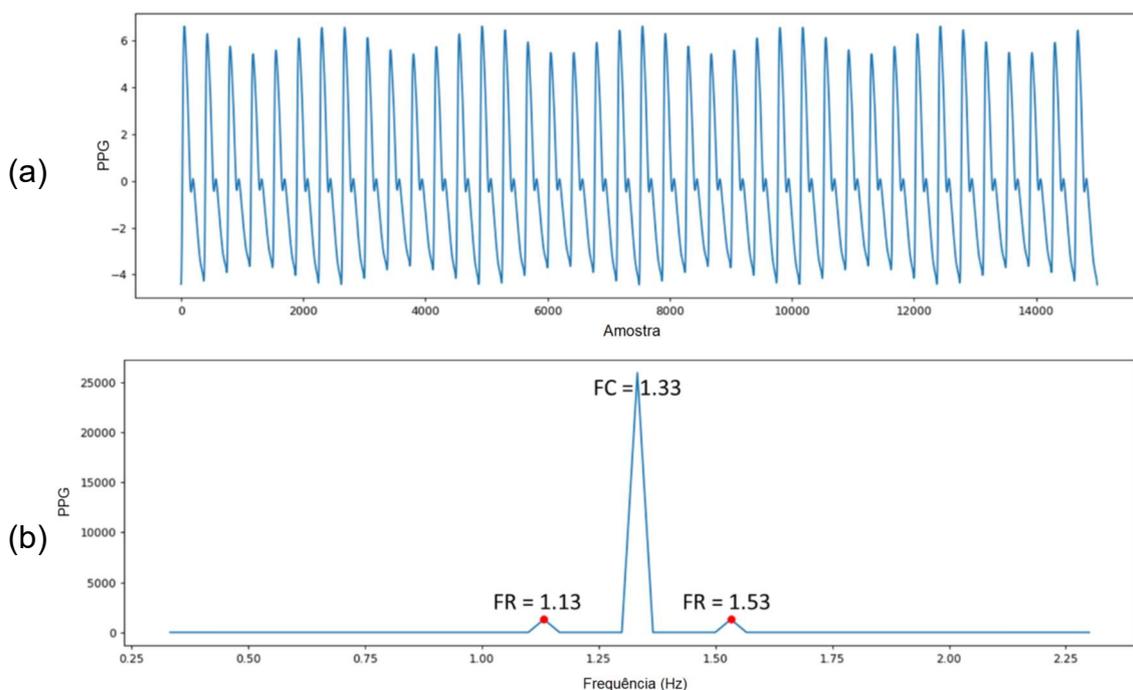


Figura 16. Aplicação da FFT em um sinal de PPG com modulação do tipo RIAV (Fonte: Autor).

A Figura 16(b) ilustra o espectro de frequências do sinal de PPG, após ser executada uma FFT. A figura mostra a existência de uma frequência dominante de 1,33 Hz, que é envolvida por duas componentes de frequência de guarda nos valores de 1,13 Hz e 1,53 Hz. A FC de 80 bpm é obtida ao multiplicar a frequência dominante por 60. A FR é obtida pelo módulo da diferença entre a frequência dominante e alguma frequência de guarda, i.e., $|1,13 - 1,33| = 0,2$ ou $|1,33 - 1,53| = 0,212$ rpm.

Embora a proposta de Chenet al. [47] seja matematicamente adequada, a sua aplicação prática pode ter sérios problemas para sinais ruidosos, principalmente em situações em que o ruído é próximo aos valores das componentes de guarda, pois este pode dificultar e até impedir o reconhecimento destas frequências.

4.20 Discussões

Os artigos analisados seguem a classificação apresentada em [2][24], onde a extração de frequência respiratória pode apresentar até cinco etapas. A Tabela 1 mostra os 19 artigos abordados neste capítulo, bem como o trabalho aqui proposto, relacionando estes artigos e nosso trabalho com: (i) ano de publicação, mostrando o foco nos cinco últimos anos; (ii) fundamento que norteia a extração da frequência respiratória; (iii) método de extração empregado; (iv) domínio que os sinais foram analisados; e (v) banco de dado utilizado para obter o sinal de PPG.

A coluna **Base** da Tabela 1 mostra que a extração da frequência respiratória da maior parte dos trabalhos é fundamentada nas características fisiológicas da respiração, sendo que uma parcela menor de trabalhos emprega o processo de filtragem do sinal de PPG. Quando analisamos isoladamente os métodos de filtragem, representados por *FL*, percebemos que a maior parte dos trabalhos [27][31][34][38][45] extrai a FR utilizando EMD e suas variações (ver coluna **Método**). Com o intuito de analisar a eficácia da EMD, o trabalho aqui proposto desenvolveu um algoritmo intitulado “Método EMD”, que extrai a frequência respiratória utilizando o princípio da EMD.

TABELA 1. SUMÁRIO COM AS PRINCIPAIS CARACTERÍSTICAS DOS TRABALHOS RELACIONADOS.

Art.	Ano	Base	Método	Domínio	Banco de dados
[25]	2017	Cfr	FFT*, RIIV, RIAV, RIFV, Fusão	Freq.	CapnoBase e BIDMC
[26]	2017	Cfr	EEMD, RIAV, RIFV	Tempo	Ad hoc
[27]	2018	FI	FFT, EEMD	Freq.	CapnoBase e MIMIC
[29]	2018	Cfr	RIIV, RIAV, RIFV	Tempo	CapnoBase
[30]	2018	Cfr	FFT*, RIIV, RIAV, RIFV	Freq.	CapnoBase e MIMIC
[31]	2019	FI	EMD, EEMD, CEEMD, CEEMDAN, ICEEMDAN	Tempo	CapnoBase e MIMIC
[32]	2019	Cfr	FFT*, APS-PPG, RIIV, RIAV, RIFV, Fusão	Freq.	Ad hoc
[33]	2020	Cfr	FFT*, RIIV, RIAV, RIFV, Fusão	Freq.	Ad hoc
[34]	2020	FI	FFT*, EEMD, RIIV, RIAV, RIFV	Freq.	Ad hoc
[35]	2020	Cfr	FFT*, RIFV	Freq.	Ad hoc
[36]	2020	Cfr	FFT*, RIIV, RIAV, RIFV	Freq.	CapnoBase e Sherpam
[38]	2020	FI e Cfr	FFT*, EMD, DWT, RIIV, RIAV, RIFV, Fusão	Freq.	CapnoBase
[39]	2021	Cfr	FFT*, RIIV, RIAV	Freq. e Tempo	CapnoBase e BIDMC
[40]	2021	Cfr	FFT, RIIV, RIAV, RIFV, Fusão	Freq.	CapnoBase
[41]	2021	Cfr	FFT*, RIIV, RIAV, RIFV, Fusão	Freq.	CapnoBase e Ad hoc
[42]	2021	Cfr	RIIV, RIAV, RIFV, Fusão	Tempo	CapnoBase
[43]	2021	FI	FIR	Tempo	BIDMC e CCSHS
[45]	2021	FI	FFT*, EMD, DWT	Freq.	BIDMC e MIT-BIH
[47]	2021	Cfr	FFT*, RIIV, RIAV, RIFV, Fusão	Freq.	Ad hoc
Este	2022	FI e Cfr	FFT, EMD, RIIV, RIAV, RIFV, Fusão	Freq. e Tempo	Synthetic Dataset, BIDMC e CapnoBase

Legenda: FI – Filtragem do sinal PPG, Cfr – Características fisiológicas da respiração
 Ad hoc – banco de dados construído com fim específico do trabalho avaliado
 FFT* – a FFT é empregada como recurso para obter o espectro de frequência de um sinal, mas não para cálculo direto da FR

Na análise referente a extração da FR fundamentada em características fisiológicas respiratórias, trabalhos representados por *Cfr* na coluna **Base**, identificamos a predominância das modulações RIIV, RIAV e RIFV, sendo que apenas um trabalho emprega a modulação APS-PPG [32]. Assim, o trabalho aqui proposto desenvolveu três algoritmos intitulados “Método RIIV”, “Método RIAV” e “Método RIFV” para estudar o desempenho isolado de cada modulação.

Adicionalmente, dividimos os artigos que extraem a FR fundamentados nas características fisiológicas da respiração em três conjuntos. Estes conjuntos são compostos pelos trabalhos que avaliam o desempenho de RIIV, RIAV e RIFV: (i) apenas individualmente [35][38][39]; (ii) individualmente, mas consideram a FR obtida com o maior índice de qualidade [29][30][36]; (iii) fazendo a fusão dos

valores de parciais de frequência respiratória obtida em cada modulação para calcular a FR final [25][26][32][33][38][40][41][42][47]. Para atender a estes cenários, o trabalho aqui proposto implementa o “Método Fusão”, que em sua etapa inicial avalia as FRs obtidas com modulações RIIV, RIAV e RIIF e faz a fusão desses valores quando um dado critério é aceito e, caso o critério seja recusado, faz a fusão com apenas duas modulações.

A coluna **Domínio** da Tabela 1 salienta que a maior parte dos trabalhos pesquisados estima a frequência respiratória analisando os sinais no domínio frequência, exceto os trabalhos [26][29][31][42][43] que empregam o domínio tempo. Dessa forma, exploramos a extração da FR com métodos que analisam tanto o domínio tempo, quanto o domínio frequência, e optamos por empregar a FFT em todos os métodos implementados. Adicionalmente, desenvolvemos o “Método FFT”, que utiliza isoladamente o princípio da FFT para estimar, baseado em filtragem, a frequência respiratória do sinal de PPG.

A coluna **Banco de Dados** da Tabela 1 mostra que a maior parte dos trabalhos utiliza o CapnoBase, seguido pelos bancos de dados MIMIC e BIDMC. Este motivo levou a escolhermos neste trabalho os bancos de dados CapnoBase e BIDMC, que são disponíveis gratuitamente e organizados para obter frequência respiratória a partir da análise do sinal de PPG. Adicionalmente, decidimos incluir o banco de dados Synthetic Dataset, do projeto Respiratory Rate Estimation [24], para avaliar as abordagens adotadas em ambiente livre de ruídos.

Todos os métodos citados neste capítulo foram descritos com mais detalhes no capítulo seguinte, informando as etapas de obtenção da frequência respiratória.

5. MÉTODOS PARA CÁLCULO DA FREQUÊNCIA RESPIRATÓRIA

Este capítulo descreve seis métodos implementados para analisar a eficácia e eficiência das estimativas de cálculo da FR provenientes do sinal de PPG. Estes métodos habilitam estimar a FR (i) empregando uma FFT; (ii) decompondo o sinal de PPG através do modo empírico; (iii) explorando as variações de frequência, amplitude e intensidade induzidas pela respiração, i.e., RIIV, RIAV, RIFV; e (iv) integrando múltiplas estimativas de FR.

Os métodos foram desenvolvidos utilizando a linguagem de programação Python dentro da ferramenta Web JupyterLab. Jupyter é um projeto de código aberto sem fins lucrativos, que evoluiu para dar suporte à ciência de dados interativa e à computação científica das linguagens de programação [48].

5.1 Empregando a Transformada Rápida de Fourier – Método FFT

A Transformada Rápida de Fourier, em inglês *Fast Fourier Transform* (FFT), calcula rapidamente a transformada discreta de Fourier de uma sequência de dados, permitindo obter o espectro de frequências de um sinal. Este é um dos métodos mais utilizados para analisar sinais no domínio frequência, pois durante o processo de transformação, o tempo é eliminado matematicamente resultando apenas em componentes do sinal na frequência [21].

A implementação deste método utiliza a função `SciPy.fft`, presente na biblioteca Python `SciPy`, a qual retorna a transformada discreta de Fourier de uma sequência real ou complexa [49][50]. A extração da frequência respiratória a partir do sinal de PPG segue as seguintes etapas:

- Aplicação da FFT no sinal de PPG, convertendo todo o sinal do domínio tempo para o domínio frequência;
- Transformação do valor de frequência para “rpm”, que é obtido multiplicando o valor de pico dominante por 60.
- Identificação das frequências dominantes, extraíndo o valor de FR dentro do intervalo aceitável para seres humanos, sendo que este intervalo está entre 4 rpm (0,06 Hz) e 60 rpm (1 Hz);

A Figura 17(b) apresenta a aplicação da FFT sobre o sinal de PPG ilustrado na Figura 17(a) – o sinal tem 20.000 amostras coletadas em uma taxa

de 500 Hz. A análise da FFT da Figura 17(b) mostra dois picos dominantes nas frequências 0,36 Hz e 1,33 Hz. Dado o intervalo de FR humana, identificamos que a frequência de 0,36 Hz está associada a respiração, correspondendo a 22 rpm, enquanto a frequência de 1,33 Hz está associada ao batimento cardíaco, correspondendo a 80 rpm.

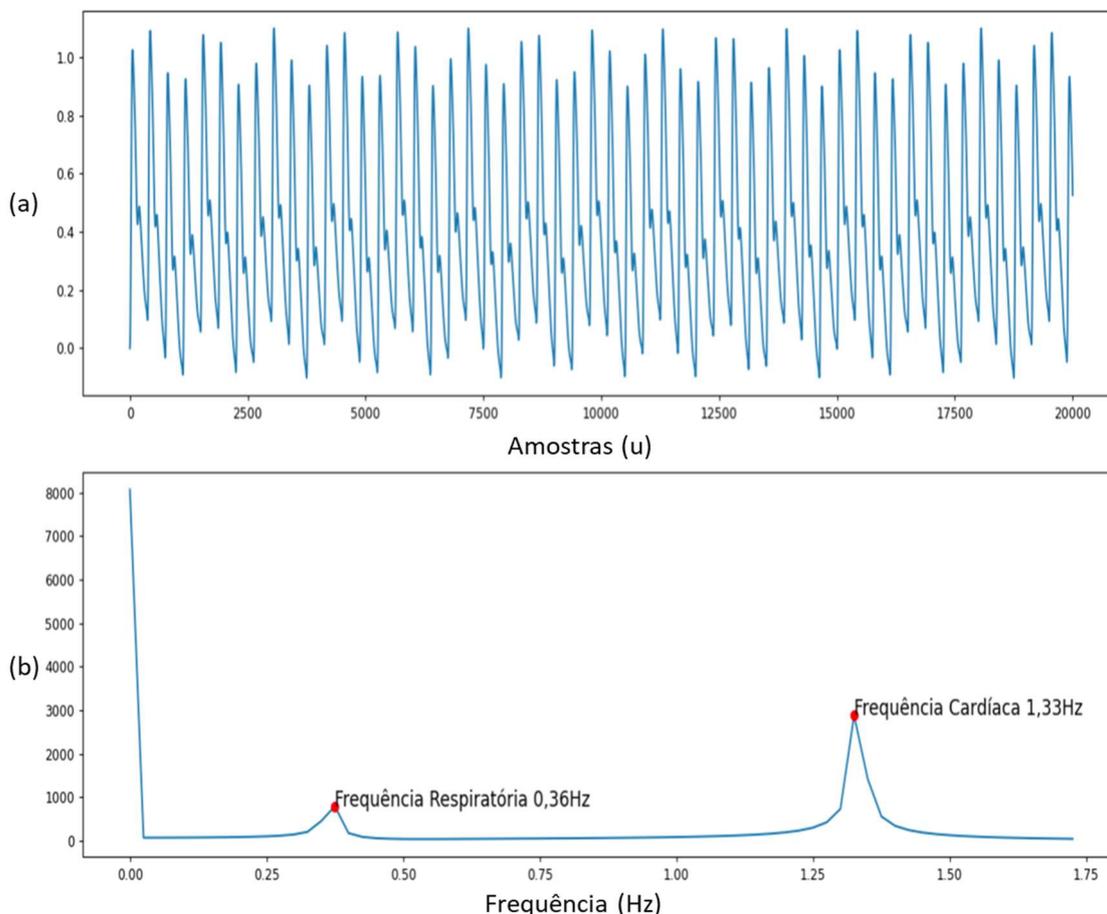


Figura 17. (a) Sinal de PPG e (b) correspondente aplicação do método FFT com identificação das frequências relevantes (Fonte: Autor).

5.2 Emprego do Modo Empírico para Decompor o Sinal de PPG – Método EMD

A decomposição de modo empírico, em inglês Empirical Mode Decomposition (EMD), desmembra uma série temporal em componentes individuais (oscilações intrínsecas), explorando as características temporais locais e estruturais dos dados [51]. Este é um método aplicável para séries temporais não lineares e não estacionárias.

A EMD inicia estimando um sinal como a soma de uma *tendência local* e

um componente de sinal representando o *detalhe local*; a tendência local é uma componente de baixa frequência e o detalhe local é responsável por altas frequências. Na EMD, os componentes de alta frequência (detalhes) são chamados de função de modo intrínseco, em inglês *Intrinsic Mode Functions* (IMF), e a parte de baixa frequência é chamada de sinal residual. O procedimento segue aplicando o mesmo processo ao sinal residual, que é considerado como uma nova série temporal. Sobre este sinal residual são extraídos um novo IMF e um novo sinal residual; portanto, os IMFs podem ser extraídos iterativamente [51], conforme apresenta a Figura 18.

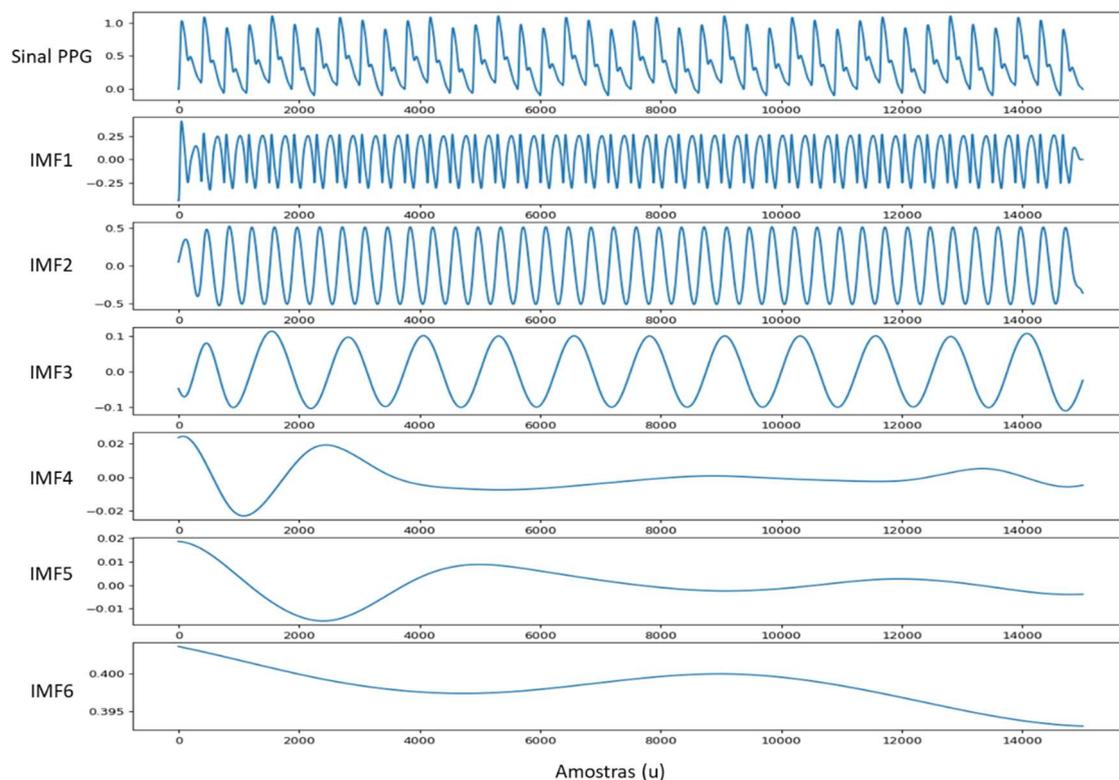


Figura 18. Procedimento iterativo para obtenção da frequência respiratória através do método EMD (Fonte: Autor).

A implementação do método EMD utiliza a função `PyEMD.emd`, presente na biblioteca Python `PyEMD`. Esta função recebe como entrada um sinal que é decomposto em um conjunto de componentes, retornando todas as funções de modo intrínseco obtidas do sinal original [52][53].

A extração da FR a partir do sinal de PPG segue as seguintes etapas:

- Extrair um sinal a partir das médias entre picos e vales do sinal de PPG;
- Subtrair o sinal obtido do sinal inicial. O sinal resultante é classificado como IMF quando a diferença de máximos e mínimos do sinal for no

máximo 1 e a média for zero;

- Aplicar a FFT nas IMF resultantes;
- Multiplicar os valores de pico obtidos por 60s para converter a frequência respiratória em “rpm”.
- Selecionar a IMF que contém picos dominantes de FR dentro do intervalo aceitável para seres humanos, sendo que o intervalo padrão para FR está entre 4 rpm (0,06 Hz) e 60 rpm (1 Hz);

5.3 Exploração das Variações de Frequência, Amplitude e Intensidade Induzidas pela Respiração - Métodos RIIV, RIAV e RIFV

A respiração pode induzir variações na linha de base, amplitude e frequência do sinal de PPG. Essas variações habilitam a exploração de três métodos para a estimativa da FR [23], ilustrados na Figura 19 e listados a seguir.

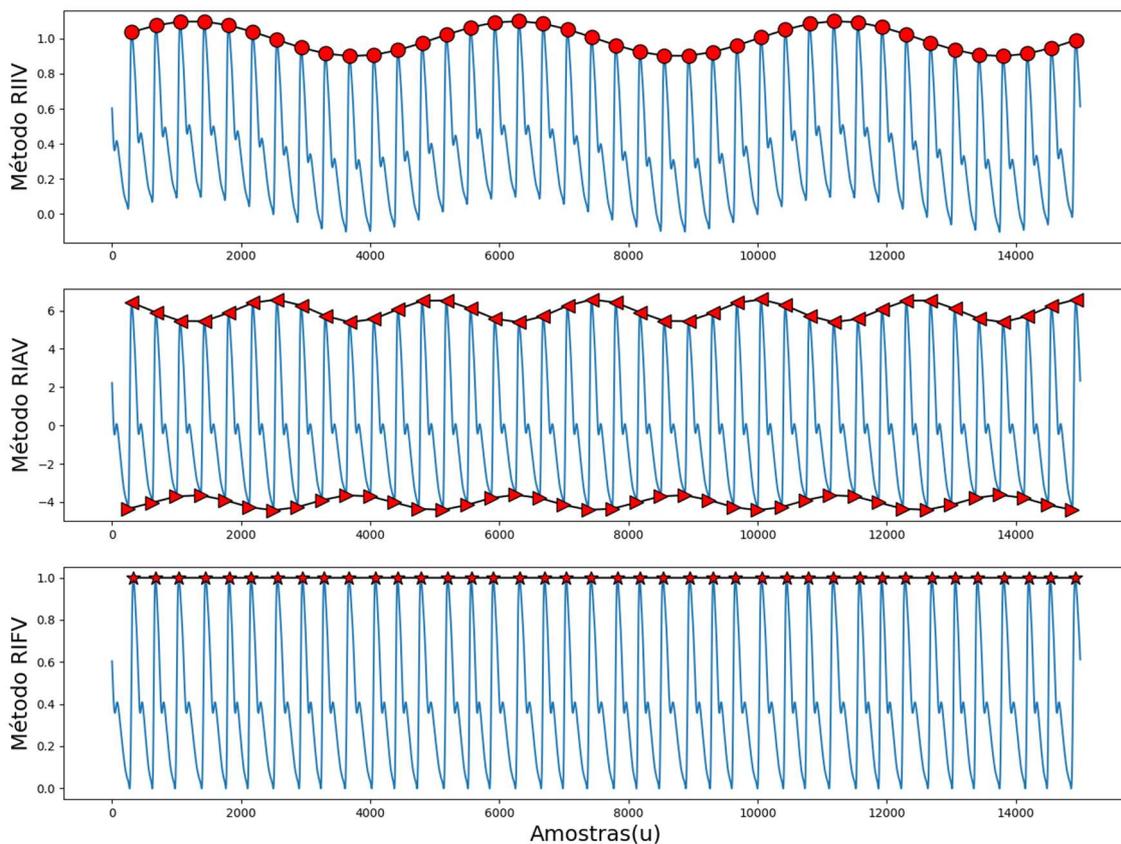


Figura 19. Métodos RIIV, RIAV e RIFV para a exploração da FR (Fonte: Autor).

- O Método RIIV explora variações da linha de base, sendo obtido através

da interpolação linear entre os picos do sinal de PPG;

- O Método RIAV explora variações da amplitude e pode ser alcançado pela interpolação linear dos valores da variação de amplitude entre os picos e vales do sinal de PPG;
- O Método RIFV explora variações da frequência e pode ser obtido pela interpolação linear entre a distância dos picos do sinal.

Os métodos RIIV, RIAV e RIFV foram implementados utilizando as funções SciPy.find_peaks e SciPy.interpolate, presentes na biblioteca Python SciPy, as quais retornam respectivamente, um vetor contendo todos os picos de um sinal e uma função cujo método de chamada usa interpolação para encontrar o valor de novos pontos, respectivamente [49][50].

A Figura 20 ilustra os resultados das interpolações lineares aplicados nos três sinais PPG modulados apresentados na Figura 19. A interpolação resulta em sinais respiratórios temporais contendo como informação principal a frequência respiratória.

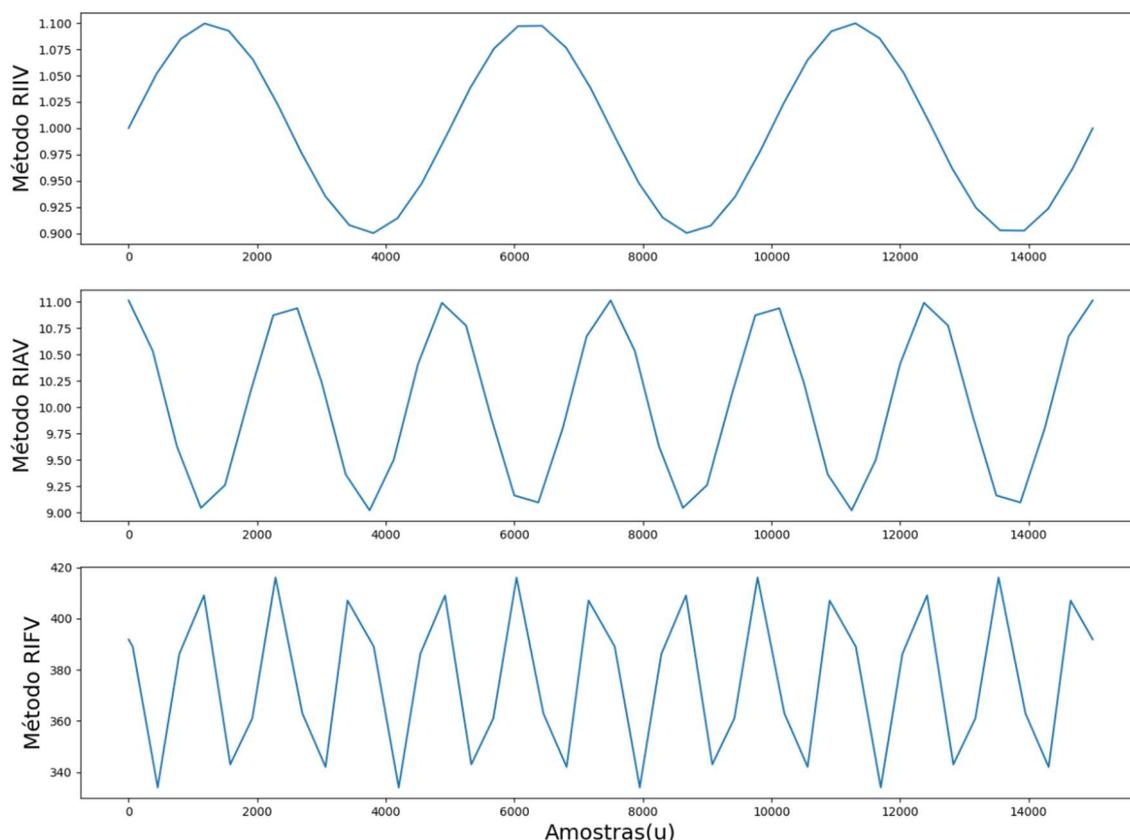


Figura 20. Sinais respiratórios dispostos no tempo extraídos pelos métodos RIIV (6 rpm), RIAV (12 rpm) e RIFV (24 rpm) (Fonte: Autor).

A FR pode ser obtida com uma análise no tempo ou frequência. A análise no tempo é alcançada pela contagem de picos ou vales do sinal. A análise na frequência requer a aplicação de uma FFT; neste caso, a FR é a frequência dominante do sinal gerado pela FFT dentro do espectro de FR de um ser humano. A FR medida pelos métodos das variações induzidas pela respiração segue as seguintes etapas:

- Extração das três variações de respiração induzidas no sinal de PPG, obtendo sinais respiratórios no tempo;
- Aplicação da FFT nos sinais respiratórios e seleção do pico de frequência dominante dentro do espectro da FR válida;
- Multiplicação das frequências dominantes por 60 para converter em “rpm”.

Inserimos nos três métodos propostos um índice de qualidade do sinal (IQS), pelo cálculo da diferença entre o número de picos e vales presentes no sinal de PPG. Apenas sinais com diferença igual ou inferior a 2 foram considerados para serem analisados; i.e., amostras com diferença superior a 2 foram descartadas, por serem consideradas amostras prejudicadas por artefatos. O IQS empregado é um valor empírico, baseado em dados obtidos da literatura [25][45].

5.4 Fusão de estimativas de FR - Método de Fusão

A fusão de estimativas de FR complementa os métodos que analisam as variações do sinal de PPG induzidas pela respiração. Este método ordena de forma crescente os valores de FR obtidos pelos métodos RIIV, RIAV e RIFV, criando um vetor de três posições, contendo os valores menor (*min*), intermediário (*itr*) e maior (*max*), e considera um *erro* (ε) entre estes valores para determinar a regra de fusão.

A determinação do valor do *erro* é empírica, sendo que para este trabalho, esta determinação foi baseada no intervalo de valores contidos nos bancos de dados BIMDC e CapnoBase – ambos empregados nos resultados experimentais. Estes bancos de dados apresentam um intervalo com 36 valores, sendo 42 rpm e 6 rpm o maior e menor valor de FR encontrados, respectivamente. Considerando este intervalo de 36 valores e o *erro* sendo um

inteiro menor ou igual a 10% do intervalo, obtemos $\varepsilon = [3,6 \text{ rpm}] = 3 \text{ rpm}$.

A fusão das estimativas de frequência respiratória é construída empregando as seguintes condições e considerando a ordenação das mesmas:

$$FR = \begin{cases} |min - max| \leq \varepsilon & \frac{min + itr + max}{3} \\ |min - itr| \leq \varepsilon & \frac{min + itr}{2} \\ |itr - max| \leq \varepsilon & \frac{itr + max}{2} \\ \text{senão} & \text{não avaliada} \end{cases}$$

- Caso a diferença entre o menor e o maior valor do vetor seja menor ou igual ao *erro*, então a FR é igual a média dos três valores. O motivo aqui é supor que se as três amostragens são próximas, então estas devem estar próximas do valor real de FR;
- Caso a diferença entre o menor e o valor intermediário seja menor ou igual ao *erro*, então a FR é igual a média desses dois valores. O motivo desta escolha é privilegiar as duas amostras que estão mais próximas, caso o primeiro critério não tenha sido satisfeito;
- Caso a diferença entre o valor intermediário e o maior valor seja menor ou igual ao *erro*, então a FR é igual a média desses dois valores. Este caso é equivalente ao anterior, mas agora considerando as amostras intermediárias e máxima;
- Caso as condições acima não sejam satisfeitas, a FR não é medida. Como não há consenso sobre qual é a melhor estimativa, o método caracteriza a amostra como sinal ruidoso e o valor de estimativa é descartado. Em uma situação extrema, onde esta condição ocorre em todas as amostras, a frequência respiratória não pode ser mensurada.

6. RESULTADOS EXPERIMENTAIS

Este capítulo apresenta resultados de experimentos obtidos com análises dos seis métodos implementados para extrair a frequência respiratória; estas análises utilizaram informações dos sinais de Fotopletismografia (PPG) contidos nos bancos de dados Synthetic Dataset, CapnoBase e BIDMC.

6.1 Descrição Sucinta dos Bancos de Dados

Synthetic Dataset [24] é um banco de dados criado no projeto *Respiratory Rate Estimation* que contém sinais sintéticos de ECG e PPG. Esses sinais foram desenvolvidos para verificar o desempenho de métodos para estimar a FR frente a um cenário que não contém ruídos externos. O conjunto de dados inclui sinais de PPG na faixa de FR entre 4 e 60 rpm, sendo modulados isoladamente em relação à linha de base, amplitude e frequência. Contudo, o Synthetic Dataset não dispõe de sinais de PPG influenciados por duas ou mais variações da respiração juntas; por este motivo, não foi avaliado o Método de Fusão com este banco de dados. O “Apêndice A – RRest-syn Dataset” contém informações complementares do Synthetic Dataset.

O conjunto de dados CapnoBase [5] contém dados de ECG, oximetria de pulso com PPG e CO₂ de 42 casos, sendo cada caso descrito por uma gravação de 8 minutos. Além disso, o CapnoBase disponibiliza a FR aferida de cada indivíduo, permitindo avaliar o desempenho dos métodos empregados; informações complementares estão disponíveis no “Apêndice B - CapnoBase IEEE TBME Respiratory Rate Benchmark”.

BIDMC [6] é um conjunto de dados usado para avaliar o desempenho de métodos de FR, contendo informações de ECG, oximetria de pulso por PPG e sinais respiratórios de pneumografia de impedância. Todos estes sinais foram adquiridos de 53 pacientes de terapia intensiva, com duração de gravações de 8 minutos para cada paciente; informações complementares do banco de dados estão disponíveis no “Apêndice C - BIDMC PPG and Respiration Dataset”.

6.2 Resultados Experimentais Obtidos com Dados Sintéticos

Esta seção descreve os resultados obtidos com o Synthetic Dataset [24]. Todas as tabelas apresentadas nesta seção destacam em “verde” erros absolutos com valor igual a 0.

6.2.1 CONFIGURAÇÃO DOS EXPERIMENTOS COM DADOS SINTÉTICOS

A Figura 21 apresenta as configurações realizadas para obtenção dos dados experimentais. Iniciando pela obtenção das curvas PPG de 29 “pessoas sintéticas”, as modulações RIIV, RIAV e RIAF obtidas de forma isolada para cada pessoa. Desta forma, Synthetic Dataset provê 87 amostras de sinais de PPG, cada amostra com 90s. Com o objetivo de avaliar a qualidade de cada método frente ao tamanho da janela de observação, fizemos uma divisão do sinal em passos de 10 s, resultado nove passos de observação, que implicaram 783 avaliações para cada método que estima a frequência respiratória. No total, os experimentos com dados sintéticos resultaram 3915 estimativas de frequência respiratória, que foram avaliadas ao comparar com valores de referência providos pelo banco de dados.

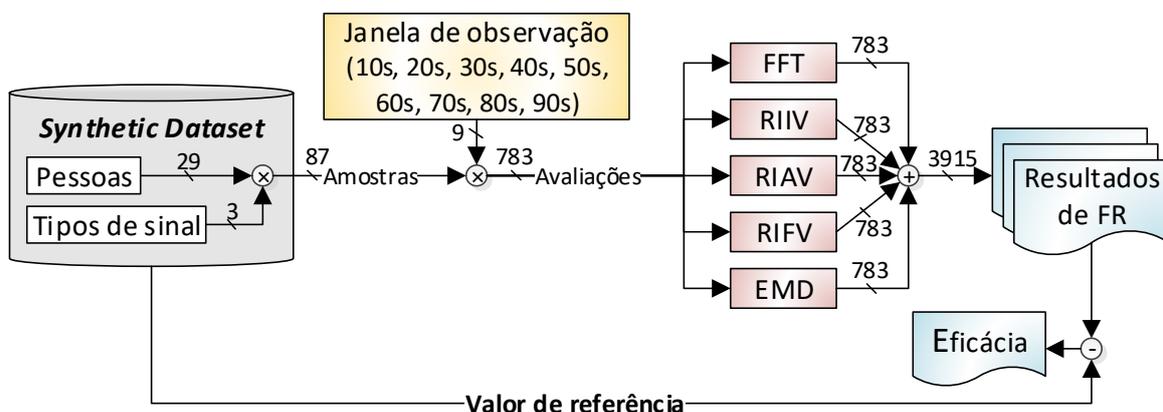


Figura 21. Etapas das análises de eficácia dos métodos de estimativa de frequência respiratória realizadas sobre os dados contidos no Synthetic Dataset (Fonte: Autor).

6.2.2 RESULTADOS EXPERIMENTAIS OBTIDOS COM DADOS SINTÉTICOS

Os métodos que estimam a frequência respiratória requerem um certo número de amostras para obter uma medida representativa. Este número de amostras implica no tempo que o dispositivo deve ficar conectado antes de

prover a primeira avaliação de FR. Desta forma, a Seção 6.2.2.1 utiliza o banco de dados sintético para avaliar a partir de qual tamanho de janela de observação é possível considerar que os dados obtidos são representativos.

Os demais experimentos desta seção objetivam avaliar as eficácias dos métodos FFT, RIIV, RIAV, RIFV e EMD na estimativa de frequência respiratória, considerando sinais de PPG modelando a respiração em linha de base, amplitude e frequência. Para tanto, as Seções 6.2.2.2 e 6.2.2.4 apresentam as análises em separado dos Métodos FFT e EMD, respectivamente, enquanto que a Seção 6.2.2.3 agrupa os resultados dos Métodos RIIV, RIAV e RIFV.

6.2.2.1 Avaliação da Janela de Observação na Eficácia das Estimativas

O Synthetic Dataset contém sinais PPG equacionados matematicamente, não compreendendo interferências externas durante sua construção. A Figura 22 exemplifica os sinais de PPG presentes no banco de dados, com uma frequência respiratória de 16 rpm modulada em intensidade (RIIV), amplitude (RIAV) e frequência (RIFV), sobre uma onda de frequência cardíaca de 80 bpm.

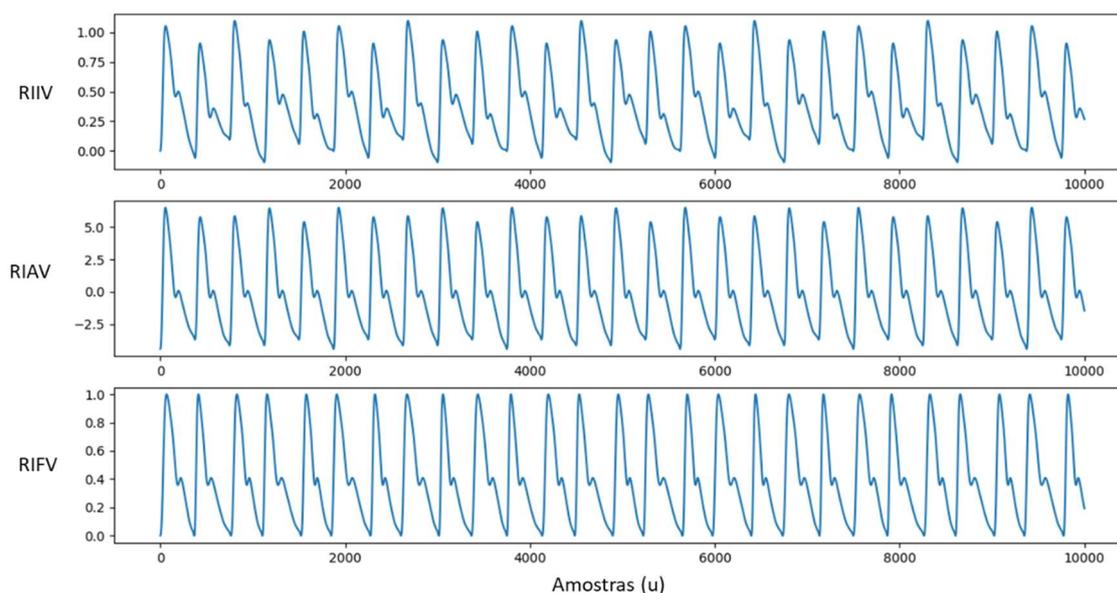


Figura 22. Sinais de PPG presentes no banco de dados sintéticos, com modulação em intensidade, amplitude e frequência (Fonte: Autor).

Tendo em vista a pureza dos sinais de PPG presentes no banco de dados, conseguimos obter informações precisas da influência entre o tamanho da janela utilizada para mensurar a frequência respiratória e, bem como do desempenho dos métodos abordados para modulações isoladas de RIIV, RIAV e RIFV.

A Tabela 2, apresenta os resultados obtidos com o Método FFT aplicado a um sinal de PPG modulado com RIIV, quando variado a janela de observação de 10 em 10 s.

TABELA 2. VARIAÇÃO DO ERRO DE ESTIMATIVA DE FREQUÊNCIA RESPIRATÓRIA COM O TAMANHO DA JANELA DE OBSERVAÇÃO. OS RESULTADOS FORAM OBTIDOS COM O MÉTODO FFT E UM SINAL DE PPG MODULADO EM RIIV.

FR de referência	10s		20s		30s		40s		50s		60s		70s		80s		90s	
	FR medida	Erro absoluto																
4	6	2	3	1	4	0	5	1	4	0	4	0	4	0	4	0	4	0
6	6	0	6	0	6	0	6	0	6	0	6	0	6	0	6	0	6	0
8	6	2	9	1	8	0	8	0	8	0	8	0	8	0	8	0	8	0
10	12	2	9	1	10	0	11	1	10	0	10	0	10	0	10	0	10	0
12	12	0	12	0	12	0	12	0	12	0	12	0	12	0	12	0	12	0
14	12	2	15	1	14	0	14	0	14	0	14	0	14	0	14	0	14	0
16	18	2	15	1	16	0	16	0	16	0	16	0	16	0	16	0	16	0
18	18	0	18	0	18	0	18	0	18	0	18	0	18	0	18	0	18	0
20	18	2	21	1	20	0	20	0	20	0	20	0	20	0	20	0	20	0
22	24	2	21	1	22	0	22	0	22	0	22	0	22	0	22	0	22	0
24	24	0	24	0	24	0	24	0	24	0	24	0	24	0	24	0	24	0
26	24	2	27	1	26	0	26	0	26	0	26	0	26	0	26	0	26	0
28	30	2	27	1	28	0	29	1	28	0	28	0	28	0	28	0	28	0
30	30	0	30	0	30	0	30	0	30	0	30	0	30	0	30	0	30	0
32	30	2	33	1	32	0	32	0	32	0	32	0	32	0	32	0	32	0
34	36	2	33	1	34	0	35	1	34	0	34	0	34	0	34	0	34	0
36	36	0	36	0	36	0	36	0	36	0	36	0	36	0	36	0	36	0
38	36	2	39	1	38	0	38	0	38	0	38	0	38	0	38	0	38	0
40	42	2	39	1	40	0	40	0	40	0	40	0	40	0	40	0	40	0
42	42	0	42	0	42	0	42	0	42	0	42	0	42	0	42	0	42	0
44	42	2	45	1	44	0	44	0	44	0	44	0	44	0	44	0	44	0
46	48	2	45	1	46	0	46	0	46	0	46	0	46	0	46	0	46	0
48	48	0	48	0	48	0	48	0	48	0	48	0	48	0	48	0	48	0
50	48	2	51	1	50	0	50	0	50	0	50	0	50	0	50	0	50	0
52	54	2	51	1	52	0	52	0	52	0	52	0	52	0	52	0	52	0
54	54	0	54	0	54	0	54	0	54	0	54	0	54	0	54	0	54	0
56	54	2	57	1	56	0	56	0	56	0	56	0	56	0	56	0	56	0
58	60	2	57	1	58	0	59	1	58	0	58	0	58	0	58	0	58	0
60	60	0	60	0	60	0	60	0	60	0	60	0	60	0	60	0	60	0

O comprimento inicial da janela de observação foi selecionado empiricamente sendo igual a 10 s. O valor inicial foi considerado como a “menor janela” de observação possível para mensurar a frequência respiratória. Posteriormente foi acrescentado um valor equivalente a “menor janela” para encontrar um tamanho de janela de observação em que o erro absoluto entre o valor de referência e o valor estimado permanecesse inalterado. Este é o ponto considerado como a janela mínima de precisão; janelas de observação

superiores não devem sofrer alterações nos resultados de frequência respiratória devido à subamostragem de dados.

Todos os métodos analisados nesta seção apresentaram valores estáveis e com erro absoluto igual a zero para janelas de observação maiores de 50 s. A janela de observação de 10 s foi a única que apresentou erro absoluto igual a 2 rpm, sendo considerado o maior erro encontrado e a janela de 30 s apresentou erro absoluto igual a zero igual as janelas superiores e iguais a 50 s.

Entendemos que algumas estimativas obtidas com 40 s foram piores que as estimativas de 30 s devido ao sinal ser sintético e preciso de forma que a multiplicidade de 40 s gera erro de precisão para a amostra de 500 Hz utilizada no banco de dados. Este achado foi essencial para compreender a influência da taxa de amostragem na obtenção da melhor janela de observação. Adicionalmente, este achado indica que não é possível definir um valor ótimo de janela de observação; este valor depende essencialmente do sinal de PPG.

6.2.2.2 Avaliação do Método FFT para as Modulações RIIV, RIAV e RIFV

Esta seção avalia a eficácia do Método FFT para estimar FR com o sinal de PPG com a frequência respiratória modelada em intensidade (RIIV), amplitude (RIAV) e frequência (RIFV). Para este estudo, estamos considerando apenas a janela de observação de 30 s, visto que este tamanho é adequado para este banco de dados sintético. A Tabela 3 mostra os valores de FR estimados e os erros absolutos quando comparados com a primeira coluna, contendo os valores de referência.

O erro absoluto mostra que o Método FFT alcança resultados ótimos ao estimar a FR quando o sinal respiratório é modulado com RIIV, este ótimo ocorre para todo o intervalo de amostragem observado. Por outro lado, a FFT não consegue capturar as variações de amplitude e frequência, de forma que as estimativas medidas não têm significado fisiológico.

TABELA 3. ESTIMATIVA DE FREQUÊNCIA RESPIRATÓRIA OBTIDA COM O MÉTODO FFT, CONSIDERANDO MODULAÇÕES RIIV, RIAV E RIAF EM SINAIS DE PPG.

FR de referência	Linha de base		Amplitude		Frequência	
	FR medida	Erro absoluto	FR medida	Erro absoluto	FR medida	Erro absoluto
4	4	0	4	0	64	60
6	6	0	6	0	62	56
8	8	0	4	4	64	56
10	10	0	4	6	60	50
12	12	0	4	8	56	44
14	14	0	4	10	52	38
16	16	0	64	48	64	48
18	18	0	62	44	62	44
20	20	0	60	40	60	40
22	22	0	58	36	58	36
24	24	0	56	32	56	32
26	26	0	54	28	54	28
28	28	0	52	24	52	24
30	30	0	50	20	50	20
32	32	0	48	16	48	16
34	34	0	46	12	46	12
36	36	0	44	8	44	8
38	38	0	42	4	42	4
40	40	0	40	0	40	0
42	42	0	38	4	38	4
44	44	0	36	8	36	8
46	46	0	34	12	34	12
48	48	0	32	16	32	16
50	50	0	30	20	30	20
52	52	0	28	24	28	24
54	54	0	26	28	26	28
56	56	0	24	32	24	32
58	58	0	22	36	22	36
60	60	0	20	40	20	40

6.2.2.3 Avaliação dos Métodos RIIV, RIAV e RIFV para o Sinal de PPG Modulado em Linha de Base, Amplitude e Frequência

A Tabela 4 compara os três métodos desenvolvidos para capturar as variações induzidas pela respiração no sinal de PPG, considerando que este foi modulado em linha de base, amplitude e frequência. Em princípio, os métodos RIIV, RIAV e RIFV deveriam ter melhores resultados nas modulações de linha de base, amplitude e frequência, respectivamente, uma vez que foram desenvolvidos com este intuito. Todavia, os resultados mostram que os métodos RIIV e RIAV obtiveram resultados muito próximos para as modulações em linha de base e amplitude. Adicionalmente, ambos os métodos apresentam erros absolutos altos para a modulação em frequência, com uma pequena vantagem, em média, para o método RIIV.

A Tabela 4 deixa claro que apenas o Método RIFV consegue capturar a modulação em frequência. Adicionalmente, independente da modulação, o método RIFV estima corretamente a FR para o intervalo [20 rpm, 38 rpm] (equivalendo a [0,333 Hz, 0,633 H]), evidenciando que as modelagens de linha de base e amplitude permitem capturar componentes de frequência médias do sinal respiratório.

TABELA 4. ESTIMATIVAS DA FREQUÊNCIA RESPIRATÓRIA CALCULADAS PELOS MÉTODOS RIIV, RIAV E RIFV, CONSIDERANDO SINAIS DE PPG MODELADOS EM LINHA DE BASE, AMPLITUDE E FREQUÊNCIA.

FR de referência	Método RIIV						Método RIAV						Método RIFV					
	Linha de base		Amplitude		Frequência		Linha de base		Amplitude		Frequência		Linha de base		Amplitude		Frequência	
	FR medida	Erro absoluto	FR medida	Erro absoluto	FR medida	Erro absoluto	FR medida	Erro absoluto	FR medida	Erro absoluto	FR medida	Erro absoluto	FR medida	Erro absoluto	FR medida	Erro absoluto	FR medida	Erro absoluto
4	4	0	4	0	8	4	4	0	4	0	16	12	10	6	10	6	4	0
6	6	0	6	0	28	22	6	0	6	0	24	18	10	4	10	4	6	0
8	8	0	8	0	16	8	8	0	8	0	32	24	10	2	10	2	8	0
10	10	0	10	0	40	30	10	0	10	0	40	30	20	10	10	0	10	0
12	12	0	12	0	40	28	12	0	12	0	16	4	24	12	10	2	12	0
14	14	0	14	0	20	6	14	0	14	0	24	10	14	0	10	4	14	0
16	16	0	16	0	16	0	16	0	16	0	16	0	32	16	10	6	16	0
18	18	0	18	0	4	14	18	0	18	0	8	10	18	0	10	8	18	0
20	20	0	20	0	20	0	20	0	20	0	40	20	20	0	20	0	20	0
22	22	0	22	0	4	18	22	0	22	0	8	14	22	0	22	0	22	0
24	24	0	24	0	16	8	24	0	24	0	16	8	24	0	24	0	24	0
26	26	0	26	0	20	6	26	0	26	0	12	14	26	0	26	0	26	0
28	28	0	28	0	8	20	28	0	28	0	16	12	28	0	28	0	28	0
30	30	0	30	0	10	20	30	0	30	0	20	10	30	0	30	0	30	0
32	32	0	32	0	16	16	32	0	32	0	16	16	32	0	32	0	32	0
34	34	0	34	0	28	6	34	0	34	0	20	14	34	0	34	0	34	0
36	36	0	36	0	24	12	36	0	36	0	16	20	36	0	36	0	36	0
38	38	0	38	0	16	22	38	0	38	0	20	18	38	0	38	0	38	0
40	40	0	40	0	40	0	40	0	40	0	40	0	40	0	10	30	40	0
42	38	4	38	4	16	26	38	4	38	4	20	22	38	4	38	4	38	4
44	36	8	36	8	24	20	36	8	36	8	16	28	36	8	36	8	36	8
46	34	12	34	12	12	34	34	12	34	12	20	26	34	12	34	12	34	12
48	32	16	32	16	16	32	32	16	32	16	16	32	32	16	32	16	32	16
50	30	20	30	20	20	30	30	20	30	20	20	30	30	20	30	20	30	20
52	28	24	28	24	16	36	28	24	28	24	8	44	28	24	28	24	28	24
54	26	28	26	28	26	28	26	28	26	28	20	34	26	28	26	28	26	28
56	24	32	24	32	16	40	24	32	24	32	32	24	24	32	24	32	24	32
58	22	36	22	36	22	36	22	36	22	36	20	38	22	36	22	36	22	36
60	20	40	20	40	20	40	20	40	20	40	40	20	20	40	20	40	20	40

Ao analisarmos os três métodos em conjunto, independente da modulação, notamos que os erros absolutos encontrados tornam as estimativas inválidas para FRs iguais ou superiores a 42 rpm. Desta forma, a Tabela 4 ilustra que dentro do intervalo de FR avaliado, existem três subintervalos com dados

relacionados: (i) [4, 18] rpm – os métodos RIIV e RIAV obtêm resultados iguais e destoantes de RIFV; (ii) [20, 40] rpm – os três métodos obtêm resultados iguais; (iii) [42, 60] rpm – os três métodos obtêm estimativas normalmente distintas, mas igualmente ruins.

A análise dos subintervalos descritos acima indica um caminho para desenvolver um método de fusão que minimize erros de estimativas, bem como, desconsidere estimativas ruins. Por exemplo, caso os três métodos obtenham um valor muito próximo, a estimativa final de FR pode ser uma média das estimativas parciais. Caso os métodos RIIV e RIAV obtenham estimativas próximas, mas destoantes da estimativa do Método RIFV, devemos considerar apenas a média dos métodos RIIV e RIAV, descartando a estimativa de FR obtida com o Método RIFV. Por outro lado, caso a estimativa provida pelo Método RIFV seja muito próxima da estimativa resultante do Método RIIV, mas distante da estimativa obtida com o Método RIAV, ou vice-versa, as amostras devem ser desconsideradas. A razão desta última decisão é porque não existe intervalo com esta combinação. Os resultados obtidos com o Método de Fusão serão apresentados na Seção 6.3.

6.2.2.4 Avaliação do Método EMD para as Modulações de Linha de Base, Amplitude e Frequência

O último experimento realizado com o banco de dados sintético objetivou explorar o método de decomposição do modo empírico; dentre as IMFs obtidas no processo de decomposição, apenas a terceira apresentou sinais dentro intervalo respiratório de seres humanos. Os dados coletados pelo Método EMD mostraram consistência para respirações induzidas na linha de base e amplitude com espectro de FR de 6 rpm a 48 rpm (i.e., 0,1 0,8 Hz) e de 22 rpm a 40 rpm (i.e., 0,36 Hz a 0,66 Hz), respectivamente. Adicionalmente, é possível notar que as frequências de respiração intermediárias tendem a ter melhores resultados para as três modulações, de forma similar que ocorre com os métodos RIIV, RIAV e RIFV.

A Tabela 5 mostra o erro absoluto associado a cada frequência respiratória estimada pelo Método da EMD, sendo os valores destacados em verde relativos a estimativas precisas, com erro absoluto igual a 0 rpm.

TABELA 5. ESTIMATIVA DA FREQUÊNCIA RESPIRATÓRIA OBTIDA COM O MÉTODO EMD; SINAIS DE PPGs MODULADOS EM LINHA DE BASE, AMPLITUDE E FREQUÊNCIA.

FR de referência	Linha de base		Amplitude		Frequência	
	FR medida	Erro absoluto	FR medida	Erro absoluto	FR medida	Erro absoluto
4	40	36	4	0	32	28
6	6	0	8	2	32	26
8	6	2	6	2	32	24
10	10	0	8	2	40	30
12	12	0	12	0	32	20
14	14	0	16	2	36	22
16	16	0	38	22	32	16
18	18	0	24	6	38	20
20	20	0	40	20	40	20
22	22	0	22	0	28	6
24	24	0	24	0	40	16
26	26	0	26	0	26	0
28	28	0	28	0	28	0
30	30	0	30	0	40	10
32	32	0	32	0	48	16
34	34	0	34	0	34	0
36	36	0	36	0	44	8
38	38	0	38	0	42	4
40	40	0	40	0	40	0
42	42	0	38	4	38	4
44	44	0	36	8	36	8
46	46	0	34	12	34	12
48	48	0	32	16	32	16
50	40	10	30	20	30	20
52	52	0	28	24	28	24
54	28	26	26	28	26	28
56	48	8	24	32	24	32
58	36	22	22	36	22	36
60	40	20	40	20	20	40

6.2.3 INTEGRAÇÃO DOS DADOS E CONCLUSÕES PARCIAIS

Nesta seção integramos os resultados apresentados na Seção 6.2.2, salientando as eficácias dos métodos e os efeitos das modulações através da Figura 23, Figura 24 e Figura 25.

A Figura 23 emprega gráficos do tipo radar com valores dos erros absolutos de cada método frente às modulações de linha de base, amplitude e frequência. Esta figura permite avaliar qual a modulação que gera os maiores erros de estimativas de FR, pela área interna definida por cada linha de modulação.

A Figura 23(a) deixa claro que, para o intervalo de FR de 4 rpm a 60 rpm, a área da figura relativa à modulação em frequência é superior a área da modulação em amplitude, que por sua vez é superior a área da modulação em

linha de base; i.e., a modulação de linha de base permite uma melhor captura global das estimativas de FR – a exceção ocorre apenas para o Método RIFV.

Adicionalmente, a Figura 23(b) apresenta dados mais restritos, contendo apenas o intervalo de FR de 4 rpm a 40 rpm, visto que a partir de 42 rpm, a maior parte dos métodos obtém estimativas ruins. Esta nova figura mostra uma redução média das áreas de erro, a relação entre os erros causados pelas modulações permanece; sendo que a área relativa a figura gerada pela modulação de linha de base é praticamente zerada.

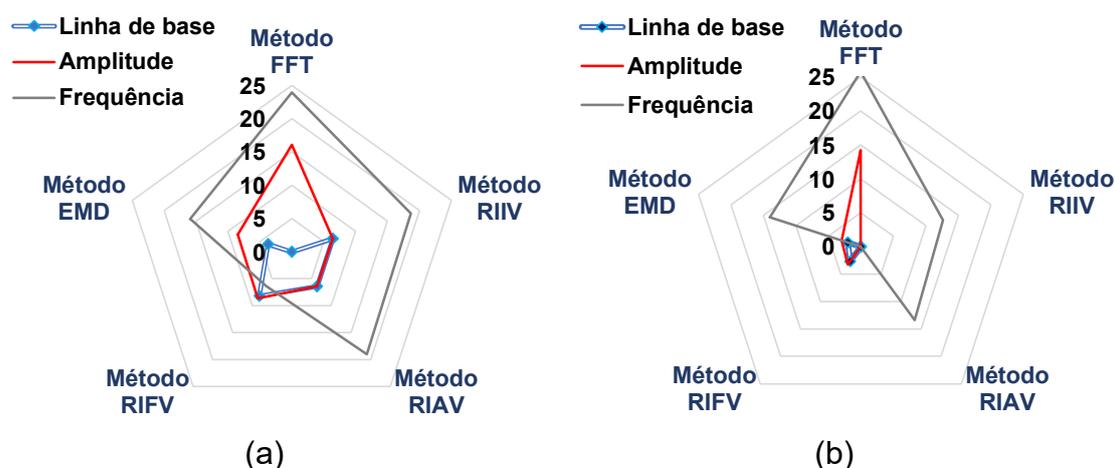


Figura 23. Avaliação do erro **absoluto** ocasionado pelas modulações em linha de base, amplitude e frequência nos métodos FFT, RIIV, RIAV, RIFV e EMD. Intervalo de FR em (a) [4, 60] e (b) [4, 40] (Fonte: Autor).

A Figura 24 apresenta resultados que se assemelham aos resultados da Figura 23(a); contudo, os erros apresentados aqui são relativos e não absolutos. O objetivo é verificar se os resultados de forma relativa são aceitáveis, já que, por exemplo, um erro de 2 rpm para 20 rpm significa 10%, o que pode ser tolerado, mas para 4 rpm representa 50%.

A análise de ambas as figuras mostra que os erros relativos e absolutos são “relativamente” similares em relação às modulações de linha de base, amplitude e frequência. Contudo, a Figura 24 chama a atenção que apenas para a modulação de linha de base, os erros relativos podem entrar em uma faixa de aceitáveis, em média, pois são inferiores a 20%; enquanto a modulação em frequência chega a alcançar erros relativos médios de mais de 140%.

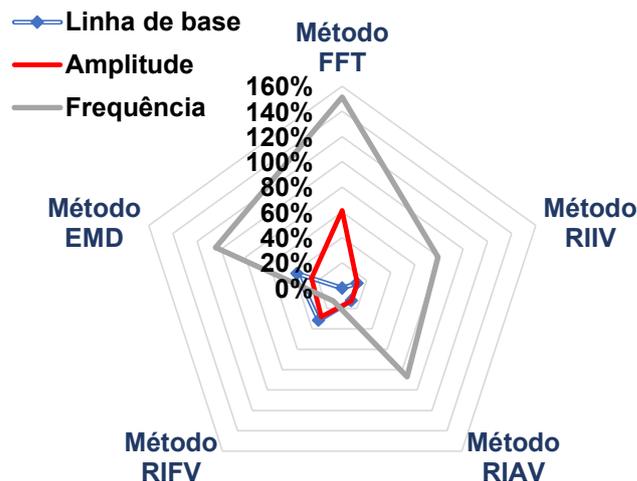


Figura 24. Avaliação do erro **relativo** ocasionado pelas modulações em linha de base, amplitude e frequência nos métodos FFT, RIIV, RIAV, RIFV e EMD. Intervalo de FR em [4, 60] (Fonte: Autor).

O objetivo da Figura 25 é avaliar o quanto cada modulação afeta a eficácia de cada método avaliado, bem como verificar qual o método que tem melhores resultados em média. Note que os valores dos métodos RIIV e RIAV são praticamente os mesmos, de forma que as figuras geométricas são sobrepostas.

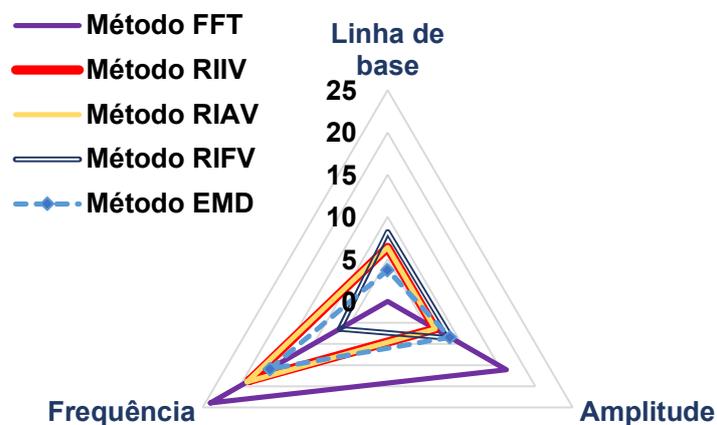


Figura 25. Avaliação do erro **absoluto** dos métodos FFT, RIIV, RIAV, RIFV e EMD frente devido às modulações de linha de base, amplitude e frequência. Intervalo de FR em [4, 60] (Fonte: Autor).

Embora o Método FFT produza resultados ótimos para a modulação em linha de base, ele gera a maior área de erros, apresentando os piores resultados com relação à modulação em frequência. Por outro lado, embora o Método RIFV não obtém os melhores resultados para nenhuma modulação, ele alcança a menor área média de erros entre todos os métodos aqui apresentados. Por fim, as áreas dos métodos RIAV, RIFV e EMD são praticamente as mesmas,

mostrando um potencial similar para alcançar as estimativas de erro.

6.3 Resultados Experimentais Obtidos com Dados Reais

Esta seção descreve os resultados referentes a estimativas de frequência respiratória obtidos com os bancos de dados CapnoBase [5] e BIDMC [6] quando aplicado os seis métodos presentes neste trabalho. A grande diferença da seção anterior está no fato dos dados do CapnoBase e BIDMC conterem artefatos e modulações conjuntas das características fisiológicas da respiração.

6.3.1 CONFIGURAÇÃO DOS EXPERIMENTOS COM DADOS REAIS

A Figura 26 apresenta as configurações realizadas para obtenção dos dados experimentais. Os bancos de dados CapnoBase e BIDMC passaram por um processo de equalização com o objetivo de obter valores de referência da FR consistentes em todo o intervalo de amostragem – A Seção 6.3.2 detalha o processo de equalização. A equalização gerou os bancos denominados CapnoBase* e BIDMC*, que contém dados sensoriais de 42 e 53 pessoas, respectivamente; estes dados correspondem a 95 sinais de PPG, cada um com 360 s de amostragem.

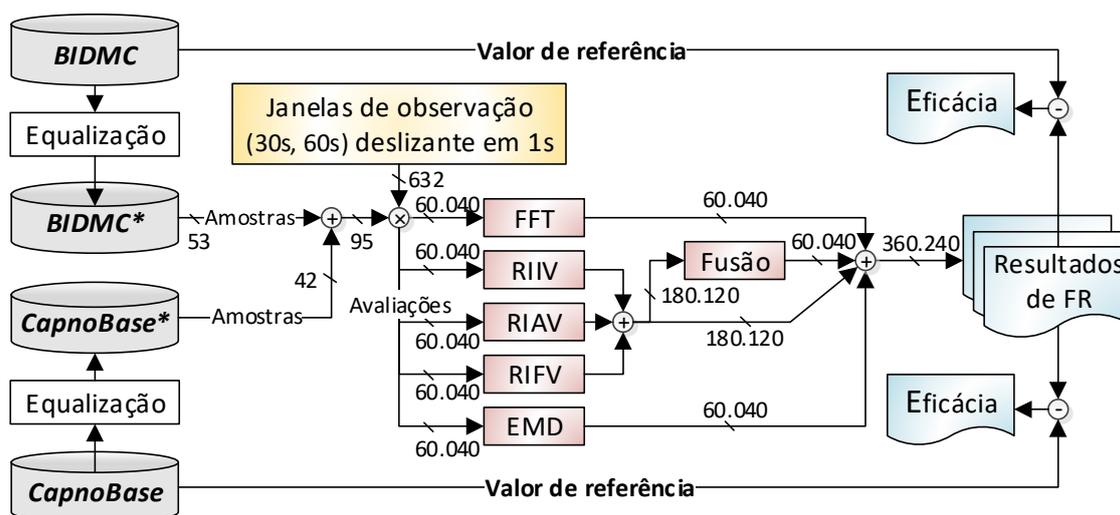


Figura 26. Etapas da análise realizada no banco de dados reais (Fonte: Autor).

Estas amostras, por sua vez, foram avaliadas pelos métodos FFT, RIIV, RIAV, RIFV, EMD e Fusão em janelas deslizantes de observação de 30 s e 60 s. O motivo de empregarmos mais de um tamanho de janela de observação foi

discutido na Seção 6.2.2.1; para dados reais, os efeitos de variação de janela que foram observados podem ser ainda mais salientes. Adicionalmente, optamos por utilizar janelas deslizantes com base de 1 s, de forma a suavizar a passagem de uma amostragem para outra – esta abordagem também foi adotada no trabalho de Fikriastuti e Muhaimin [40] (Seção 4.14). A utilização de uma janela deslizante de 1 s, dentro do intervalo de 360 s, implicou 331 e 301 amostras para as janelas de observação de 30 s e 60 s, respectivamente. Escolhemos trabalhar com apenas seis minutos (360 s) dos bancos de dados que contêm amostras de oito minutos, removendo o minuto inicial e final de cada paciente; essa escolha foi feita empiricamente, com o intuito de remover as bordas dos bancos de dados e eliminar possíveis medições errôneas.

No total, resulta em 632 janelas de observação para cada um dos 95 sinais de PPG; conseqüentemente, 60.040 avaliações que devem ser feitas por cinco dos seis métodos propostos – exceção do Método de Fusão que tem como entrada os resultados dos métodos RIIV, RIAV e RIFV. A execução de todos os experimentos resulta em 360.240 estimativas de frequência respiratória, cujo erro absoluto e correspondente eficácia são avaliados comparando com os valores de referência inclusos nos bancos de dados CapnoBase e BIDMC.

Os métodos RIIV, RIAV e RIFV avaliam o IQS quando comparam a quantidade de picos e vales presentes em cada amostra, conforme apresentado na Seção 5.3. A execução destes métodos implicou na remoção de 941 e 1087 amostras para frames de 30 s e 60 s do banco de dados BIDMC, respectivamente, enquanto o CapnoBase não teve amostras descartadas. Esta avaliação evidencia que o BIDMC contém sinais muito mais ruidosos que os presentes no CapnoBase, sendo um indicativo para redução na eficácia dos métodos de inferência da frequência respiratória.

O Método Fusão avalia a qualidade do sinal quando integra os três valores de FR obtidos, conforme abordado na Seção 5.4. Ao executar este método sobre os dados do CapnoBase resultou na remoção de 800 e 399 amostras, para janelas de observação de 30 s e 60 s, respectivamente. Analogamente, o BIDMC teve 3.222 e 2.504 amostras removidas, para janelas de observação de 30 s e 60 s, respectivamente. Esta remoção não está diretamente relacionada com os ruídos presentes no banco de dados, mas sim, com a discrepância existente entre os métodos RIIV, RIAV e RIFV, que não permitiram ao Método de Fusão a

escolha de qual a melhor estimativa a ser tomada. Adicionalmente, como consequência destas remoções, todas as análises percentuais apresentadas nesta seção subtraem para os Métodos RIIV, RIAV, RIFV e Fusão as amostras classificadas como ruidosas da quantidade total de amostras.

6.3.2 EQUALIZAÇÃO DOS BANCOS DE DADOS CAPNOBASE E BIDMC

Os dois bancos de dados informam que contém as frequências respiratórias de referência para cada sinal de PPG. Entretanto, os valores de referência para aferir a frequência respiratória do CapnoBase, em alguns casos estavam presentes apenas no intervalo de 7 s a 72 s ou intervalos menores; enquanto cada paciente tem um total de 480 s (8 min) para armazenar o sinal de PPG e seu respectivo sinal respiratório de referência (CO_2), tal como pode ser observado na Figura 27.

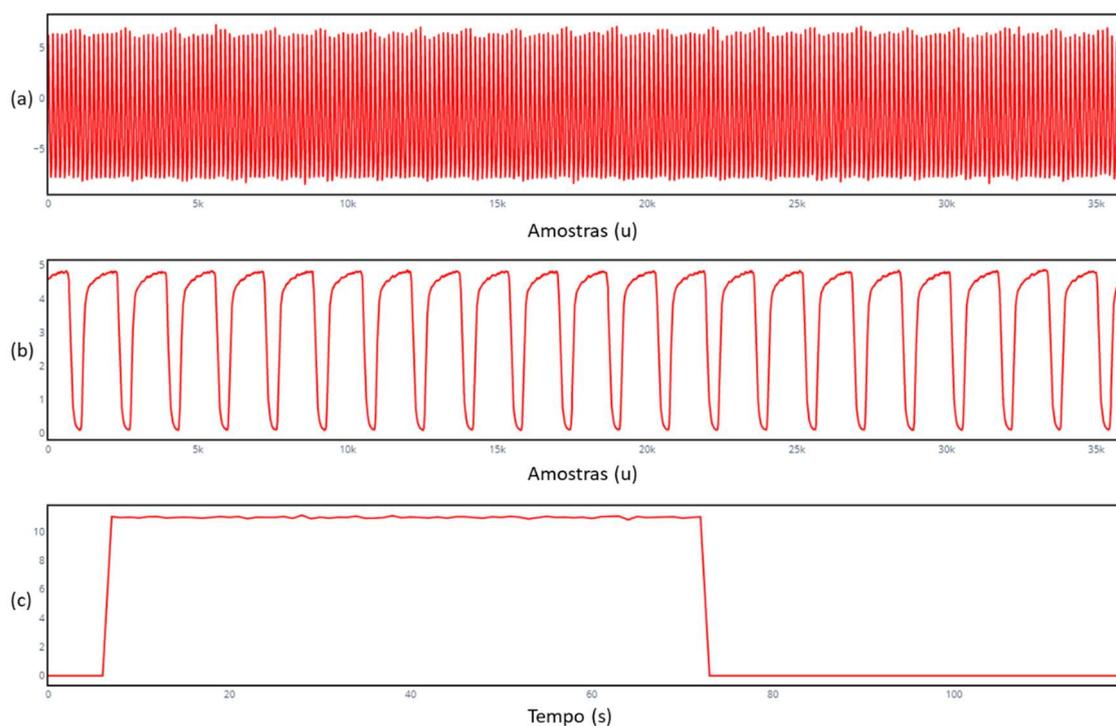


Figura 27. Exemplo de dados de um paciente do banco de dados CapnoBase contendo (a) sinal de PPG, (b) sinal respiratório de referência (CO_2), e (c) valores de referência da frequência respiratória. A amostragem está cortada em 120 s para facilitar a visualização (Fonte: Autor).

Para podermos obter os valores de referência da FR em todo o intervalo de 360 s explorado no banco de dados, aplicamos uma FFT sobre o sinal de CO_2 . Com o intuito de manter similaridade na análise dos dois bancos de dados,

aplicamos o mesmo procedimento no sinal de Impedância presente no banco de dados BIDMC. Este processo em ambos os bancos de dados foi denominado Equalização (ver Figura 26). Contudo, a abordagem de Equalização pode falhar quando a janela analisada contém ruídos que se sobrepõem ao sinal respiratório, tal como ilustrado na Figura 28. Uma vez que sinal respiratório não é avaliado corretamente, as estimativas de FR provavelmente sofrerão desvios que podem alterar a análise das eficácias dos métodos avaliados.

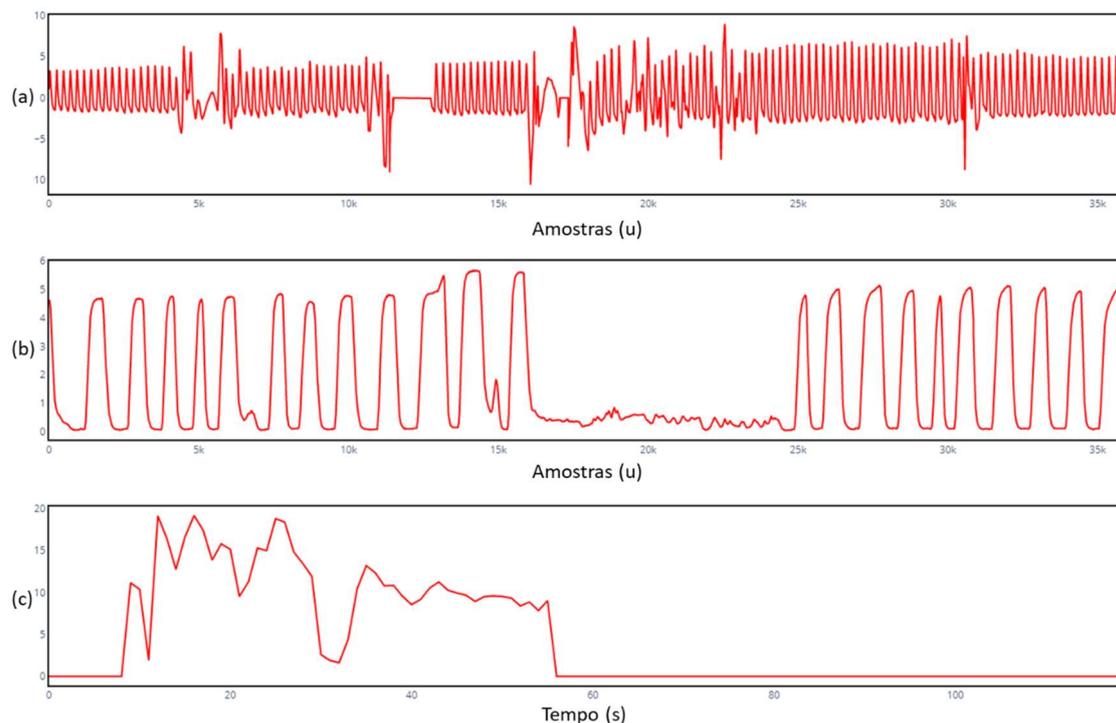


Figura 28. Exemplo de dados de um paciente do banco de dados CapnoBase contendo um forte ruído que se sobrepõe aos sinais de (a) PPG e (b) CO₂, bem como aos (c) valores de referência da FR (Fonte: Autor).

6.3.3 RESULTADOS EXPERIMENTAIS OBTIDOS COM DADOS SINTÉTICOS

O intervalo de frequência respiratória compreendido dos bandos de dados CapnoBase e BIDMC está entre 6 rpm e 42 rpm (0,1 Hz -0,7 Hz); i.e., é uma faixa de FR que está contida dentro do intervalo de FR provida pelo Synthetic Dataset. Adicionalmente, embora tenha sido realizado um experimento com o Synthetic Dataset para descobrir qual a melhor janela de observação, nos experimentos com dados reais decidimos avaliar dois tamanhos de janela, pois as variabilidades contidas nos bancos de dados podem gerar artefatos que podem ser minimizados em janelas maiores. Além do mais, as janelas aqui

observadas são deslizantes com passos de 1 s. Por fim, escolhemos trabalhar com apenas seis minutos (360 s) dos bancos de dados que contém amostras de oito minutos, sendo que o minuto inicial e final de cada paciente foi descartado.

A Figura 29 apresenta o erro percentual médio obtido com cada método avaliado, considerando dados providos pelo CapnoBase, para ambas as janelas de observação.

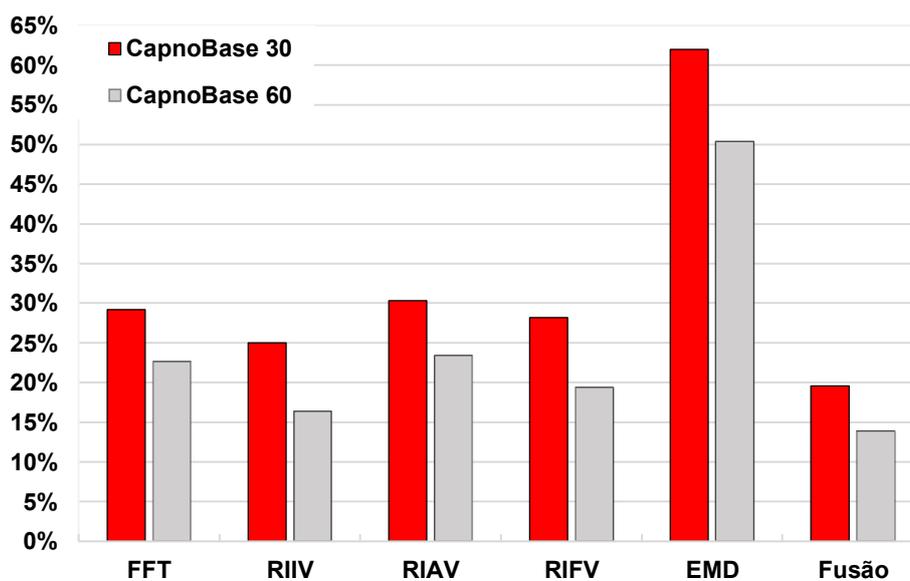


Figura 29. Erro percentual médio obtido para os métodos FFT, RIIV, RIAV, RIFV, EMD e Fusão, utilizando dados do CapnoBase e janelas de observação deslizantes de 30 s e 60 s (Fonte: Autor).

A análise dos resultados mostra que é uma variação média de praticamente 10% de erro com a redução da janela de observação. Efeito que não era observado nos dados sintéticos, mas que indica que os métodos propostos tendem a melhorar as estimativas de frequência com o aumento da janela de observação, quando trabalham com dados reais. Adicionalmente, o Método de Fusão obtém os melhores resultados, conseguindo melhorar a qualidade das estimativas que são obtidas com os métodos RIIV, RIAV e RIFV. Por fim, o Método EMD apresenta estimativas bastante ruins de FR.

A Figura 30 é complementar a Figura 29, apresentando o erro percentual médio resultante de cada método avaliado, considerando dados providos pelo BIDMC com janelas de observação de 30 s e 60 s.

Os resultados ilustrados na Figura 30 indicam que existem muitas diferenças nos dados contidos nos bancos de dados. Exemplos evidentes são o Método de Fusão, que não obteve os melhores resultados para o banco de

dados BIDMC, e o método EMD que não teve estimativas tão ruins quanto as obtidas com o CapnoBase. Adicionalmente, embora a janela de observação de 60 s consiga prover melhores estimativas, o ganho em média é praticamente a metade do ganho que ocorre com o banco de dados CapnoBase.

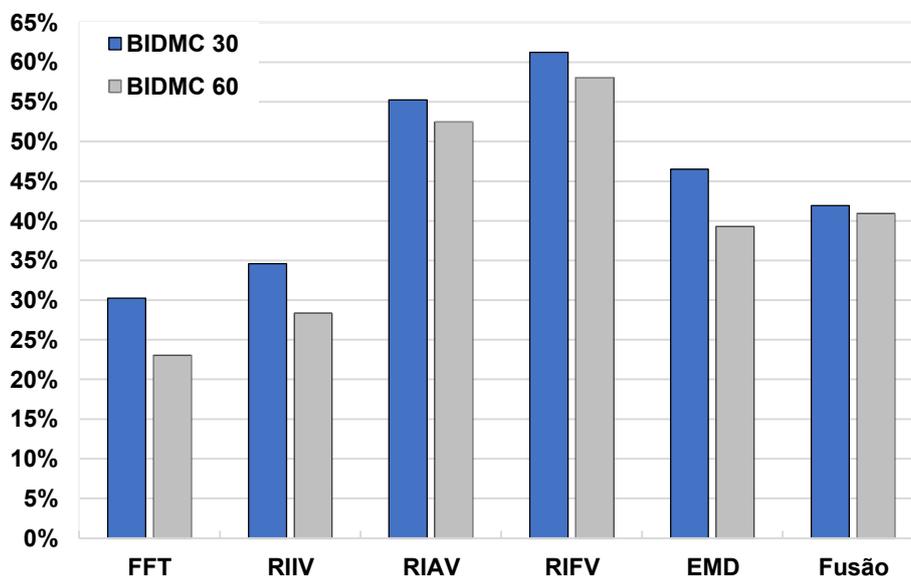


Figura 30. Erro percentual médio computado com os métodos FFT, RIIV, RIAV, RIFV, EMD e Fusão, tendo como entrada dados do BIDMC e janelas de observação deslizantes de 30 s e 60 s (Fonte: Autor).

A comparação entre os bancos de dados é evidenciada com a Figura 31, que junta as informações da Figura 29 com as informações da Figura 30. Nesta última figura fica evidente que praticamente todos os métodos têm eficácia maior quando trabalham com o banco de dados CapnoBase; a exceção ocorre apenas com o Método EMD.

A Figura 31 evidencia que o Método Fusão tem o melhor desempenho entre os métodos baseados nas características fisiológicas do sinal PPG para o CapnoBase; contudo, a mesma eficácia não é alcançada com este método, considerando o BIDMC. Convém descrever que ao analisar visualmente os sinais de PPG, foi identificada uma quantidade superior de amostras com artefatos no banco de dados BIDMC, sendo este o principal motivo que deve ter levado aos métodos terem um desempenho médio inferior, quando comparados com as avaliações feitas no CapnoBase.

A Figura 32 objetiva analisar globalmente a eficácia dos seis métodos propostos para ambos os bancos de dados e janelas de observação. Os achados principais que a figura mostra são a qualidade ruim que o método EMD tem em

média, em contraposição a alta eficácia nas estimativas providas pelos métodos RIIV e FFT. Adicionalmente, o Método de Fusão que teve resultados superiores a todos os demais com o banco de dados CapnoBase, fica em terceiro lugar, provavelmente pelos artefatos contidos no banco de dados BIDMC. Contudo, como o Método de Fusão aplica regras com o Método RIIV que obteve os melhores resultados, há um indicativo de trabalho futuro para avaliar uma regra que beneficie a fusão, mesmo para o BIDMC.

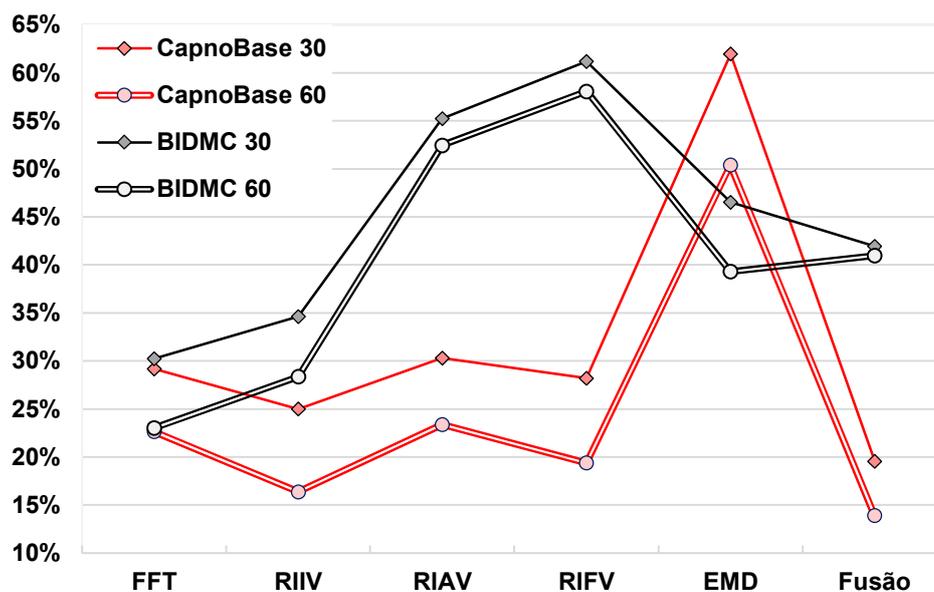


Figura 31. Erro percentual médio computado com todos os métodos, tendo como entrada ambos os bancos de dados e janelas de observação deslizantes de 30 s e 60 s (Fonte: Autor).

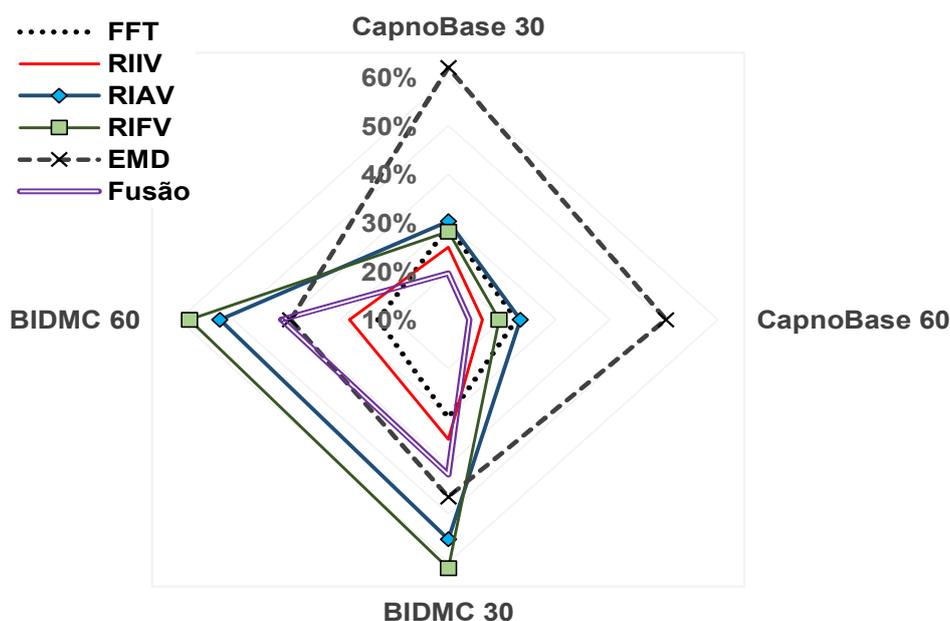


Figura 32. Análise global da eficácia de todos os métodos para ambos bancos de dados e janelas de observação (Fonte: Autor).

6.3.4 CONCLUSÕES PARCIAIS

Artefatos no sinal de PPG foram o principal motivo que levou algumas janelas de observação resultarem em erro absoluto da estimativa de frequência de respiração superior a 3 rpm. A Figura 33(a) ilustra uma janela de observação de 60 s do BIDMC com FR igual a 18 rpm, apresentando um ruído durante a captura do sinal de PPG; a região com ruído está destacada em azul.

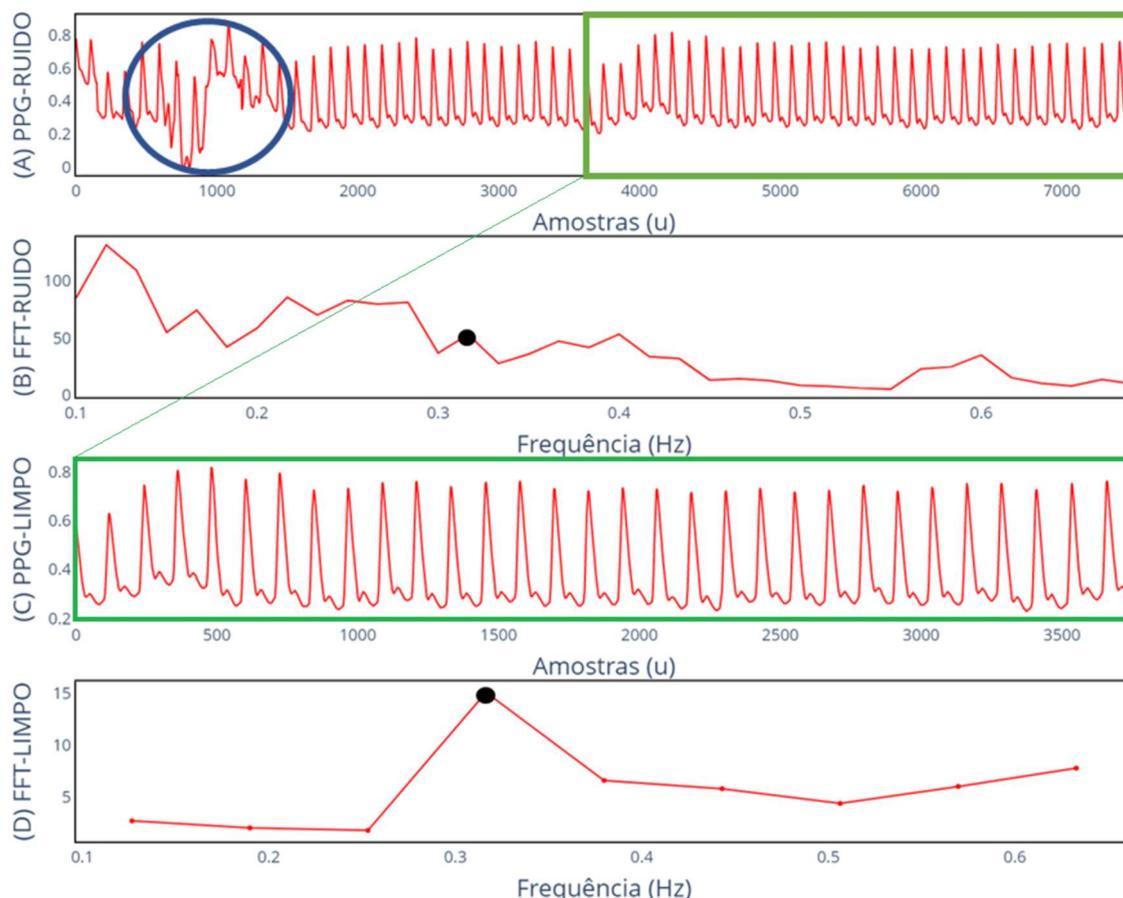


Figura 33. Exemplificação do efeito de um artefato na captura da estimativa de FR de uma amostra do banco de dados BIDMC; (a) mostra uma janela de observação de 60 s salientando o artefato e uma região sem ruído; (b) FFT aplicada à janela de (a); (c) zoom da região sem ruído; (d) FFT aplicada na região sem ruído (Fonte: Autor).

A Figura 33(b) ilustra a FFT extraída de toda a janela de observação de 60 s de medição, i.e., toda as amostras apresentadas na Figura 33(a). Nesta FFT fica evidente que o pico destacado com ponto preto, que é a FR de 18 rpm anotada no banco de dados, tem amplitude inferior aos picos que estão à esquerda, considerados interferências de baixa frequência ocasionados pela parte em azul destacada na Figura 33(a). Entretanto quando analisamos uma janela de 30 s para o mesmo sinal, retângulo verde da Figura 33(a), que é

destacado na Figura 33(c), notamos visualmente que praticamente não há ruídos de baixa frequência. Esta observação é corroborada ao aplicar a FFT sobre este sinal, resultando na Figura 33(b), onde o pico dominante passa a ser exatamente o valor de referência que está no banco de dados.

A Tabela 6 ilustra estimativas de frequência respiratória obtidas pelo Método EMD com a decomposição do sinal PPG em IMFs, considerando uma janela de observação de 60 s.

TABELA 6. MÉTODO EMD APLICADO EM UMA JANELA DE OBSERVAÇÃO DE 60 S, PARA ESTIMATIVAS DE FREQUÊNCIAS RESPIRATÓRIAS CONSIDERANDO 20 PESSOAS PRESENTES NO BANCO DE DADOS BIDMC.

Pessoa	FR de referência	Frequências respiratórias medidas					Erro absoluto
		IMF1	IMF2	IMF3	IMF4	IMF5	
1	21	6	35	39	21	8	0
2	15	34	33	15	7	6	0
3	18	11	17	17	10	6	1
4	17	38	38	34	17	6	0
5	7	7	36	12	7	6	0
6	20	21	40	40	20	6	0
7	20	41	17	20	7	6	0
8	18	41	18	6	6	6	0
9	17	41	19	9	7	6	2
10	19	39	41	20	9	6	1
11	14	17	38	24	16	6	2
12	18	26	17	18	11	9	0
13	19	6	37	19	6	6	0
14	12	6	38	26	13	6	1
15	15	28	15	15	6	6	0
16	20	9	32	14	17	9	3
17	17	6	36	33	17	7	0
18	18	18	18	36	18	7	0
19	15	41	32	19	12	6	3
20	19	19	37	19	8	6	0

O Método EMD decompõe o sinal em IMF de forma empírica e cada IMF contém sinais com valores dominantes em diferentes intervalos de frequência. Isso resulta em mais de uma IMF com frequência dominante dentro de um intervalo aceitável para a respiração humana [0,1 Hz, 0,7 Hz]. Conseqüentemente, é difícil a escolher a IMF relativa a FR da pessoa que está sendo avaliada. A Tabela 6 ilustra este procedimento realizado sobre o banco de dados BIDMC, onde as IMFs que deveriam ser selecionadas estão destacadas em vermelho, sendo o erro absoluto para a amostra selecionada destacado na última coluna (em verde, no caso de ser coincidente com o valor de referência). Para mitigar este problema, uma solução é escolher a IMF após uma passagem de uma sequência de janelas deslizantes, verificando qual a maior coincidência de valores de estimativas frequência respiratória.

7. CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho teve como objetivo avaliar a eficácia de seis métodos de inferência da frequência respiratória de sinais de PPG disponíveis em bancos de dados sintéticos e reais. Os métodos propostos seguem a classificação que contém de três a cinco etapas descritas em [2] e [24]. Todos os métodos implementam as etapas de “Extração dos sinais respiratórios” obtidas pela análise de características fisiológicas do sinal de PPG (Método RIIV, Método RIAV, Método RIFV e Método Fusão) e filtragem (Método FFT e Método EMD), e “Estimar FR” realizada pela análise do pico máximo dentro do intervalo de frequência respiratória aceitável para seres humanos.

Os métodos que utilizam análise das características fisiológicas do sinal de PPG contém uma etapa de “Avaliação de Qualidade” para remoção de sinais ruidosos; esta etapa empregada pelos métodos RIIV, RIAV e RIFV avalia as variações entre picos e vales do sinal PPG. Adicionalmente, o Método de Fusão também emprega um critério de filtro quando não são satisfeitas certas condições das estimativas de RIIV, RIAV e RIFV; tipicamente informando que as estimativas são dispares e não devem ser consideradas.

O Método FFT apresentou a maior eficácia para sinais de PPG contendo variações de intensidade ocasionadas pela respiração, alcançando erro nulo em todo o intervalo de frequência respiratória presente no banco de dados sintéticos. Além disso, manteve consistência nos resultados com os bancos de dados reais, apresentando eficácia em torno de 70% e 76% para análises em janelas de observação de 30 s e 60 s, respectivamente.

O Método RIIV apresentou resultados similares com o Método RIAV nas análises realizadas no banco de dados sintético. Entretanto, quando foram executados nos bancos de dados reais, apenas o Método RIIV obteve um desempenho aceitável, conseguindo alcançar eficácia de 85% nas estimativas de FR realizadas com janela de observação de 60 s e banco de dados CapnoBase.

Para o banco de dados sintético, o Método EMD apresentou resultados próximos aos resultados dos métodos RIIV e RIAV. Entretanto, a eficácia do Método EMD foi proporcionalmente reduzida quando aplicado aos dados dos bancos de dados reais CapnoBase e BIDMC. Estes resultados indicam que o

Método EMD tende a ter resultados piores que os métodos RIIV e RIAV na presença de um sinal ruidoso – o caso dos bancos de dados reais.

O Método Fusão apresentou a maior eficácia entre os métodos avaliados com o banco de dados CapnoBase, principalmente porque a fusão consegue alcançar em média os melhores resultados dos métodos que foram correlacionados. Entretanto, mesmo contendo a análise da qualidade do sinal, implícita nos métodos RIIV, RIIV e RIAV, bem como a qualidade da correlação, o Método Fusão apresentou uma eficácia menor com a análise dos dados do BIDMC, provavelmente, porque que continha presença constante de ruído nos sinais de PPG. Dessa forma, nenhum método obteve a totalidade de sinais analisados com erro absoluto menor ou igual a 10% da faixa de FR (i.e., 3 rpm) compreendendo os dois bancos de dados. O Método de Fusão, em janelas de 60s no banco de dados Capnobase, que obteve 85% das amostras; este método alcançou o melhor desempenho entre os métodos avaliados. Para o banco de dados BIDMC, o Método FFT obteve o melhor desempenho com 75% com erro inferior ou igual a 3 rpm, igualmente empregando janelas de 60s.

Como trabalhos futuros propomos aumentar o espaço de exploração de métodos para captura da frequência respiratória. Uma exploração incremental é o uso do Método de EMD junto com os métodos RIIV, RIAV e RIFV; ou seja, estender o Método de Fusão. O objetivo principal aqui é aumentar a correlação, e permitir uma escolha mais assertiva da IMF. Uma segunda exploração mais complexa envolve a captura das estimativas de frequência respiratória empregando aprendizado de máquina. Para este último caso, também envolve aspectos exploratórios de eficácia e eficiência em relação ao local onde deve ser feita a análise (dispositivo vestível ou concentrador).

A qualidade do sinal de PPG apresentou grande impacto nos resultados das frequências respiratórias; por este motivo, como trabalho futuro também propomos um estudo de métricas relevantes para classificar a qualidade do sinal (empregando algum índice como IQR ou IQS), considerando uma análise exploratória que contemple o maior intervalo de frequência respiratórias disponibilizados nos bancos de dados reais.

Adicionalmente, pretendemos implementar estes algoritmos dentro do firmware do dispositivo vestível do projeto LifeSenior, de forma a avaliar em cenários reais e em tempo real os métodos explorados neste trabalho.

8. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] G. Olivadoti, “How Advances in Sensor and Digital Technology Yield Better Patient Care”, Thought Leadership Article, Analog Devices, pp. 1-2, 2021, disponível em <https://www.analog.com/en/technical-articles/how-advances-in-sensor-and-digital-tech-yield-better-patient-care.html>, acessado em Jul. 2022.
- [2] P. Charlton, D. Birrenkott, T. Bonnici, M. Pimentel, A. Johnson, J. Alastruey, L. Tarassenko, P. Watkinson, R. Beale, D. Clifton, “Breathing Rate Estimation from the Electrocardiogram and Photoplethysmogram: A Review”, IEEE Reviews in Biomedical Engineering, v. 11, pp. 2-20, Oct. 2018.
- [3] Osram, “Health Monitoring & Fitness Tracking”, 2022, disponível em <https://www.osram.com/os/applications/health-monitoring-and-fitness-tracking/index.jsp>, acessado em Jul. 2022.
- [4] M. Much, C. Marcon, F. Hessel, A. Cataldo Neto, “LifeSenior – A Health Monitoring IoT System Based on Deep Learning Architecture”, Lecture Notes in Computer Science, v. 12787, pp. 293-306, Jul. 2021.
- [5] W. Karlen, M. Turner, E. Cooke, G. Dumont, J. Ansermino, “CapnoBase: Signal database and tools to collect, share and annotate respiratory signals”, Proceedings of the Annual Meeting of the Society for Technology in Anesthesia (STA), pp. 1-27, 2010.
- [6] M. Pimentel, A. Johnson, P. Charlton, D. Clifton, “BIDMC PPG and Respiration Dataset”, Version: 1.0.0, Jun. 2018, disponível em <https://physionet.org/content/bidmc/1.0.0/>, acessado em Jul. 2022.
- [7] V. Bartoski, “Análise Comparativa de Algoritmos de Machine Learning na Detecção de Quedas”, Relatório Técnico, Programa de Pós-Graduação em Ciência da Computação (PPGCC) da Pontifícia Universidade Católica do Rio Grande do Sul, 2022, 49p.
- [8] Toth Lifecare, “Sistema de Monitoramento LifeSenior”, disponível em <https://www.tothlifecare.com.br/>, acessado em Ago. 2022.
- [9] Amazon, “Computação em nuvem com a AWS”, 2020, disponível em <https://aws.amazon.com/pt/what-is-aws/>, acessado em Jul. 2022.
- [10] J. Allen, “Photoplethysmography and Its Application in Clinical Physiological Measurement”, Physiological Measurement, v. 28, n. 3, pp. 1-39, Mar. 2007.
- [11] Analog Devices, Inc., “ADPD1080 / ADPD1081 Data Sheet”, Analog Devices - Photometric Front Ends, pp. 1-74, 2020.
- [12] T. Ishikawa, Y. Hyodo, K. Miyashita, K. Yoshifuji, Y. Komoriya, Y. Imai, “Wearable Motion Tolerant PPG Sensor for Instant Heart Rate in Daily Activity”, Proceedings

- of the International Conference on Bio-inspired Systems and Signal Processing (BIOSIGNALS), pp. 126-133, 2017.
- [13] Task Force of the European Society of Cardiology the North American Society of Pacing Electrophysiology, "Heart rate variability. Standards of measurement, physiological interpretation, and clinical use", American Heart Association, v. 93, n. 5, pp. 1043-1065, Mar. 1996.
- [14] P. Mohan, A. Nisha, N. Velmurugan, E. Jothi, "Measurement of Arterial Oxygen Saturation (SpO₂) using PPG Optical Sensor", Proceedings of the International Conference on Communication and Signal Processing (ICCSP), pp. 1136-1140, 2016.
- [15] Y. Kurylyak, F. Lamonaca, D. Grimaldi, "A Neural Network-based method for continuous blood pressure estimation from a PPG signal", Proceedings of the IEEE International instrumentation and measurement technology conference (I2MTC), pp. 280-283, 2013.
- [16] D. Jarchi, D. Salvi, L. Tarassenko, D. Clifton, "Validation of instantaneous respiratory rate using reflectance PPG from different body positions", Sensors (Basel), v. 18, n. 11, pp. 3705, Nov. 2018.
- [17] ST Microelectronics, "iNEMO-Inertial Modules", 2022, disponível em <https://www.st.com/en/mems-and-sensors/inemo-inertial-modules.html>, acessado em Jul. 2022.
- [18] A. Kamal, J. Harness, G. Irving, A. Mearns, "Skin photoplethysmography—a review", Computer methods and programs in biomedicine, v. 28, n. 4, pp. 257-269, Apr. 1989.
- [19] T. Tamura, Y. Maeda, M. Sekine, M. Yoshida, "Wearable photoplethysmographic sensors—past and present", Electronics, v. 3, n. 2, pp. 282-302, Apr. 2014.
- [20] E. Mejia-Mejia, J. Allen, K. Budidha, C. El-Hajj, P. Kyriacou, P. Charlton, "Photoplethysmography Signal Processing and Synthesis", Photoplethysmography - Technology, Signal Analysis and Applications, Academic Press, chap. 4, pp. 69-146, Nov. 2021.
- [21] T. Tamura, Y. Maeda, "Pulse and Flow – Photoplethysmogram", Seamless Healthcare Monitoring - Advancements in Wearable, Attachable, and Invisible Devices, Ed. Springer, Part III, pp. 159-192, 2018.
- [22] T. Benetti, "Estimativa Robusta da Frequência Cardíaca a Partir de Sinais de Fotopletismografia de Pulso", Dissertação de Mestrado, PPGE/PUCRS, 2018, 179p.
- [23] P. Dehkordi, A. Garde, B. Molavi, J. Ansermino, G. Dumon, "Extracting Instantaneous Respiratory Rate from Multiple Photoplethysmogram Respiratory-

- Induced Variations”, *Frontiers in Physiology*, v. 9, pp. 948.1-948.10, Jul. 2018.
- [24] P. Charlton, T. Bonnici, L. Tarassenko, D. Clifton, R. Beale, P. Watkinson, “An Assessment of Algorithms to Estimate Respiratory Rate from The Electrocardiogram and Photoplethysmogram”, *Physiological Measurement*, v. 37, n. 4, pp. 610-26, Apr. 2016.
- [25] M. Pimentel, A. Johnson, P. Charlton, D. Birrenkott, P. Watkinson, L. Tarassenko, D. Clifton, “Toward a Robust Estimation of Respiratory Rate from Pulse Oximeters”, *IEEE Transactions on Biomedical Engineering*, v. 64, n. 8, pp. 1914-1923, Aug. 2017.
- [26] C. Orphanidou, “Derivation of respiration rate from ambulatory ECG and PPG using Ensemble Empirical Mode Decomposition: Comparison and fusion”, *Computers in Biology and Medicine*, v. 81, pp. 45-54, Feb. 2017.
- [27] M. Motin, C. Karmakar, M. Palaniswami, “Ensemble Empirical Mode Decomposition with Principal Component Analysis: A Novel Approach for Extracting Respiratory Rate and Heart Rate from Photoplethysmographic Signal”, *IEEE Journal of Biomedical and Health Informatics*, v. 22, n. 3, pp. 766-774, May 2018.
- [28] A. Johnson, T. Pollard, R. Mark, “MIMIC-III Clinical Database”, Version: 1.4, Sep. 2016, disponível em <https://physionet.org/content/mimiciii/1.4/>, acessado em Jul. 2022.
- [29] S. Khreis, D. Ge, G. Carrault, “Estimation of Breathing Rate from the Photoplethysmography Using Respiratory Quality Indexes”, *Proceedings of the Computing in Cardiology Conference (CinC)*, pp. 1-4, 2018.
- [30] D. Birrenkott, M. Pimentel, P. Watkinson, D. Clifton, “A Robust Fusion Model for Estimating Respiratory Rate from Photoplethysmography and Electrocardiography”, *IEEE Transactions on Biomedical Engineering*, v. 65, n. 9, pp. 2033-2041, Sep. 2018.
- [31] M. Motin, C. Karmakar, M. Palaniswami. “Selection of Empirical Mode Decomposition Techniques for Extracting Breathing Rate From PPG”, *IEEE Signal Processing Letters*, v. 26, n. 4, pp. 592-596, Apr. 2019.
- [32] H. Yang, M. Li, D. He, X. Che, X. Qin, “Respiratory Rate Estimation from the Photoplethysmogram Combining Multiple Respiratory-induced Variations Based on SQI”, *Proceedings of the IEEE International Conference on Mechatronics and Automation (ICMA)*, pp. 382-387, 2019.
- [33] D. Pollreisz, N. Nejad, “Reliable Respiratory Rate Extraction using PPG”, *Proceedings of the IEEE Latin American Symposium on Circuits & Systems (LASCAS)*, pp. 1-4, 2020.

- [34] M. Motin, C. Karmakar, D. Kumar, M. Palaniswami, "PPG Derived Respiratory Rate Estimation in Daily living Conditions", Proceedings of the Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), pp. 2736-2739, 2020.
- [35] D. Pollreisz, N. TaheriNejad, "Efficient Respiratory Rate Extraction on a Smartwatch", Proceedings of the Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), pp. 5988-5991, 2020.
- [36] S. Khreis, D. Ge, H. Rahman, G. Carrault, "Breathing Rate Estimation Using Kalman Smoother with Electrocardiogram and Photoplethysmogram", IEEE Transactions on Biomedical Engineering, v. 67, n. 3, pp. 893-904, Mar. 2020.
- [37] CominLabs, "Sherpam", 2022, disponível em <https://project.inria.fr/sherpam/>, acessado em Jul. 2022.
- [38] R. Lazazzera, G. Carrault, "Breathing Rate Estimation Methods from PPG Signals, on CAPNOBASE Database", Proceedings of the Computing in Cardiology (CinC), v. 47, pp. 1-4, 2020.
- [39] J. Kozumplik, L. Smital, A. Nemcova, M. Ronzhina, R. Smisek, L. Marsanova, M. Kralik, M. Vitek, "Respiratory Rate Estimation Using the Photoplethysmogram: Towards the Implementation in Wearables", Proceedings of the Computing in Cardiology (CinC), v. 48, pp. 1-4, 2021.
- [40] N. Fikriastuti, H. Muhaimin, "Respiratory Rate Estimations using Three Respiratory-Induced Variations on Photoplethysmogram", Proceedings of the International Conference on Electrical Engineering and Informatics (ICEEI), pp. 1-6, 2021.
- [41] G. Protopsaltis, M. Krizea, J. Gialelis, "Continuous Measurement of Respiratory Rate via Single-Wavelength Reflective Photoplethysmography", Proceedings of the Mediterranean Conference on Embedded Computing (MECO), pp. 1-5, 2021.
- [42] S. Haddad, A. Boukhayma, A. Caizzone, "PPG-Based Respiratory Rate Monitoring Using Hybrid Vote-Aggregate Fusion Technique", Proceedings of the Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), pp. 1605-1608, 2021.
- [43] F. Icazatti, C. Dell'Aquila, E. Leber, "Design and validation of a respiratory rate estimation algorithm based on photoplethysmography (PPG) signal", Proceedings of the Workshop on Information Processing and Control (RPIC), pp. 1-5, 2021.
- [44] G. Zhang, L. Cui, R. Mueller, S. Tao, M. Kim, M. Rueschman, S. Mariani, D. Mobley, S. Redline, "The National Sleep Research Resource: towards a sleep data commons", Journal of the American Medical Informatics Association. v. 25,

- n. 10, pp. 1351-1358, Oct. 2018.
- [45] A. Adami, R. Boostani, F. Marzbanrad, P. Charlton, "A New Framework to Estimate Breathing Rate from Electrocardiogram, Photoplethysmogram, and Blood Pressure Signals", *IEEE Access*, v. 9, pp. 45832-45844, Mar. 2021.
- [46] Y. Ichimaru, G. Moody, "Development of the polysomnographic database on CD-ROM", *Psychiatry and Clinical Neurosciences*, v. 53, pp. 175-177, Apr. 1999.
- [47] M. Chen, Q. Zhu, M. Wu and Q. Wang, "Modulation Model of the Photoplethysmography Signal for Vital Sign Extraction", *IEEE Journal of Biomedical and Health Informatics*, v. 25, n. 4, pp. 969-977, Apr. 2021.
- [48] Jupyter, "About Us - Project Jupyter's origins and governance", 2022, disponível em <https://jupyter.org/about>, acessado em Jul. 2022.
- [49] J. Cooley, J. Tukey, "An algorithm for the machine calculation of complex Fourier series", *Mathematics of Computation*, v. 19, pp. 297-301, May 1965.
- [50] L. Bluestein, "A linear filtering approach to the computation of discrete Fourier transform". *IEEE Transactions on Audio and Electroacoustics*, v. 18, n. 4, pp. 451-455, Dec. 1970.
- [51] D. Labate, F. Foresta, G. Occhiuto, F. Morabito, A. Lay-Ekuakille, P. Vergallo, "Empirical Mode Decomposition vs. Wavelet Decomposition for the Extraction of Respiratory Signal from Single-Channel ECG: A Comparison", *IEEE Sensors Journal*, v. 13, n. 7, pp. 2666-2674, 2013.
- [52] N. Huang, Z. Shen, S. Long, M. Wu, H. Shih, Q. Zheng, N.-C. Yen, C. Tung, H. Liu, "The empirical mode decomposition and the Hilbert spectrum for non-linear and non-stationary time series analysis", *Proceedings of the Royal Society*, v. 454, n. 1971, pp. 903-995, Mar. 1998.
- [53] G. Rilling, P. Flandrin, P. Goncalves, "On Empirical Mode Decomposition and its algorithms", *Proceedings of the IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing (NSIP)*, pp.1-5, 2003.
- [54] P. Charlton, "Synthetic Dataset - Dataset for verification of algorithm implementations", 2016, disponível em https://peterhcharlton.github.io/RRest/synthetic_dataset.html, acessado em Jul. 2022.
- [55] P. Charlton, "CapnoBase Dataset External - dataset of recordings during surgery and anaesthesia", 2016, https://peterhcharlton.github.io/RRest/capnobase_dataset.html, acessado em Jul. 2022.
- [56] P. Charlton, "BIDMC Dataset - External dataset of critical care recordings", 2016, https://peterhcharlton.github.io/RRest/bidmc_dataset.html, acesso em Jul. 2022.

9. APÊNDICE A – RREST-SYN DATASET

RRest-syn [54] é uma coleção de sinais sintéticos de ECG e PPG (por oximetria de pulso), que foram modulados pelas três características fisiológicas respiratórias descritas na Seção 3.4:

- RIIV – que no banco de dados é referenciada como modulação de linha de base, em inglês *Baseline Wander* (BW);
- RIAV – referenciada no baco de dados como modulação de amplitude, em inglês *Amplitude Modulation* (AM);
- RIFV – definida no banco de dados como modulação de frequência, em inglês *Frequency Modulation* (FM).

A coleção RRest-syn inclui o banco de dados Synthetic Dataset [24] que foi gerado usando o script Matlab® chamado RRest-syn_generator, permitindo alcançar sinais livres de ruídos ambientais que refletem batimentos cardíacos e respiração de um ser humano. Os dados de ECG e PPG com duração de um segundo foram repetidos 210 vezes, resultando sinais simulados com duração de 210 s. Estes sinais foram, então, modulados em cada uma das características fisiológicas da respiração descritas acima (BW, AM e FM), produzindo três sinais separados. A Figura 34 exemplifica sinais sintéticos de PPG e ECG sem modulação e modulados com BW, AM, FM.

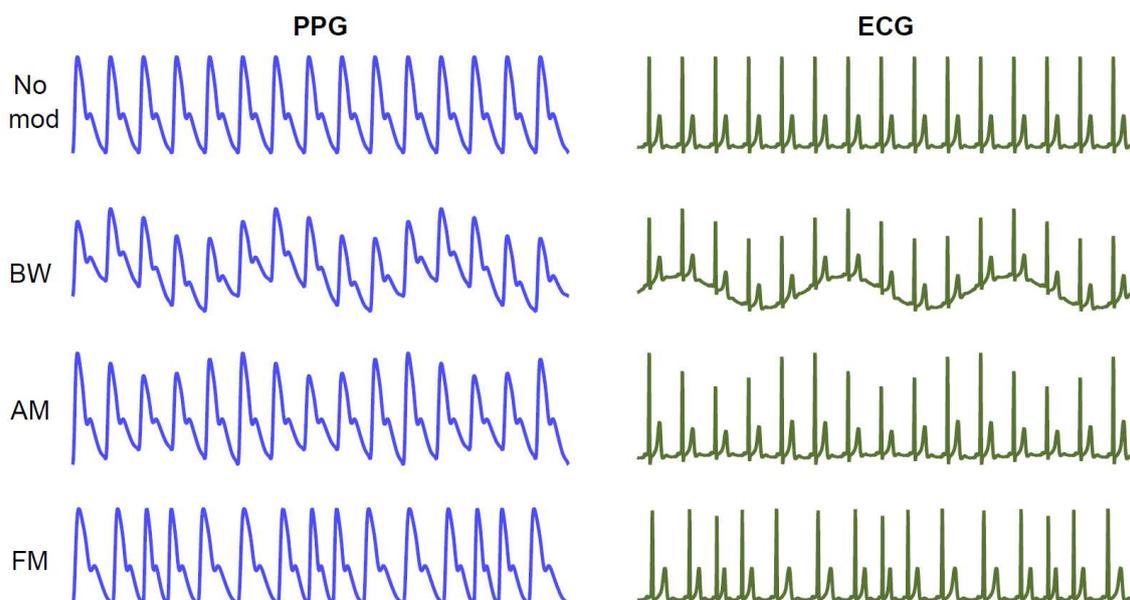


Figura 34. Sinais de PPG e ECG sem modulação e modulados com BW, AM e FM (Fonte: [54]).

O processo de geração dos sinais foi repetido para as faixas de frequência cardíaca de [30 bpm, 200 bpm] e respiratória de [4 rpm, 60 rpm]. Para analisar a variação de frequência cardíaca, os autores do banco de dados fixaram a frequência respiratória em 20 bpm. De forma análoga, para analisar a frequência respiratória, a frequência cardíaca foi fixada em 80 bpm. A taxa de amostragem dos sinais é de 500 Hz, i.e., uma amostra a cada 2 ms.

Os arquivos do banco de dados têm o formato “.csv”, consistindo cada arquivo em duas colunas, uma para o sinal PPG e outra para o ECG. A Tabela 7 ilustra este formato incluindo o tempo relativo à taxa de amostragem na primeira coluna.

TABELA 7. TRECHO DO ARQUIVO DO BANCO DE DADOS RREST-SYN, ILUSTRANDO OS SINAIS DE PPG E ECG, BEM COMO A TAXA DE AMOSTRAGEM.

TEMPO(s)	SINAL PPG	SINAL ECG
0	0	62,893
0,002	0,00098884	62,977
0,004	0,0034346	63,06
0,006	0,0068075	63,144
0,008	0,010672	63,17
0,01	0,016399	62,205
0,012	0,024125	60,653
0,014	0,033215	59,476
0,016	0,043385	59,481
0,018	0,055966	60,211
0,02	0,070661	61,11
0,022	0,086873	61,697
0,024	0,10472	61,566
0,026	0,12513	60,913
0,028	0,14752	60,216
0,03	0,17122	59,958

Os dados descritos na Tabela 7 são acompanhados por um arquivo que descreve os metadados para esse conjunto de sinais, por exemplo:

- Nome do arquivo: rrest-syn001;
- Sinal: Pleth (Plethysmograph), pulse oximeter PPG; and simulated ECG;
- Frequência de amostragem: 500 Hz;
- Tipo de modulação respiratória: BW;
- Frequência respiratória: 4 breaths/min (i.e., 4 rpm);
- Frequência cardíaca: 80 beats/min (i.e., 80 bpm);

10. APÊNDICE B - CAPNOBASE IEEE TBME RESPIRATORY RATE BENCHMARK

CapnoBase [5] é um conjunto de dados de referência que disponibiliza a avaliação de 42 pessoas em gravações de 8 minutos, disponibilizando formas de onda de capnografia (CO_2) e sinal de PPG obtido com a avaliação da oximetria de pulso. Especificamente, o banco de dados contém:

- O sinal de PPG bruto para 42 casos, cada um com 8 minutos de duração;
- Rótulos de pico de pulso e artefatos validados por um avaliador especialista que estava presente durante a coleta de informação;
- O sinal de CO_2 de referência e frequência de respiração instantânea para todos os casos;
- O sinal de ECG de referência com rótulos de pico e artefato, validado por um avaliador especialista;
- A referência de frequência cardíaca instantânea derivada de rótulos de pico de pulso de ECG e PPG;
- A saída do algoritmo SmartFusion e subcomponentes, quando aplicado a este conjunto de dados de referência para comparação algorítmica.

A Figura 35 apresenta formas de onda dos sinais de CO_2 , ECG e PPG que ocorrem simultaneamente, sendo parte do banco de dados CapnoBase.

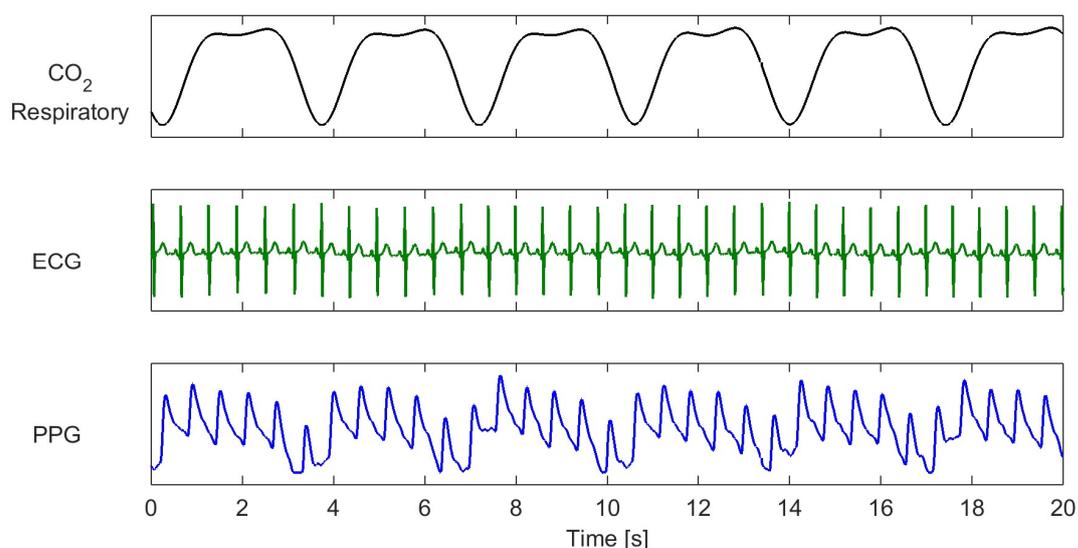


Figura 35. Ilustração das formas de onda dos sinais de CO_2 , ECG e PPG contidos no banco de dados CapnoBase (Fonte: [55]).

Para cada indivíduo avaliado, o banco de dados dispõe de seis arquivos descritos a seguir:

- **##_param.csv** – contendo taxas de amostragem, nome do caso, modo de ventilação;
- **##_meta.csv** – contendo metadados, como o sexo do paciente, idade e tipo de tratamento;
- **##_SFresults.csv** – contendo a frequência respiratória obtida usando a abordagem Smart Fusion e suas etapas;
- **##_signal.csv** – contendo os sinais brutos de CO₂, PPG e ECG;
- **##_labels.csv** – contendo rótulos para batimentos, respirações e artefatos obtidos com o apoio de um avaliador humano;
- **##_reference.csv** – contendo tendências derivadas dos rótulos.

Onde **##** representa a identificação do indivíduo avaliado, e.g., “0009_8min”.

A Tabela 8 exemplifica o formato de um arquivo “##_signal.csv” que contém três colunas, referentes aos sinais CO₂, PPG e ECG; adicionalmente, inserimos uma coluna de tempo que relaciona os dados com sua taxa de amostragem de 300 Hz ($\approx 0,00333$ ms).

TABELA 8. EXEMPLIFICAÇÃO DO FORMATO DE UM ARQUIVO “##_SIGNAL.CSV” DO BANCO DE DADOS CAPNOBASE, CONTENDO OS SINAIS DE CO₂, PPG E ECG.

Tempo(s)	co2_y	pleth_y	ecg_y
0,000	1,5	-0,64	-0,31
0,003	1,54	-0,64	-0,34
0,007	1,59	-0,67	-0,31
0,010	1,64	-0,69	-0,26
0,013	1,68	-0,72	-0,18
0,017	1,73	-0,72	-0,15
0,020	1,78	-0,72	-0,16
0,023	1,83	-0,72	-0,18
0,027	1,88	-0,83	-0,18
0,030	1,92	-0,93	-0,18
0,033	1,97	-1,04	-0,16
0,037	2,02	-1,04	-0,06
0,040	2,08	-1,04	0,03
0,043	2,14	-1,04	0,13
0,047	2,19	-1,15	0,17
0,050	2,24	-1,25	0,17
0,053	2,3	-1,36	0,18
0,057	2,36	-1,36	0,21

11. APÊNDICE C - BIDMC PPG AND RESPIRATION DATASET

O BIDMC é um conjunto de dados de ECG, PPG por oximetria de pulso e sinais respiratórios de pneumografia de impedância, sendo estes dados obtidos de pacientes de terapia intensiva. O BIDMC serve para avaliar o desempenho de algoritmos de frequência respiratória, refletindo seu desempenho potencial em um ambiente de cuidados intensivos do mundo real. O banco de dados contém 53 gravações, cada uma representando 8 minutos de dados sensorizados de um paciente. Os principais dados do banco são:

- Sinais de PPG, pneumografia de impedância e ECG amostrados em uma taxa de 125 Hz;
- Parâmetros fisiológicos amostrados em 1 Hz, como frequências cardíaca e respiratória e nível de saturação de oxigênio no sangue (SpO₂);
- Metadados do paciente;
- Anotações manuais de respirações.

A Figura 36 ilustra os sinais de pneumografia de impedância, ECG e PPG contidos no BIDMC.

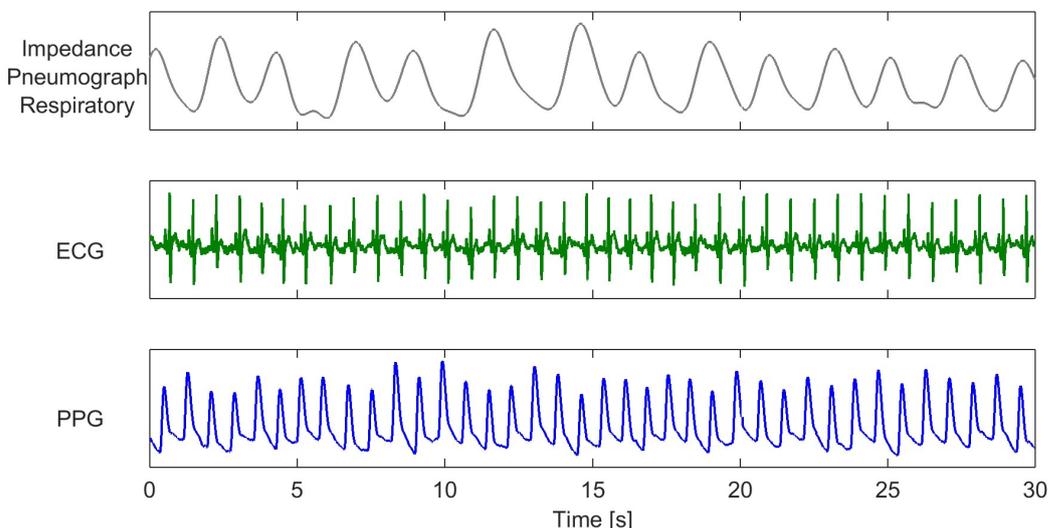


Figura 36. Exemplos dos sinais de pneumografia de impedância, ECG e PPG disponibilizados no BIDMC, que foram amostrados simultaneamente (Fonte: [56]).

O BIDMC fornece os seguintes arquivos para cada paciente:

- `bidmc_##_Fix.txt` – contendo informações gerais como identificação do paciente, nomes de sinais e taxas de amostragem;
- `bidmc_##_Breaths.csv` – contendo anotações de respiração;

- bidmc_##_Numerics.csv – contendo parâmetros fisiológicos como frequências respiratória e cardíaca, e nível de saturação de oxigênio no sangue (SpO₂);
- bidmc_##_Signals.csv – contendo os sinais fisiológicos;

Onde ## é um número que identificação do indivíduo avaliado, e.g., “01”.

O arquivo “bidmc_##_Signals.csv” contém os dados principais empregados nos experimentos realizados neste trabalho. A Tabela 9 ilustra parte deste arquivo, que está organizado em um formato com as colunas (i) Time [s]: representando o tempo da amostra em segundos; (ii) RESP: contendo o valor de pneumografia de impedância; (iii) PLETH: sendo o sinal de PPG; e (iv) a (vi) V, AVR e II: representando três variações de ECG.

TABELA 9. TRECHO DO DATASET BDMIC, REFERENTE AO ARQUIVO “BIDMC_##_SIGNALS.CSV”.

Time [s]	RESP	PLETH	V	AVR	II
0	0,35386	0,43597	0,52549	0,30392	0,72549
0,008	0,35679	0,43206	0,51961	0,33529	0,67059
0,016	0,35875	0,42815	0,51569	0,37451	0,6098
0,024	0,36168	0,42424	0,50588	0,41961	0,55098
0,032	0,36364	0,42131	0,5098	0,44902	0,5
0,04	0,36559	0,41838	0,50588	0,48039	0,4549
0,048	0,36657	0,4174	0,51569	0,5098	0,4098
0,056	0,36852	0,41642	0,51569	0,51961	0,3902
0,064	0,36852	0,41544	0,51961	0,53529	0,37451
0,072	0,36852	0,41447	0,51961	0,5451	0,35882
0,08	0,36852	0,41251	0,52549	0,5451	0,3549
0,088	0,36755	0,41153	0,52549	0,5549	0,34902
0,096	0,36657	0,40958	0,53529	0,55098	0,3549
0,104	0,36559	0,40762	0,52941	0,5451	0,36471
0,112	0,36168	0,40665	0,52549	0,5451	0,3549
0,12	0,35875	0,40665	0,53529	0,5451	0,36471
0,128	0,35288	0,40665	0,52549	0,5451	0,37451

12. APÊNDICE D – CÓDIGO COM MÉTODOS PARA CALCULAR A FREQUÊNCIA RESPIRATÓRIA PROVENIENTE DO SINAL DE PPG

Este apêndice apresenta o código desenvolvido em Python, contendo os seis métodos analisados para calcular a frequência respiratória proveniente do sinal PPG.

```

1   %%time
2   #Data CAPNOBASE
3   num_arquivos = 42 # quantidade de arquivos no dataset
4   frequencia = 300 # frequência de amostragem do dataset
5   inicio = 60      # início da análise em segundos
6   fim = 420        # final da análise em segundos
7   janela = 300     # tamanho da janela de observação
8   metodo = 'fft'   # método desejado para análise
9
10  N_PPG = (abs(inicio-fim) * frequencia)
11  N_JANELA = janela * frequencia
12  janela_tempo = fim - (inicio + janela) #quantidade de repetições
13  contador_acertou = 0
14  contador_sinalruim = 0
15
16  PPG_sinal = np.empty((num_arquivos, N_PPG)) #SINAL DE PPG 17   CO2_sinal
    = np.empty((num_arquivos, N_PPG)) #SINAL DE CO2
17
18  for kk in range(janela_tempo):
19      T_PPG = 1 / frequencia
20      FrPPG = np.array(range(num_arquivos))
21      FrREF = np.array(range(num_arquivos))
22      Erro_medido = np.array(range(num_arquivos))
23
24      for i in range(num_arquivos):
25          cp1 = (kk * frequencia) + (frequencia * inicio)
26          cp2 = N_JANELA + cp1
27          if(metodo == 'fusao'):
28              #sinal original com aumento das extremidades
29              sinal_original = PPG_sinal[i][cp1-2000:cp2+2000]
30              #encontrando os picos e vales
31              peaks_x, _ = find_peaks(sinal_original, prominence=1)
32              vales_x, _ = find_peaks((sinal_original*(-1)), prominence=1)
33              # Diferença no número de vales e picos é menor q 2
34              if( abs(len(peaks_x) - len(vales_x)) < 2):
35                  ##### AMPLITUDE
36                  # quantidade de picos menores/igual e
37                  # primeiro pico começa antes do vale
38                  if(len(peaks_x)<=len(vales_x) and peaks_x[0]<vales_x[0]):
39                      diferenca_pico_vale = np.zeros(len(peaks_x)-1)
40                      for z in range(len(diferenca_pico_vale)-1):
41                          diferenca_pico_vale[z]=sinal_original[peaks_x[z+1]]
42                              - sinal_original[vales_x[z]]
43
44                  # Quantidade de picos menores/igual e
45                  # primeiro pico começa depois do vale
46                  elif(len(peaks_x)<=len(vales_x) and peaks_x[0]>vales_x[0]):

```

```

45         diferenca_pico_vale = np.zeros(len(peaks_x))
46         for z in range(len(diferenca_pico_vale)):
47             diferenca_pico_vale[z] = sinal_original[peaks_x[z]]
48                 - sinal_original[vales_x[z]]
49     # Quantidade de vales menores/igual e
50     # primeiro pico começa antes do vale
51     elif(len(vales_x)<=len(peaks_x) and (peaks_x[0]<vales_x[0])):
52         diferenca_pico_vale = np.zeros(len(vales_x)-1)
53         for z in range(len(diferenca_pico_vale)-1):
54             diferenca_pico_vale[z]=sinal_original[peaks_x[z+1]]
55                 - sinal_original[vales_x[z]]
56     # Quantidade de vales menores/igual e
57     # primeiro pico começa depois do vale
58     elif(len(vales_x)<=len(peaks_x) and (peaks_x[0]>vales_x[0])):
59         diferenca_pico_vale = np.zeros(len(vales_x))
60         for z in range(len(diferenca_pico_vale)):
61             diferenca_pico_vale[z] = sinal_original[peaks_x[z]]
62                 - sinal_original[vales_x[z]]
63     s_a = interp1d(vales_x[0:len(diferenca_pico_vale)],
64         diferenca_pico_vale, kind = 'linear',
65         bounds_error = False, fill_value=0.0)
66     sinal_respiratorio1 = np.zeros(len(sinal_original))
67     for aux3 in range(len(sinal_original)):
68         sinal_respiratorio1[aux3] = s_a(aux3)
69     y0 = sinal_respiratorio1[2000:(len(sinal_original)-2000)]
70     ##### AMPLITUDE
71     #####LINHA DE BASE
72     l_b = interp1d(peaks_x,sinal_original[peaks_x],
73         kind = 'linear',bounds_error = False, fill_value=0.0)
74     sinal_respiratorio2 = np.zeros(len(sinal_original))
75     for k in range(len(sinal_original)):
76         sinal_respiratorio2[k] = l_b(k)
77     y1 = sinal_respiratorio2[2000:(len(sinal_original)-2000)]
78     ##### LINHA DE BASE
79     ##### FREQUÊNCIA
80     fm_y = np.zeros(len(peaks_x)-1)
81     for z in range(len(peaks_x)-1):
82         fm_y[z] = peaks_x[z+1]-peaks_x[z]
83     fm_x = peaks_x[0:(len(peaks_x)-1)]
84     s_f = interp1d(fm_x,fm_y, kind = 'linear',
85         bounds_error = False, fill_value=0.0)
86     sinal_respiratorio3 = np.zeros(len(sinal_original))
87     for k in range(len(sinal_original)):
88         sinal_respiratorio3[k] = s_f(k)
89     y2 = sinal_respiratorio3[2000:(len(sinal_original)-2000)]
90     ##### FREQUÊNCIA
91     else:
92         contador_sinalruim = contador_sinalruim + 1
93     # Amplitude
94     yf0 = fft(y0)
95     xf0 = fftfreq(N_JANELA, T_PPG)[:N_JANELA//2]
96     yf0 = np.abs(yf0[0:N_JANELA//2])
97     f1 = xf0[5] - xf0[4]
98     p1 = int(0.1/f1)
99     p2 = int(0.7/f1)
100    pos1 = yf0[p1:p2].argmax()

```

```

100     val1 = xf0[pos1+p1]
101     FrMED[0] = val1*60
102
103     # Linha de base
104     yf1 = fft(y1)
105     xf1 = fftfreq(N_JANELA, T_PPG)[:N_JANELA//2]
106     yf1 = np.abs(yf1[0:N_JANELA//2])
107     f2 = xf1[5] - xf1[4]
108     p3 = int(0.1/f2)
109     p4 = int(0.7/f2)
110     pos2 = yf1[p3:p4].argmax()
111     val2 = xf1[pos2+p3]
112     FrMED[1] = val2*60
113
114     # Frequência
115     yf2 = fft(y2)
116     xf2 = fftfreq(N_JANELA, T_PPG)[:N_JANELA//2]
117     yf2 = np.abs(yf2[0:N_JANELA//2])
118     f3 = xf2[5] - xf2[4]
119     p5 = int(0.1/f3)
120     p6 = int(0.7/f3)
121     pos3 = yf2[p5:p6].argmax()
122     val3 = xf2[pos3+p5]
123     FrMED[2] = val3*60
124     orden = np.sort(FrMED)
125     difpu = abs(orden[0] - orden[2])
126     difpa = abs(orden[0] - orden[1])
127     difau = abs(orden[1] - orden[2])
128     if(difpu <= 3):
129         FrPPG[i] = np.mean(orden)
130     elif (difpa <= 3):
131         FrPPG[i] = np.mean(orden[0:2])
132     elif (difau <= 3):
133         FrPPG[i] = np.mean(orden[1:3])
134     else:
135         FrPPG[i] = 0
136         contador_sinalruim = contador_sinalruim + 1
137
138     # Valor CO2
139     sinal_CO2 = CO2_cap[i][cp1:cp2]
140     yf3 = fft(sinal_CO2)
141     xf3 = fftfreq(N_JANELA, T_PPG)[:N_JANELA//2]
142     yf3 = np.abs(yf3[0:N_JANELA//2])
143     f4 = xf3[5] - xf3[4]
144     p7 = round(0.1/f4)
145     p8 = round(0.7/f4)
146     pos3 = yf3[p7:p8].argmax()
147     val3 = xf3[pos3+p7]
148     FrREF[i] = round(val3*60)
149     else:
150
151         ##### FFT
152         if (metodo == 'fft'):
153             y0 = PPG_sinal[i][cp1:cp2]
154             ##### FFT
155
156         ##### Linha de base/amplitude/frequência
157         elif(metodo=='riiv' or metodo=='riav' or metodo=='rifv'):

```

```

158     # Sinal original com aumento das extremidades
159     sinal_original = PPG_sinal[i][cp1-2000:cp2+2000]
160     # Encontrando os picos e vales
161     peaks_x, _ = find_peaks(sinal_original, prominence=1)
162     vales_x, _ = find_peaks((sinal_original*(-1)), prominence=1)
163     # Diferença no número de vales e picos é menor que 2
164     if( abs(len(peaks_x) - len(vales_x)) < 2):
165         ##### AMPLITUDE
166         if(metodo == 'riav'):
167             # Quantidade de picos menores/igual e
168             # primeiro pico começa antes do vale
169             if(len(peaks_x)<=len(vales_x) and
170                peaks_x[0]<vales_x[0]):
171                 diferenca_pico_vale = np.zeros(len(peaks_x)-1)
172                 for z in range(len(diferenca_pico_vale)-1):
173                     diferenca_pico_vale[z]=sinal_original[peaks_x[z+1]]
174                     - sinal_original[vales_x[z]]
175             # Quantidade de picos menores/igual e
176             # primeiro pico começa depois do vale
177             elif(len(peaks_x)<=len(vales_x) and peaks_x[0]>vales_x[0]):
178                 diferenca_pico_vale = np.zeros(len(peaks_x))
179                 for z in range(len(diferenca_pico_vale)):
180                     diferenca_pico_vale[z] = sinal_original[peaks_x[z]]
181                     - sinal_original[vales_x[z]]
182             # Quantidade de vales menores/igual e
183             # primeiro pico começa antes do vale
184             elif(len(vales_x)<=len(peaks_x) and peaks_x[0]<vales_x[0]):
185                 diferenca_pico_vale = np.zeros(len(vales_x)-1)
186                 for z in range(len(diferenca_pico_vale)-1):
187                     diferenca_pico_vale[z]=sinal_original[peaks_x[z+1]]
188                     - sinal_original[vales_x[z]]
189             # Quantidade de vales menores/igual e
190             # primeiro pico começa depois do vale
191             elif(len(vales_x)<= len(peaks_x) and peaks_x[0]>vales_x[0]):
192                 diferenca_pico_vale = np.zeros(len(vales_x))
193                 for z in range(len(diferenca_pico_vale)):
194                     diferenca_pico_vale[z] = sinal_original[peaks_x[z]]
195                     - sinal_original[vales_x[z]]
196             s_a = interp1d(vales_x[0:len(diferenca_pico_vale)],
197                            diferenca_pico_vale, kind = 'linear',
198                            bounds_error = False, fill_value=0.0)
199             sinal_respiratorio1 = np.zeros(len(sinal_original))
200             for aux3 in range(len(sinal_original)):
201                 sinal_respiratorio1[aux3] = s_a(aux3)
202             y0 = sinal_respiratorio1[2000:(len(sinal_original)-2000)]
203         ##### AMPLITUDE
204         ##### LINHA DE BASE
205         elif(metodo == 'riiv'):
206             l_b = interp1d(peaks_x,sinal_original[peaks_x],
207                            kind = 'linear', bounds_error = False, fill_value=0.0)
208             sinal_respiratorio2 = np.zeros(len(sinal_original))
209             for k in range(len(sinal_original)):
210                 sinal_respiratorio2[k] = l_b(k)
211             y0 = sinal_respiratorio2[2000:(len(sinal_original)-2000)]
212         ##### LINHA DE BASE
213         ##### FREQUÊNCIA
214         elif(metodo == 'rifv'):

```

```

212         fm_y = np.zeros(len(peaks_x)-1)
213         for z in range(len(peaks_x)-1):
214             fm_y[z] = peaks_x[z+1]-peaks_x[z]
215         fm_x = peaks_x[0:(len(peaks_x)-1)]
216         s_f = interp1d(fm_x, fm_y, kind = 'linear',
217                       bounds_error = False, fill_value=0.0)
218         sinal_respiratorio3 = np.zeros(len(sinal_original))
219         for k in range(len(sinal_original)):
220             sinal_respiratorio3[k] = s_f(k)
221         y0 = sinal_respiratorio3[2000:(len(sinal_original)-2000)]
222         ##### FREQUÊNCIA
223     else:
224         contador_sinalruim = contador_sinalruim + 1
225
226     ##### EMD
227     elif (metodo == 'emd'):
228         y0 = PPG_sinal[i][cp1:cp2]
229         time = np.linspace(0, 1, len(y0))
230         emd1 = EMD()
231         IMF = emd1.emd(y0, time)
232         #y0 = IMF[0] #IMF1
233         #y0 = IMF[1] #IMF2
234         #y0 = IMF[2] #IMF3
235         y0 = IMF[3] #IMF4
236         #y0 = IMF[4] #IMF5
237     #####EMD
238
239     # VALOR FR MEDIDO
240     yf0 = fft(y0)
241     xf0 = fftfreq(N_JANELA, T_PPG)[:N_JANELA//2]
242     yf0 = np.abs(yf0[0:N_JANELA//2])
243     fyy = xf0[5] - xf0[4]
244     p1 = round(0.1/fyy)
245     p2 = round(0.7/fyy)
246     pos_y = yf0[p1:p2].argmax()
247     val_x = xf0[pos_y+p1]
248     FrPPG[i] = round(val_x*60)
249
250     #VALOR FR REFERÊNCIA
251     sinal_CO2 = CO2_sinal[i][cp1:cp2]
252     yf1 = fft(sinal_CO2)
253     xf1 = fftfreq(N_JANELA, T_PPG)[:N_JANELA//2]
254     yf1 = np.abs(yf1[0:N_JANELA//2])
255     fxx = xf1[5] - xf1[4]
256     p3 = round(0.1/fxx)
257     p4 = round(0.7/fxx)
258     pos_yy = yf1[p3:p4].argmax()
259     val_xx = xf1[pos_yy+p3]
260     FrREF[i] = round(val_xx*60)
261
262     # CÁLCULO DO ERRO ABSOLUTO
263     Erro_medido[i] = abs(FrREF[i] - FrPPG[i])
264     if( Erro_medido[i]<=3 ):
265         contador_acertou = contador_acertou + 1
266
267     print(contador_acertou)
268     print(contador_sinalruim)

```



Pontifícia Universidade Católica do Rio Grande do Sul
Pró-Reitoria de Graduação
Av. Ipiranga, 6681 - Prédio 1 - 3º. andar
Porto Alegre - RS - Brasil
Fone: (51) 3320-3500 - Fax: (51) 3339-1564
E-mail: prograd@pucrs.br
Site: www.pucrs.br