Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Engenharia Eletrônica

Detecção de sonolência em motorista usando sensor PPG e GSR

Autor: Lourenço Jamba Mphili

Orientador: Prof. Dr. Gerardo Antonio Idrobo Pizo

Brasília, DF

2025



Lourenço Jamba Mphili

Detecção de sonolência em motorista usando sensor PPG e GSR

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica .

Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Engenharia Eletrônica

Orientador: Prof. Dr. Gerardo Antonio Idrobo Pizo

Brasília, DF

2025

Lourenço Jamba Mphili
Detecção de sonolência em motorista usando sensor PPG e GSR/ Lourenço Jamba Mphili. – Brasília, DF, 2025- 86 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Dr. Gerardo Antonio Idrobo Pizo

Trabalho de Conclusão de Curso – Universidade de Brasília - UnB
Faculdade UnB Gama - FGA
Engenharia Eletrônica , 2025.

1. . 2. . I. Prof. Dr. Gerardo Antonio Idrobo Pizo. II. Universidade de Brasília. III. Faculdade UnB Gama. IV.Detecção de sonolência em motorista usando sensor PPG e GSR

CDU 02:621.39:615.84:621.3

Lourenço Jamba Mphili

Detecção de sonolência em motorista usando sensor PPG e GSR

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica .

Trabalho aprovado. Brasília, DF, 21 de julho de 2025:

Prof. Dr. Gerardo Antonio Idrobo Pizo
Orientador

Prof. Dr. Daniel M. Muñoz Arboleda
Convidado 1

Prof. Dr. Diogo de Oliveira Costa
Convidado 2

Brasília, DF
2025

Dedico este trabalho aos meus pais, por todo o amor e apoio incondicional que me deram ao longo dos anos. Aos meus professores, por terem sido fontes inspiradoras de conhecimento e orientação. A Luzia Odélia Canganja, Valter Canganja Mphili e ao Fernando Kuvi, por serem pessoas especiais na minha vida e por sempre me apoiarem. E aos meus amigos, por terem sido uma constante fonte de apoio e motivação. Obrigado por terem feito parte desta jornada.

Agradecimentos

Agradeço primeiramente à Deus, que me deu saúde e força para enfrentar todas as dificuldades.

À Universidade de Brasília pela oportunidade de estudo. Aos professores pelos ensinamentos no decorrer do curso. Principalmente, ao meu orientador, Gerardo, por todo o conhecimento passado, incentivo, disponibilidade em ajudar e pelo tempo e paciência investidos nesse trabalho.

Aos meus pais, André Mphili e Emília Jamba e ao Fernando Kuvi por todo o apoio, encorajamento, dedicação e carinho. Além de serem uma grande referência tanto como pessoas quanto como profissionais.

Aos meus irmãos, a Luzia Odélia Canganja e ao Valter Canganja Mphili por vos carregar sempre no meu coração e na minha mente, mesmo que distante sempre estão ao meu lado.

E à toda minha família, amigos, colegas e todos que contribuíram direta ou indiretamente na minha formação.

"Não olhe onde você caiu, mas onde você escorregou".
Provérbio africano

Resumo

O sono causa mais acidentes que o álcool, a detecção de sonolência nos motoristas é o procedimento mais necessário para evitar acidentes rodoviários. Para tanto, esse trabalho objetiva fazer a detecção de sonolência usando sensores de PPG (fotopletismografia) e GSR (resposta galvânica da pele) para medir sinais fisiológicos do motorista e que alertar o motorista quando ele está ficando sonolento e pode estar em risco de adormecer ao volante.

A metodologia que será realizada é a detecção da sonolência do próprio autor, monitorando os sinais corporais durante vários dias, especialmente durante os períodos de sono, com o objetivo de evitar dormir. A metodologia seguirá os seguintes passos: escolha dos sensores, coleta de dados e análise dos dados.

Os possíveis resultados incluem: Identificação dos sinais corporais mais relevantes para detectar a sonolência, como a diminuição da frequência cardíaca e o aumento da variabilidade da frequência cardíaca. Desenvolvimento de um sistema de monitoramento de sonolência que possa alertar o motorista em tempo real com um aviso sonoro ou visual para que ele possa tomar medidas para descansar ou mudar de motorista. Validação da metodologia de detecção da sonolência do próprio autor por meio da comparação dos resultados com outros estudos e coleções de dados existentes na literatura científica e aumento da conscientização sobre a importância da detecção da sonolência no contexto da segurança rodoviária, levando à implementação de medidas preventivas mais efetivas para reduzir o número de acidentes causados pela sonolência ao volante.

Palavras-chaves: Sensores de fotopletismografia. Sensores de resposta galvânica da pele. Sonolência.

Abstract

Sleep causes more accidents than alcohol, the detection of drowsiness in drivers is the most necessary procedure to avoid road accidents. Therefore, this work aims to detect drowsiness using PPG (photoplethysmography) and GSR (galvanic skin response) sensors to measure the driver's physiological signals and to alert the driver when he is becoming drowsy and may be at risk of falling asleep while driving. steering wheel.

The methodology that will be carried out is the detection of the author's own sleepiness, monitoring body signals for several days, especially during periods of sleep, with the aim of avoiding sleep. The methodology will follow the following steps: choice of sensors, data collection and data analysis.

Possible outcomes may include: Identification of body signals most relevant to detect drowsiness, such as decreased heart rate and increased heart rate variability. Development of a drowsiness monitoring system that can alert the driver in real time with an audible or visual warning so that he can take steps to rest or change drivers. Validation of the author's own drowsiness detection methodology by comparing the results with other studies and existing data collections in the scientific literature and raising awareness about the importance of drowsiness detection in the context of road safety, leading to the implementation of preventive measures most effective in reducing the number of accidents caused by drowsy driving.

Key-words: Photoplethysmography sensors. Galvanic skin response sensors. Somnolence.

Lista de ilustrações

Figura 1 – Principais causas de acidentes de trânsito nas rodovias federais do Brasil (Polícia Rodoviária Federal, 2024). 17
Figura 2 – Princípio de funcionamento dos sensores PPG. Adaptado de (ZHAO et al., 2017). 25
Figura 3 – Sinais de PPG durante estágios de sono. Adaptado de (KORKALAINEN et al., 2020). 26
Figura 4 – Modo transmissão (a) e modo reflexão (b). Adaptado de (ALMARSHAD MD SAIFUL ISLAM; BAHAMMAM, 2022). 26
Figura 5 – Sinais de ECG e PPG. Adaptado (PETER; NOURY; CERNY, 2014). . 27
Figura 6 – Configuração GSR e suas conexões. 32
Figura 7 – Imagem modificada das Atividade GSR. Adaptado (INDURSKY; MARKELOV, 2017). 33
Figura 8 – Diagrama de pinagem do ESP32 (ESP32-DevKitC...,). 34
Figura 9 – Diagrama representando o funcionamento do protocolo MQTT 38
Figura 10 – Interface do Node-RED com suas principais áreas destacadas: (1) Área de construção de fluxos, onde os nós são interconectados para criar aplicações; (2) Barra lateral esquerda com a biblioteca de nós disponíveis, incluindo os adicionais (como o Node-RED Dashboard 2.0); (3) Barra lateral direita com abas de informações do nó selecionado, depuração e configuração do dashboard. 40
Figura 12 – Relação entre autores e tópicos sobre sonolência e sistemas vestíveis. . 44
Figura 11 – Estudos associados às palavras-chave na base de dados Scopus. 45
Figura 13 – Configuração do projeto, excetuando-se as etapas de classificação, resultados e alarme, previstas para trabalhos futuros. 48
Figura 14 – Diagrama conceitual da interação entre os componentes do sistema. Os sensores PPG/GSR enviam dados ao ESP32, que os publica no Mosquitto Broker via MQTT. O Node-RED processa e visualiza os dados, podendo acionar alertas. 49
Figura 15 – Diagrama esquemático do sistema de detecção de sonolência em motoristas com sensores MAX30102 e GSR, ESP32, display OLED e buzzer. 50
Figura 16 – Conexões dos sensores MAX30102, GSR, OLED e buzzer com a placa ESP32 para o sistema de detecção de sonolência. 50
Figura 17 – Identificação dos principais componentes do sistema de detecção de sonolência, incluindo sensores GSR e MAX30102, display OLED, bateria e a placa ESP32. As setas indicam os componentes do sistema. 53

Figura 18 – Configuração dos nós no Node-RED para recepção dos dados dos sensores via MQTT. 54
Figura 19 – Interface do *dashboard* desenvolvida no Node-RED para visualização dos dados em tempo real. 54
Figura 20 – Arquitetura conceitual do sistema proposto para detecção de sonolência. 55
Figura 21 – Dispositivo de detecção de sonolência utilizando sensores PPG e GSR integrados ao ESP32. 56
Figura 22 – Fluxo de funcionamento do sistema embarcado para detecção de sonolência. O diagrama representa as etapas sequenciais de aquisição, processamento e análise dos sinais fisiológicos no ESP32. A lógica envolve a leitura dos sensores MAX30102 e GSR, aplicação de filtros e cálculos de BPM, SpO_2 e condutância da pele. Caso os parâmetros indicativos de sonolência sejam detectados, o sistema aciona um alerta sonoro e transmite os dados via MQTT para monitoramento remoto em tempo real. 62
Figura 23 – Distribuição comparativa da Frequência Cardíaca (BPM) entre os estados de Sono (N=537) e Vigília (N=52). 65
Figura 24 – Distribuição comparativa da Saturação de Oxigênio (SpO_2) entre os estados de Sono (N=537) e Vigília (N=55). Nota-se uma maior dispersão e uma leve redução da SpO_2 durante o sono. 65
Figura 25 – Distribuição comparativa da Condutância da Pele (GSR) entre os estados de Sono (N=537) e Vigília (N=55). A condutância se mostrou consistentemente mais elevada durante o período de sono neste estudo. 66
Figura 26 – Inclusão de bibliotecas e inicialização de objetos globais. 80
Figura 27 – Definição de constantes e variáveis para conectividade, sensores e controle do sistema. 80
Figura 28 – Configuração do display OLED e definição dos bitmaps para os ícones. 81
Figura 29 – Funções responsáveis pela conexão à rede Wi-Fi e pelo gerenciamento da comunicação com o servidor MQTT. 82
Figura 30 – Implementação da função média móvel simples e Função setup que inicializa todos os componentes de hardware e software do dispositivo. . 83
Figura 31 – Parte inicial do loop principal, focada na leitura do GSR, detecção de batimentos, cálculo de BPM e atualização visual no display OLED. . . 84
Figura 32 – Continuação do loop - Algoritmo de cálculo de SpO2 e tratamento de ausência de leitura. 84
Figura 33 – Trecho final do loop principal, responsável por Publicação de dados via MQTT e lógica de alerta de sonolência. 85

Lista de tabelas

Tabela 1 – Sinistros de Trânsito nas Rodovias do Brasil (2021–2024) 18
Tabela 2 – Modos de operação e consumo do ESP32 36
Tabela 3 – Níveis de Qualidade de Serviço (QoS) no MQTT 37
Tabela 4 – Nós do Node-RED 40
Tabela 5 – Comparação aprimorada entre trabalhos sobre detecção de sonolência em motoristas. 46
Tabela 6 – Especificações técnicas dos componentes utilizados no sistema 52
Tabela 7 – Análise estatística da Frequência Cardíaca (BPM) usando o teste t de Welch. 65
Tabela 8 – Análise estatística da SpO_2 usando o teste t de Welch. 66
Tabela 9 – Análise estatística da Condutância da Pele (GSR) usando o teste t de Welch. 66
Tabela 10 – Desempenho dos classificadores baseados em limiar único para cada parâmetro fisiológico, utilizando o estado "dormindo"como proxy para "sonolento". 67

Lista de abreviaturas e siglas

BLE	Bluetooth Low Energy
CNNs	Redes Neurais Convolucionais
DF	Distrito Federal
ECG	Eletrocardiograma
EDA	Electrodermal Activity
EEG	Eletroencefalografia
EOG	Electrooculography
FC	Frequência cardíaca
GSR	Galvanic Skin Response
HF	High Frequency
HR	Heart Rate
HRV	Heart Rate Variability
IA	Inteligência Artificial
IoT	Internet of Things
KSS	Karolinska Sleepiness Scale
LED	Light Emitting Diode
LF	Low Frequency
LSTMs	Long Short-Term Memory
MATLAB	Matrix Laboratory
MQTT	Message Queuing Telemetry Transport
PERCLOS	Percentage of Eye Closure Time over the Total Observation Time
PPG	Plethysmography Photoplethysmography
PRF	Polícia Rodoviária Federal

PRV	Heart Rate Variability
REM	Rapid Eye Movement
RNNs	Redes Neurais Recorrentes
RR	R-R Interval
SMA(t)	Média móvel simples
SVM	Support Vector Machine
SWS	Slow Wave Sleep
SpO2	Saturação periférica de oxigênio no sangue

Lista de símbolos

bpm	batimentos cardíacos por minuto
Hz	Unidade SI, frequência de um fenômeno periódico cujo período tem a duração de um segundo
V	Tensão elétrica, em Volts
R	Razão entre absorbâncias normalizadas
ϵ	Coeficiente de extinção molar
α	Fator de amortecimento
µS	Microsiemens

Sumário

1 INTRODUÇÃO . . . 17
1.1 Contextualização . . . 17
1.2 Definição do problema . . . 20
1.3 Objetivos . . . 21
1.3.1 Objetivo geral . . . 21
1.3.2 Objetivos Específicos . . . 21

2 FUNDAMENTAÇÃO TEÓRICA . . . 23
2.1 Sensores PPG . . . 23
2.1.1 Limitações Técnicas e Estratégias de Mitigação . . . 23
2.1.2 Princípio de Funcionamento do Sensor PPG . . . 24
2.1.3 Medição da frequência cardíaca . . . 27
2.1.4 Medição de Saturação de Oxigênio . . . 28
2.1.5 Calibração do Sensores PPG . . . 29
2.2 Sensor GSR . . . 30
2.2.1 Limitações Técnicas e Estratégias de Mitigação . . . 30
2.2.2 Princípio de Funcionamento do Sensor GSR . . . 31
2.3 Microcontrolador ESP32 . . . 33
2.3.1 Consumo Energético . . . 35
2.4 MQTT (Message Queuing Telemetry Transport) . . . 36
2.4.1 Funcionamento do MQTT . . . 37
2.4.2 Escalabilidade com MQTT e Node-RED . . . 38
2.5 Node-RED . . . 39
2.6 Mosquitto Broker . . . 41
2.7 Filtros para processamento de sinais . . . 42
2.8 Aspectos Éticos e Proteção de Dados . . . 43
2.9 Estado da Arte . . . 44

3 METODOLOGIA . . . 48
3.1 Requisitos de Hardware . . . 49
3.2 Configuração do Node-RED . . . 53
3.3 Aquisição dos dados dos sensores PPG e GSR . . . 56
3.4 Processamento dos sinais . . . 58
3.5 Protocolo Experimental para Validação Preliminar . . . 59
3.6 Implementação do sistema no microcontrolador ESP32 . . . 60
3.7 Critérios de Avaliação de Desempenho . . . 63

4 RESULTADOS E ANÁLISE 64
4.1 Análise Estatística e Pré-processamento dos Sinais 64
4.1.1 Mitigação de Artefatos no Pré-processamento 64
4.1.2 Análise Comparativa dos Parâmetros Fisiológicos 64
4.2 Avaliação de Desempenho do Sistema de Detecção 66
4.3 Discussão dos Resultados e Proposta de Validação 67
4.3.1 Análise Crítica dos Sensores e Potencial para Fusão de Dados 67
4.3.2 Proposta de Validação com Padrão-Ouro e Limitações do Estudo 68
4.3.3 Comparação com a Literatura e Diferenciais do Sistema Proposto 69

5 CONSIDERAÇÕES FINAIS 70

REFERÊNCIAS 74

APÊNDICE A – CÓDIGO-FONTE DO ESP32 (REPRESENTADO EM IMAGENS) 80

APÊNDICE B – DISPONIBILIDADE DE DADOS E CÓDIGO-FONTE 86

1 Introdução

1.1 Contextualização

A segurança no trânsito é uma preocupação constante no Brasil, e os dados mais recentes da Polícia Rodoviária Federal (Polícia Rodoviária Federal, 2024) reforçam a gravidade de determinadas causas de acidentes nas rodovias federais. Entre os anos de 2021 e 2024, foram registrados mais de 629 mil acidentes de trânsito, resultando em milhares de feridos e vítimas fatais. Um fator de risco que se destaca de forma recorrente nesse período é a sonolência ao volante.

De acordo com os dados apresentados na Tabela 1, a categoria **Condutor Dormindo** foi responsável por 56.898 acidentes ao longo dos quatro anos analisados, resultando em 3.912 mortes e deixando 29.981 feridos. Em 2024, por exemplo, esse fator ocasionou 15.640 sinistros, sendo a quarta maior causa de acidentes com mortes.

Esses números evidenciam que a sonolência continua sendo uma das principais causas de acidentes graves nas rodovias, com impactos comparáveis aos da ingestão de álcool. A constância desses índices ao longo dos anos reforça que se trata de um problema persistente e subestimado, exigindo soluções tecnológicas acessíveis, eficazes e não invasivas para sua detecção precoce.

Neste cenário, o desenvolvimento de dispositivos portáteis e embarcados capazes de identificar sinais fisiológicos de fadiga — como alterações na frequência cardíaca e condutância da pele — pode contribuir de forma significativa para a redução de acidentes e a preservação de vidas nas estradas brasileiras.

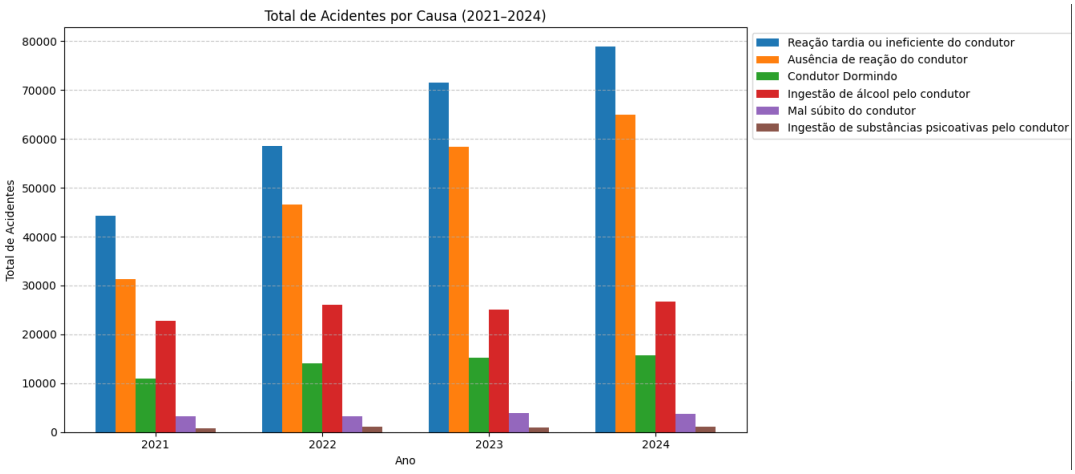


Figura 1 – Principais causas de acidentes de trânsito nas rodovias federais do Brasil (Polícia Rodoviária Federal, 2024).

Tabela 1 – Sinistros de Trânsito nas Rodovias do Brasil (2021–2024)

Causa do Acidente	Ano	Total	Feridos	Mortos	Mortos e Feridos
2024					
Reação tardia ou ineficiente do condutor	2024	78861	37905	3695	41600
Ausência de reação do condutor	2024	64989	31061	3622	34683
Condutor Dormindo	2024	15640	8003	1128	9131
Ingestão de álcool pelo condutor	2024	26780	10853	1463	12316
Mal súbito do condutor	2024	3790	1796	422	2218
Ingestão de substâncias psicoativas	2024	1115	481	114	595
Subtotal 2024		**192175**	**90199**	**10444**	**100543**
2023					
Reação tardia ou ineficiente do condutor	2023	71497	34217	2823	37040
Ingestão de álcool pelo condutor	2023	25129	10149	1230	11379
Ausência de reação do condutor	2023	58470	27277	3103	30380
Condutor Dormindo	2023	15298	8092	1137	9229
Mal súbito do condutor	2023	3821	1574	515	2089
Ingestão de substâncias psicoativas	2023	1015	372	102	474
Subtotal 2023		**175230**	**81681**	**8910**	**90591**
2022					
Ingestão de álcool pelo condutor	2022	26071	10816	1182	11998
Reação tardia ou ineficiente do condutor	2022	58501	27862	2678	30540
Ausência de reação do condutor	2022	46551	22036	2310	24346
Condutor Dormindo	2022	13995	7560	945	8505
Ingestão de substâncias psicoativas	2022	1056	485	53	538
Mal súbito do condutor	2022	3167	1667	395	2062
Subtotal 2022		**149341**	**70426**	**7563**	**77989**
2021					
Ingestão de álcool pelo condutor	2021	22851	9807	1025	10832
Reação tardia ou ineficiente do condutor	2021	44239	21074	1987	23061
Condutor Dormindo	2021	10965	6326	702	7028
Ausência de reação do condutor	2021	31297	14884	1651	16535
Mal súbito do condutor	2021	3169	1612	295	1907
Ingestão de substâncias psicoativas	2021	695	250	56	306
Subtotal 2021		**113216**	**53953**	**5716**	**59669**

Fonte: Dados hipotéticos para exemplo (adaptados de relatórios de trânsito).

Para aprimorar a segurança no trânsito e prevenir a distração de motoristas, têm sido propostos dispositivos portáteis, como smartwatches. A sonolência ao volante repre-

senta um fator de risco significativo, e diversos estudos têm sido realizados com o objetivo de detectá-la.

Segundo (SABET et al., 2012), a sonolência foi detectada por meio de uma câmera que monitorava o rosto e os olhos do motorista. No entanto, o método apresentou limitações em relação à variação de luminosidade e tonalidade da pele. De acordo com (HACHISUKA, 2013), a análise da expressão facial foi utilizada para identificar a sonolência. Embora eficaz, esse método exige grande capacidade de processamento, dificultando sua implementação em dispositivos móveis atuais.

Conforme (XU et al., 2014), foi desenvolvido um sistema de detecção de sonolência em smartphones, utilizando a métrica PERCLOS (percentual de fechamento dos olhos). No entanto, o uso direto do dispositivo pode distrair o motorista — fator que também contribui para o aumento de acidentes. Já (EBRAHIM; STOLZMANN; YANG, 2013) empregaram eletrooculografia (EOG) para monitorar os movimentos oculares, em um simulador de condução baseado na plataforma da Mercedes-Benz.

De acordo com (LIM; CHIA; CHIN, 2015), o estado dos olhos foi reconhecido com base em registros de eletroencefalografia (EEG), mas o método apresentou taxa de detecção de apenas 31% e requer que o usuário utilize sensores EEG durante a condução. Além de caros, esses sensores são suscetíveis a ruídos provocados por movimentos. Em outro estudo, (RAMESH; NAIR; KUNNATH, 2011) propuseram um sistema baseado em sensores fisiológicos instalados no volante, que mediam frequência cardíaca e eletrocardiograma (ECG). No entanto, a instalação exigia diversas configurações e apresentava baixa precisão em tempo real.

Segundo (ZILBERG et al., 2007), outro sistema tentou detectar sonolência com base em movimentos corporais captados pela cadeira do veículo. Contudo, a abordagem também apresentou limitações, como a complexidade de configuração e a necessidade de múltiplos sensores, o que inviabiliza sua aplicação em tempo real.

As informações disponíveis em (LAWOYIN et al., 2014) são limitadas, mas o estudo propõe o monitoramento da sonolência por meio da análise dos movimentos da direção das rodas, com uma precisão de apenas 90%. Já (LI; CHUNG, 2014) estimaram o grau de fechamento dos olhos utilizando sensores EEG, mas novamente a exigência do uso desses sensores representa um desafio prático. Por fim, (LEE; CHUNG, 2012) combinaram sinais faciais e biofisiológicos para monitorar o estado de alerta do motorista. Diferente de abordagens anteriores, que focavam exclusivamente em sinais fisiológicos ou comportamentais, o sistema propõe a fusão de ambas as fontes para aumentar a precisão da detecção.

Diante desses estudos, é evidente que ainda há muito espaço para o desenvolvimento de soluções mais eficientes e acessíveis para detectar a sonolência do motorista,

visando garantir a segurança no trânsito. O uso de dispositivos portátil pode ser uma alternativa interessante, desde que sejam desenvolvidos de maneira a evitar distrações e garantir a precisão dos resultados.

A escolha pelos sensores PPG (Photoplethysmography) e GSR (Galvanic Skin Response) neste trabalho baseia-se na busca por uma solução fisiológica não invasiva, de baixo custo, alta portabilidade e com bons indicadores de alteração no estado de vigília. O sensor PPG permite monitorar, com boa confiabilidade, a frequência cardíaca e a variabilidade do ritmo cardíaco (HRV), reconhecidamente afetadas em estados de sonolência devido à modulação do sistema nervoso autônomo. Já o sensor GSR fornece uma medida direta da atividade simpática, refletindo alterações no nível de excitação do indivíduo — o que tende a decrescer com o aumento da sonolência.

Ambos os sensores possuem ampla documentação técnica, bibliografia consolidada e são facilmente integráveis a microcontroladores modernos, como o ESP32, permitindo desenvolvimento de sistemas embarcados leves e eficazes para monitoramento em tempo real. Além disso, diferentemente de sensores ópticos frontais ou eletrodos de contato direto com o couro cabeludo, PPG e GSR podem ser implementados em wearables discretos, como pulseiras ou luvas, tornando-os mais viáveis para aplicação prática no trânsito.

Assim, a opção por PPG e GSR é respaldada tanto pela revisão crítica dos métodos existentes quanto pela viabilidade técnica e potencial de aplicação prática, evidenciando uma escolha consciente e alinhada aos objetivos de segurança, usabilidade e eficiência do sistema proposto.

1.2 Definição do problema

O desenvolvimento de um sistema embarcado para detecção de sonolência por meio de sinais fisiológicos enfrenta desafios técnicos relevantes, especialmente em condições reais de uso. A aquisição, filtragem e interpretação de dados provenientes de sensores como PPG e GSR exigem precisão e estabilidade, principalmente quando realizados em microcontroladores de capacidade limitada, suscetíveis a ruídos e interferências ambientais.

Este trabalho define o problema como a investigação da viabilidade de um sistema simples, acessível e funcional, baseado em sensores fisiológicos e no microcontrolador ESP32, capaz de detectar alterações associadas à sonolência em tempo real. O escopo do projeto limita-se à validação técnica do sistema com testes realizados em um único indivíduo, o próprio autor, o que permite o foco no funcionamento do hardware e software em condições reais de coleta, processamento e visualização dos sinais.

É importante destacar que a escolha por uma amostra única não representa uma limitação acidental, mas sim uma delimitação consciente do escopo, que visa garantir

o desenvolvimento e a validação funcional inicial do sistema. Testes mais amplos com múltiplos usuários e validação clínica ficam para trabalhos futuros, considerando também aspectos éticos importantes, como consentimento informado e proteção de dados pessoais, conforme previsto na legislação vigente LGPD.

Entre os principais desafios técnicos, destacam-se a instabilidade nas leituras dos sensores, a definição de limiares confiáveis a partir de dados de uma única amostra, a aplicação eficiente de filtros digitais sob restrições computacionais e a sincronização precisa entre aquisição e apresentação dos sinais. Além disso, o sistema é pensado para atender principalmente motoristas, profissionais que dependem de níveis elevados de atenção, embora sua aplicação possa ser ampliada futuramente para outros perfis de usuários.

Dessa forma, o problema central deste trabalho é validar a funcionalidade de um sistema embarcado simples para detecção de sonolência, considerando as limitações técnicas, amostrais e éticas, estabelecendo uma base para avanços futuros que possam ampliar o alcance e a robustez do sistema.

1.3 Objetivos

1.3.1 Objetivo geral

Desenvolver um sistema de detecção de sonolência em motoristas utilizando sensores de fotopletismografia (PPG) (MAX30102) e resposta galvânica da pele (GSR), integrados ao microcontrolador ESP32, e monitorado em tempo real através do Node-RED, com notificações exibidas em um display OLED e acionadas por um sinal sonoro.

1.3.2 Objetivos Específicos

- Projetar e montar o circuito de aquisição de sinais fisiológicos utilizando os sensores PPG (MAX30102) e GSR, integrando-os fisicamente ao microcontrolador ESP32.
- Desenvolver o firmware embarcado no ESP32 para aquisição contínua dos sinais de condutância da pele, frequência cardíaca e saturação de oxigênio.
- Construir um sistema de visualização baseado em dashboards no Node-RED, para monitoramento em tempo real dos dados fisiológicos e do estado de sonolência.
- Integrar um módulo de alerta embarcado utilizando display OLED e buzzer, responsável por emitir notificações visuais e sonoras em caso de detecção de sonolência.
- Realizar a validação funcional do sistema embarcado completo por meio de testes experimentais em ambiente controlado.

- Refinar o modelo de detecção e os parâmetros do sistema a partir da análise dos resultados experimentais, otimizando sua precisão e confiabilidade.

2 Fundamentação teórica

Neste capítulo, é apresentado a base teórico do projeto a partir dos principais conceitos e princípios de funcionamento dos sensores PPG e GSR para entender o sistema de aquisição de dados. Neste capítulo, também será abordado o estado da arte para sistemas de detecção de sonolência pela Esp32 e Matlab.

2.1 Sensores PPG

Apesar da diversidade de designs disponíveis para sensores de fotopletismografia (PPG), todos têm a função de medir alterações no volume sanguíneo e produzir resultados comparáveis (CHEANG; PECK; SMITH, 2003). Um sensor PPG comum utiliza um ou mais LEDs para emitir luz na região do tecido, enquanto um fotodiodo monitora a quantidade de luz refletida que não é absorvida pelo tecido (FISCHER et al., 2017).

Nos experimentos científicos, os LEDs vermelhos e verdes são os mais comumente empregados, embora alguns estudos também utilizem LEDs amarelos (LAI; KIM, 2015). A luz com comprimentos de onda mais longos tende a penetrar mais profundamente nos tecidos (SPIGULIS et al., 2007). Por exemplo, a luz infravermelha é mais eficiente na penetração da pele do que a luz verde. No entanto, é importante destacar que a luz infravermelha é mais suscetível a artefatos de movimento, conforme apontado por Spigulis (SPIGULIS et al., 2007). Dessa forma, os LEDs verdes, que possuem comprimentos de onda mais curtos, são frequentemente preferidos em aplicações biomédicas por apresentarem maior estabilidade frente a movimentos.

2.1.1 Limitações Técnicas e Estratégias de Mitigação

Apesar da sua ampla aplicabilidade e simplicidade, a aquisição de sinais PPG está sujeita a diversas limitações técnicas que podem comprometer a qualidade e a confiabilidade dos dados. A principal fonte de erro são os artefatos de movimento. Movimentos do usuário, mesmo que sutis, causam variações na pressão de contato entre o sensor e a pele, além de deslocamentos relativos que alteram o caminho óptico da luz. Esses artefatos geram distorções no sinal PPG que podem mascarar ou se sobrepor à componente pulsátil cardíaca, levando a estimativas errôneas da frequência cardíaca e da SpO2 (ELGENDI, 2012; ALLEN, 2007).

Outras limitações incluem:

- **Variações Interindividuais:** Fatores como a pigmentação da pele (melanina), es-

pessura do tecido e perfusão sanguínea periférica variam significativamente entre indivíduos. A melanina, por exemplo, absorve luz e pode atenuar o sinal, exigindo maior intensidade luminosa do LED ou algoritmos de ganho adaptativo (CASTANEDA et al., 2018).

- **Baixa Perfusão Periférica:** Em condições de frio, estresse ou certas patologias, o fluxo sanguíneo nas extremidades (como dedos e pulso) diminui. Isso resulta em um componente AC do sinal PPG com amplitude muito baixa, dificultando a detecção dos picos cardíacos e a medição acurada da SpO2.
- **Pressão de Contato do Sensor:** Uma pressão excessiva pode ocluir os vasos sanguíneos, atenuando ou interrompendo o sinal pulsátil. Por outro lado, uma pressão insuficiente pode resultar em um acoplamento óptico deficiente e maior suscetibilidade a artefatos de movimento (ALLEN, 2007).
- **Luz Ambiente:** A interferência da luz ambiente, especialmente de fontes que contêm componentes no espectro infravermelho (como luz solar ou lâmpadas incandescentes), pode saturar o fotodetector ou introduzir ruído no sinal, exigindo blindagem óptica adequada.

Para mitigar esses desafios, diversas estratégias podem ser empregadas. O uso de sensores inerciais (acelerômetros) em conjunto com o sensor PPG é uma abordagem comum para detectar e caracterizar os artefatos de movimento. Com base nesses dados, aplicam-se algoritmos de compensação, como a filtragem adaptativa (e.g., LMS, RLS) ou técnicas de separação de sinais (e.g., Análise de Componentes Independentes - ICA), que visam subtrair o ruído do sinal PPG original (ELGENDI, 2012). Além disso, o desenvolvimento de índices de qualidade do sinal (Signal Quality Index - SQI) permite avaliar a confiabilidade dos segmentos de dados em tempo real, descartando trechos corrompidos e evitando medições imprecisas.

2.1.2 Princípio de Funcionamento do Sensor PPG

Sensores de PPG detectam alterações no volume sanguíneo utilizando luz infravermelha. Essas alterações são resultado das variações de pressão nos vasos sanguíneos ao longo do ciclo cardíaco (AKAY, 2006). O sensor PPG é composto por uma fonte de luz — geralmente um LED infravermelho — e um fotodetector. A luz emitida penetra na pele, interage com os tecidos e vasos sanguíneos, e parte dela é absorvida ou refletida. A quantidade de luz detectada varia conforme o fluxo sanguíneo, sendo processada para gerar um sinal correspondente à atividade cardiovascular (ZHAO et al., 2017), como ilustrado na Figura 2.

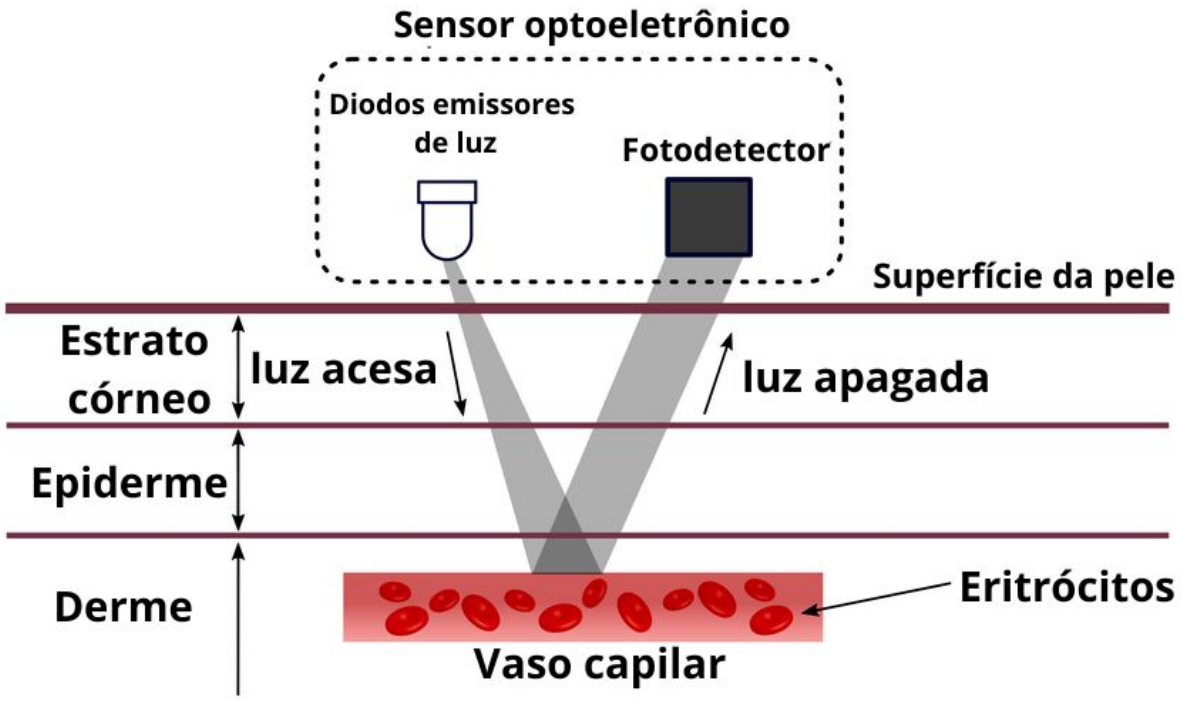


Figura 2 – Princípio de funcionamento dos sensores PPG. Adaptado de (ZHAO et al., 2017).

O sinal PPG apresenta dois componentes principais: (1) um componente DC, que representa a absorção constante de luz pelos tecidos; e (2) um componente AC, correspondente às pulsações causadas pelos batimentos cardíacos (ZHAO et al., 2017). A técnica baseia-se na Lei de Beer-Lambert, que relaciona a atenuação da luz à concentração dos elementos absorventes, sendo esta dependente do comprimento de onda (KARLEN et al., 2013).

A Figura 3 ilustra sinais PPG registrados durante diferentes estágios do sono. Observa-se que, em vigília, a frequência e a amplitude do sinal são relativamente constantes. Durante o sono N1, há variações irregulares na amplitude e queda de frequência. Nos estágios N2 e N3, a amplitude diminui progressivamente, com a presença de oscilações de baixa frequência. O sono REM, por sua vez, assemelha-se à vigília, embora com maior variação na amplitude do sinal.

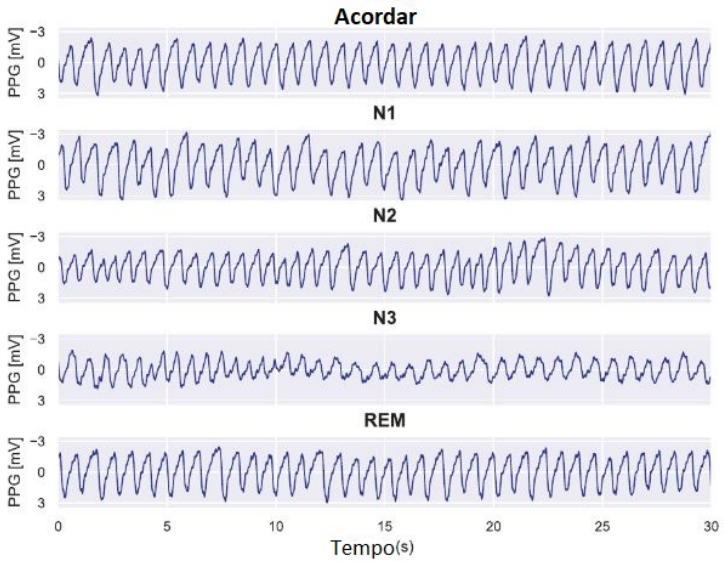


Figura 3 – Sinais de PPG durante estágios de sono. Adaptado de (KORKALAINEN et al., 2020).

Existem dois modos operacionais para sensores PPG: o modo de transmissão e o modo de reflexão, conforme ilustrado na Figura 4 (BOULNOIS, 1986).

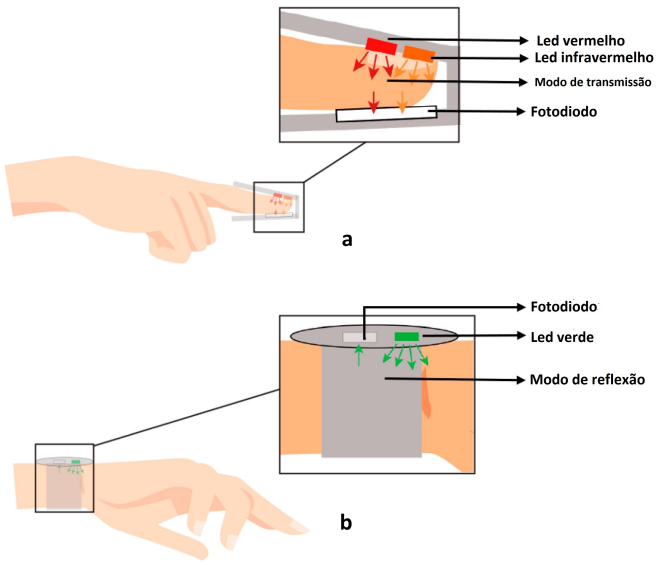


Figura 4 – Modo transmissão (a) e modo reflexão (b). Adaptado de (ALMARSHAD MD SAIFUL ISLAM; BAHAMMAM, 2022).

No modo de transmissão (Figura 4a), a fonte de luz e o fotodetector estão em lados opostos do tecido, como em sensores aplicados ao dedo. A luz atravessa o tecido, sendo atenuada pelas variações de volume sanguíneo. Já no modo de reflexão (Figura 4b), ambos estão no mesmo lado da pele. A luz refletida pelo tecido retorna ao detector, permitindo o monitoramento em locais onde a luz não pode atravessar, como o pulso (GUBBI; AMRUTUR, 2015; WANG; ZHENG, 2008; LEE et al., 2018).

2.1.3 Medição da frequência cardíaca

Um número significativo de tecnologias vestíveis projetadas para aplicações de longo prazo utiliza a oximetria de pulso não apenas para medir a saturação de oxigênio, mas também para extrair parâmetros relacionados à frequência cardíaca (FC). A tecnologia do sensor de fotopletismografia (PPG) tem facilitado enormemente o desenvolvimento de dispositivos de monitoramento da FC devido à sua simplicidade e custo-benefício. Tipicamente, esses dispositivos requerem apenas um LED para capturar os sinais necessários.

Existem principalmente dois métodos utilizados para derivar a FC a partir dos sinais de PPG. O primeiro método envolve a análise da forma do sinal de PPG para detectar o ciclo cardíaco. Este sinal é gerado pela absorção de luz pelo sangue arterial pulsátil, onde os picos correspondem a eventos sistólicos após a contração ventricular, refletindo aumentos no volume sanguíneo arterial e na absorção de luz. É importante notar que esses picos no sinal de absorção têm um significado fisiológico distinto em comparação com os do sinal transmitido como na Figura 5.

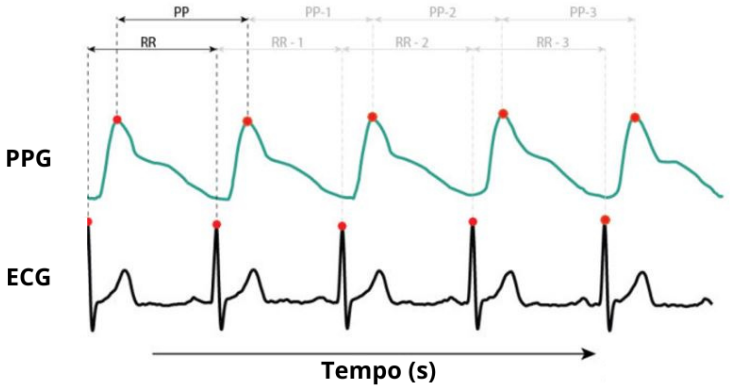


Figura 5 – Sinais de ECG e PPG. Adaptado (PETER; NOURY; CERNY, 2014).

O intervalo entre picos sucessivos (intervalo PP) corresponde diretamente à duração de um ciclo cardíaco. A partir deste intervalo, o parâmetro de FC pode ser calculado usando a fórmula:

$$Frequênciacardíaca = \frac{F_s \times 60}{intervaloPP} \tag{2.1}$$

A mesma informação relativa à frequência dos batimentos cardíacos pode ser obtida a partir dos sinais PPG e ECG. No caso do ECG, a frequência cardíaca (FC) é medida com precisão através do intervalo entre picos R, que são gerados durante a fase de sístole do ciclo cardíaco. Já o segundo método envolve a identificação da frequência das pulsações cardíacas a partir do sinal PPG. Para isso, utiliza-se uma transformada de Fourier para estimar a distribuição de energia na faixa de frequência do sinal PPG. Estudos demonstram que a frequência cardíaca está correlacionada com a frequência na qual o pico cardíaco aparece no espectro do PPG (CHOI; SHIN, 2017).

2.1.4 Medição de Saturação de Oxigênio

A medição da saturação de oxigênio SpO2 é um procedimento fundamental para a avaliação da saúde respiratória e cardiovascular. A técnica mais comum para essa finalidade é a oximetria de pulso, que utiliza dispositivos não invasivos chamados oxímetros de pulso para monitorar a saturação de oxigênio arterial (NITZAN; TAITELBAUM, 2008).

O princípio de funcionamento baseia-se na espectrofotometria. Oxímetros convencionais empregam dois Diodos Emissores de Luz (LEDs), que emitem luz em comprimentos de onda específicos — tipicamente vermelho ($\lambda \approx 660$ nm) e infravermelho ($\lambda \approx 940$ nm). A escolha desses comprimentos de onda é estratégica, pois a hemoglobina desoxigenada (Hb) e a oxiemoglobina (HbO), as duas principais formas de hemoglobina, apresentam coeficientes de absorção distintos nessas faixas do espectro (NITZAN; TAITELBAUM, 2008).

A análise se concentra na componente pulsátil do sinal luminoso detectado, que corresponde ao fluxo de sangue arterial. A partir dela, calcula-se a razão das absorbâncias normalizadas, conhecida como razão R (NITZAN; TAITELBAUM, 2008):

$$R = \frac{A_{\text{pulsátil},R}}{A_{\text{pulsátil},IR}} \tag{2.2}$$

Onde $A_{\text{pulsátil},R}$ e $A_{\text{pulsátil},IR}$ são as amplitudes da absorbância pulsátil para a luz vermelha e infravermelha, respectivamente.

Com base na lei de Beer-Lambert, essa razão pode ser expressa em função da SpO e dos coeficientes de extinção molar (ϵ) da Hb e da HbO (NITZAN; TAITELBAUM, 2008):

$$R = \frac{\epsilon_{\text{Hb},R} + (\epsilon_{\text{HbO2},R} - \epsilon_{\text{Hb},R}) \cdot \text{SpO2}}{\epsilon_{\text{Hb},IR} + (\epsilon_{\text{HbO2},IR} - \epsilon_{\text{Hb},IR}) \cdot \text{SpO2}} \tag{2.3}$$

Onde:

- $\epsilon_{\text{Hb},R}$ e $\epsilon_{\text{HbO2},R}$ são os coeficientes de extinção da Hb e HbO na luz vermelha;
- $\epsilon_{\text{Hb},IR}$ e $\epsilon_{\text{HbO2},IR}$ são os coeficientes de extinção da Hb e HbO na luz infravermelha.

Rearranjando a equação, é possível isolar a SpO2 para seu cálculo direto, expresso como uma porcentagem (NITZAN; TAITELBAUM, 2008):

$$\text{SpO2}(\%) = \frac{\epsilon_{\text{Hb},R} - \epsilon_{\text{Hb},IR} \cdot R}{(\epsilon_{\text{Hb},R} - \epsilon_{\text{HbO2},R}) + (\epsilon_{\text{HbO2},IR} - \epsilon_{\text{Hb},IR}) \cdot R} \times 100 \tag{2.4}$$

Contudo, a aplicação direta da lei de Beer-Lambert representa um modelo idealizado. Na prática, a luz que atravessa o tecido não segue um caminho retilíneo, sendo

influenciada por fenômenos complexos como o espalhamento (scattering), que prolonga o caminho óptico da luz de forma diferente para cada comprimento de onda.

Devido a esses fatores, a relação teórica entre R e SpO2 pode apresentar desvios significativos. Por essa razão, os oxímetros de pulso comerciais são submetidos a rigorosos processos de calibração empírica. Esse procedimento, que envolve a comparação das medições do oxímetro com análises de sangue arterial (in vitro) em voluntários, corrige as imprecisões do modelo teórico e assegura que as medições sejam confiáveis e clinicamente válidas (NITZAN; TAITELBAUM, 2008).

2.1.5 Calibração do Sensores PPG

A calibração de sensores fotopletismográficos (PPG), como os utilizados em oxímetros de pulso, é fundamental para garantir a acurácia nas estimativas tanto da saturação periférica de oxigênio (SpO_2) quanto da frequência cardíaca (FC). No caso da SpO_2, a calibração tradicional é realizada por meio de estudos clínicos controlados com voluntários saudáveis, que respiram misturas gasosas com diferentes frações inspiradas de oxigênio. Durante esses protocolos, realiza-se a gasometria arterial (SaO_2) — padrão-ouro — em momentos específicos, ao mesmo tempo em que são capturadas as razões ópticas (R) pelo dispositivo em calibração. A partir desses dados empíricos, constrói-se uma curva de calibração, usualmente por regressão polinomial ou linear, relacionando R à SpO_2 real, que é então incorporada ao firmware do oxímetro (PAGLIARI; OUTROS, 2024).

A estimativa da frequência cardíaca, por sua vez, é baseada na análise do sinal PPG no domínio do tempo ou da frequência, detectando picos ou ritmos oscilatórios que correspondem à pulsação arterial. Para a calibração da FC, é comum utilizar um dispositivo de referência com monitoramento eletrocardiográfico (ECG) ou um oxímetro validado, realizando medições simultâneas para comparar os valores obtidos. Essa validação cruzada permite ajustar algoritmos de detecção de picos, filtragem e segmentação de batimentos, a fim de reduzir erros como detecções falsas ou perdas de pulso, que impactam diretamente a acurácia da estimativa de FC (ELGENDI et al., 2022; SEDGHAMIZ, 2018).

Neste trabalho, considerando as limitações éticas, técnicas e logísticas para coleta invasiva de dados (como a gasometria arterial), foi adotada uma abordagem de calibração empírica simplificada. Utilizou-se como referência um oxímetro de pulso comercial previamente validado, capaz de medir SpO_2 e FC simultaneamente. Foram realizadas aquisições paralelas entre o sistema desenvolvido e o oxímetro de referência, utilizando o próprio autor como voluntário. Para a SpO_2, registraram-se pares de dados (R, SpO_2 do comercial) e aplicou-se regressão linear para derivar uma curva de calibração. Para a FC, compararam-se os valores batimento a batimento estimados pelo algoritmo de detecção de picos no sinal PPG com os valores fornecidos pelo dispositivo de referência.

Essa estratégia, embora limitada a um único sujeito e a um intervalo restrito de variação fisiológica, permitiu validar preliminarmente o desempenho do sistema em condições controladas. A calibração conjunta de SpO_2 e FC fornece uma base sólida para análises posteriores em ambientes mais realistas, como testes com múltiplos usuários e sob diferentes condições fisiológicas.

2.2 Sensor GSR

Segundo (LESTARI; ABUZAIRI, 2020), baseado em princípios físicos, o GSR é um ajuste das propriedades elétricas da pele em resposta a vários tipos de estímulos. Resposta galvânica da pele (GSR), também conhecida como atividade eletrodérmica (EDA), reflexos psicogalvânicos ou respostas de condutância da pele.

Os sinais GSR (Resposta Galvânica da Pele, em tradução livre) mostram mudanças elétricas medidas na superfície da pele humana que variam com as mudanças nos níveis de umidade da pele (sudorese) e refletem diferenças em seu sistema nervoso simpático, como mencionado na referência (NOURBAKHSH et al., 2012). Esses sinais são formados por mudanças na resistência corporal devido a mudanças na condutividade corporal causadas por respostas a secreções nas glândulas sudoríparas, de acordo com a referência (SYSOEV et al., 2014).

2.2.1 Limitações Técnicas e Estratégias de Mitigação

Embora o sinal de Resposta Galvânica da Pele (GSR), ou Atividade Eletrodérmica (EDA), seja um indicador valioso da ativação do sistema nervoso simpático, sua medição é suscetível a diversas fontes de ruído e limitações que precisam ser consideradas para uma interpretação correta. As principais limitações incluem:

- **Artefatos de Movimento:** Similarmente ao PPG, o movimento é uma fonte significativa de artefatos. O deslocamento dos eletrodos ou variações na pressão de contato com a pele podem gerar picos abruptos e transitórios no sinal, que podem ser erroneamente interpretados como respostas fásicas (reações a estímulos) (BOUCSEIN, 2012).
- **Variações Interindividuais e Intraindividuais:** A condutância basal da pele (nível tônico) e a amplitude das respostas (nível fásico) variam drasticamente entre diferentes indivíduos. Além disso, fatores como hidratação, temperatura corporal e estado emocional ao longo do dia podem alterar a resposta GSR de uma mesma pessoa, tornando as comparações diretas entre sujeitos ou sessões um desafio (BRAITHWAITE et al., 2013).

- **Influência da Temperatura e Umidade Ambiente:** A temperatura e a umidade do ambiente afetam diretamente a termorregulação do corpo e, consequentemente, a atividade das glândulas sudoríparas. Ambientes quentes ou úmidos podem elevar o nível tônico da condutância da pele, reduzindo a sensibilidade para detectar pequenas respostas fásicas (BOUCSEIN, 2012).

- **Saturação e Habituação da Resposta:** A apresentação de estímulos muito intensos ou repetidos em um curto intervalo de tempo pode levar à saturação das glândulas sudoríparas ou à habituação da resposta, onde a amplitude da reação diminui a cada estímulo subsequente. Isso pode complicar a análise de eventos emocionais discretos (DAWSON; SCHELL; FILION, 2007).

- **Estabilidade dos Eletrodos:** A qualidade do contato do eletrodo com a pele é crucial. A secagem do gel condutor (se utilizado) ou a polarização dos eletrodos ao longo do tempo podem causar um desvio (drift) no sinal, afetando principalmente a medição do componente tônico de baixa frequência.

2.2.2 Princípio de Funcionamento do Sensor GSR

Segundo (LESTARI; ABUZAIRI, 2020) sensor GSR mede a atividade das glândulas sudoríparas decorrente de estímulos emocionais. O princípio deste dispositivo baseia-se na variação da resistência da pele de acordo com nossos estados emocionais. Em momentos de maior estresse, a pele oferece menos resistência, enquanto que em momentos de relaxamento, a resistência da pele é maior. A redução da resistência da pele durante momentos de alto estresse se dá devido ao aumento do fluxo sanguíneo na pele. Dois eletrodos são fixados ao corpo e, quando há maior atividade de suor, o sinal é transmitido através dos eletrodos para o dispositivo GSR por meio de um fio condutor.

A resistência da pele varia com a atividade das glândulas sudoríparas, ou seja, quanto maior a atividade das glândulas sudoríparas, menor é a resistência da pele. Portanto, para medir o GSR, aproveitamos as propriedades elétricas da pele. Na verdade, o GSR mede a condutância e não a resistência. A condutância é o oposto da resistência e é medida em Siemens conforme a fórmula 2.5.

$$G = \frac{I}{V} \tag{2.5}$$

A Figura 6 mostra a configuração de um sensor de resposta galvânica da pele (GSR, do inglês *Galvanic Skin Response*) e suas conexões. O sensor GSR é amplamente utilizado para medir a condutância da pele, que pode ser influenciada por fatores como estresse, ansiedade e excitação. A configuração do sensor envolve a fixação de eletrodos na pele, geralmente nas pontas dos dedos, que detectam as mudanças na condutância

elétrica. Esses eletrodos são conectados a um circuito de aquisição de dados que registra as respostas galvânicas da pele. A imagem destaca a disposição dos eletrodos e as conexões necessárias para medir a resposta galvânica da pele usando o sensor GSR.



Figura 6 – Configuração GSR e suas conexões.

A Figura 7, mostra os resultados das atividade eletrodérmica durante o sono. Segundo (PURNAMASARI; JUNIKA, 2019) A baixa resistência da pele e o alto nível de atividade fásica (GSR) estão associados à atividade elétrica da pele e são frequentemente usados como medidas de excitação fisiológica.

Observa-se na Figura 7 que, quando uma pessoa está acordada e em um estado de vigília ativa, é comum verificar uma baixa resistência da pele e um alto nível de atividade fásica. Isso ocorre devido à excitação fisiológica do sistema nervoso autônomo simpático, que está associada ao estado de alerta e de vigilância.

Durante o período de relaxamento e fase de sonolência, é comum observar uma diminuição na atividade fásica e um aumento na resistência da pele, o que indica uma diminuição na excitação fisiológica. Isso ocorre porque o sistema nervoso autônomo parassimpático é ativado, o que está associado à fase de transição para o sono.

No segundo estágio do sono, a atividade fásica atinge seu máximo, indicando um aumento na excitação fisiológica. Durante o estágio de sono profundo (SWS), a atividade fásica atinge seu pico máximo e permanece elevada. Isso ocorre porque durante o sono profundo, o sistema nervoso simpático é ativado, o que aumenta a excitação fisiológica.

Durante o sono REM, a atividade fásica diminui novamente, indicando uma diminuição na excitação fisiológica. Isso ocorre porque durante o sono REM, o sistema nervoso

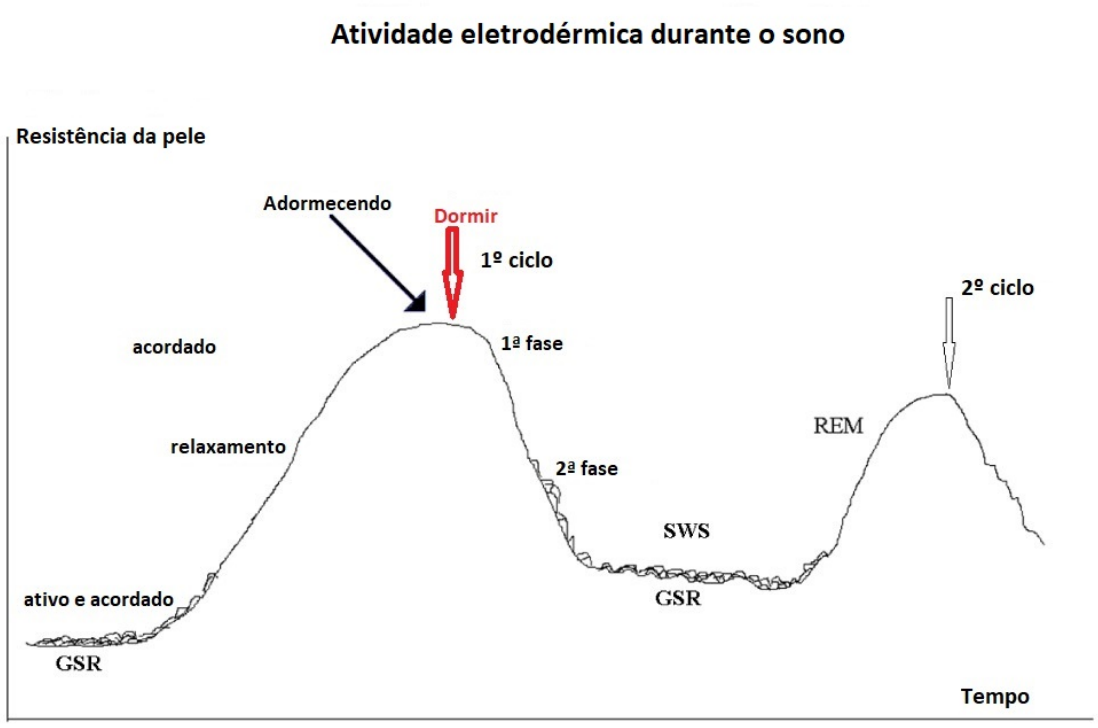


Figura 7 – Imagem modificada das Atividade GSR. Adaptado (INDURSKY; MARKELOV, 2017).

parassimpático é ativado novamente, o que está associado a uma diminuição na atividade elétrica da pele.

Para (LENG; LEE; CHUNG, 2015) Os sensores GSR (Resposta Galvânica da Pele) podem ser utilizados para detectar a sonolência através da medição da condutividade elétrica da pele, que é influenciada pela atividade sudorípara, a qual diminui quando uma pessoa está sonolenta. No entanto, é importante lembrar que o GSR não é a única ferramenta para detectar a sonolência e que outros fatores devem ser considerados, como a variação do padrão respiratório e a frequência dos movimentos oculares.

2.3 Microcontrolador ESP32

De acordo com Segundo (BABIUCH; FOLTYNEK; SMUTNý, 2019) a placa ESP32 é uma placa de desenvolvimento popular na área de eletrônica, pois é uma solução conveniente para projetos que envolvem conectividade Wi-Fi e Bluetooth, além de ter um microcontrolador dual-core de 32 bits. É muito versátil, com uma ampla gama de interfaces que permitem conectá-la a uma variedade de sensores e dispositivos externos. O uso da ESP32 pode simplificar a criação de dispositivos de IoT, tornando mais fácil para os engenheiros projetar e prototipar seus sistemas, tanto para projetos de hobby quanto para aplicações industriais. Além disso, a ESP32 também é compatível com uma variedade de

linguagens de programação, incluindo C, C++, Python e JavaScript, o que a torna ainda mais acessível para desenvolvedores e engenheiros de diferentes áreas de especialização.

A Figura 8 é um diagrama de pinagem do microcontrolador ESP32. Ele ilustra a organização dos pinos do ESP32, fornecendo informações sobre suas funções e capacidades. O diagrama é uma referência útil para entender a disposição física dos pinos do microcontrolador e para conectar corretamente os componentes externos.

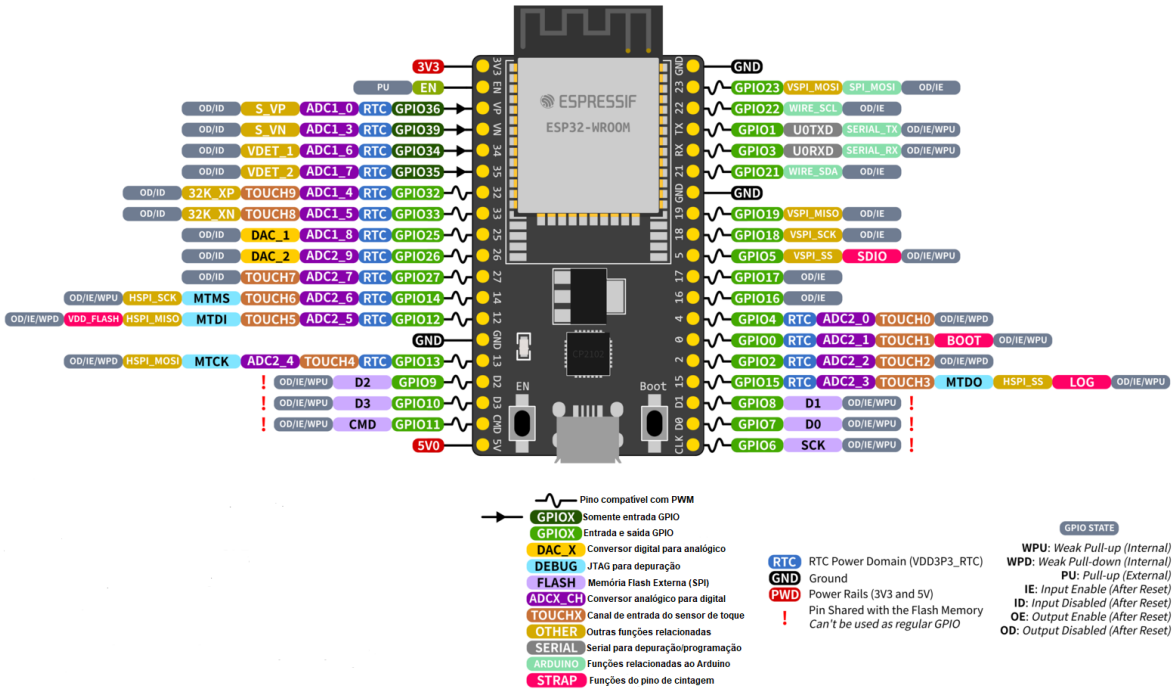


Figura 8 – Diagrama de pinagem do ESP32 (ESP32-DevKitC. . . ,).

O microcontrolador ESP32 é um dispositivo poderoso e versátil que oferece várias características e capacidades que o tornam adequado para a implementação do sistema de detecção de sonolência com sensores PPG e GSR. De acordo com o (ESP-WROOM-32. . . ,), várias características são exploradas, como:

- **Conectividade:** O ESP32 oferece conectividade Wi-Fi integrada, permitindo a comunicação sem fio com outros dispositivos e a transmissão de dados. Isso é particularmente útil para enviar alertas em tempo real para dispositivos externos ou para fins de monitoramento remoto.
- **Bluetooth Low Energy (BLE):** Além do Wi-Fi, o ESP32 suporta BLE, que é uma tecnologia de baixo consumo de energia usada para comunicação com dispositivos móveis e wearables. Essa conectividade pode ser aproveitada para enviar dados do sistema de detecção de sonolência para um smartphone ou smartwatch, permitindo que o motorista seja alertado sobre sua condição sonolenta.
- **Interfaces e Periféricos:** O ESP32 oferece uma variedade de interfaces e periféricos, como GPIOs, I2C, SPI e UART. Essas interfaces são necessárias para a

integração dos sensores PPG e GSR, pois esses sensores geralmente se comunicam por meio dessas interfaces. Os GPIOs também podem ser usados para controlar outros componentes, como LEDs ou buzzers, para fornecer alertas visuais ou sonoros.

- **Memória:** O ESP32 possui memória flash integrada para armazenamento de programas e dados, além de memória RAM para execução de código e manipulação de dados. Essa capacidade de armazenamento e processamento é importante para a implementação do sistema de detecção de sonolência, pois permite o processamento dos sinais dos sensores e a execução de algoritmos de detecção.
- **Suporte e Recursos:** O ESP32 possui uma comunidade de desenvolvedores ativa e uma ampla documentação disponível. Existem bibliotecas e exemplos de código prontos para uso que facilitam o desenvolvimento do sistema de detecção de sonolência. Além disso, existem placas de desenvolvimento específicas para o ESP32, como a ESP32 DevKit, que oferecem facilidades de prototipagem e testes.

Portanto, o microcontrolador ESP32 foi escolhido para implementar o sistema de detecção de sonolência graças à sua capacidade de processamento, conectividade integrada, interfaces adequadas para a integração dos sensores, capacidade de armazenamento e amplo suporte da comunidade. Ele oferece uma plataforma robusta e flexível para o desenvolvimento e a implementação do sistema proposto.

2.3.1 Consumo Energético

A eficiência energética é um aspecto fundamental em sistemas vestíveis, especialmente aqueles projetados para monitoramento contínuo, como o proposto neste trabalho. O microcontrolador utilizado, o **ESP32**, apresenta diversos modos de operação que permitem otimizar significativamente o consumo de energia, dependendo do perfil de uso do dispositivo.

O ESP32 opera tipicamente em modo ativo com consumo entre ~160 mA e 240 mA durante a transmissão via Wi-Fi. No entanto, quando não é necessária a comunicação ou processamento contínuo, é possível alternar para modos de baixo consumo, como *modem-sleep*, *light-sleep* e, principalmente, *deep-sleep*, onde o consumo pode ser reduzido para cerca de ~10 µA (Espressif Systems, 2023).

Além disso, estratégias como o uso de timers para ativar o ESP32 em intervalos regulares, a desativação de periféricos não utilizados e a limitação do tempo de ativação da interface Wi-Fi contribuem para reduzir o consumo global (Espressif Systems, 2022). Os sensores utilizados neste projeto, o **PPG (Photoplethysmography)** e o **GSR (Galvanic Skin Response)**, também devem ser analisados sob o ponto de vista energético. Embora tipicamente apresentem baixo consumo (na ordem de alguns miliamperes), a lei-

tura contínua pode ser otimizada com técnicas como *duty cycling* ou coleta em janelas temporais, de forma a manter a acurácia sem comprometer a autonomia da bateria (KIM; PARK, 2020).

Portanto, a adoção de políticas de gerenciamento energético é essencial para a viabilidade de longo prazo do sistema em aplicações reais. A Tabela 2 resume os principais modos de consumo do ESP32.

Tabela 2 – Modos de operação e consumo do ESP32

Modo de Operação	**Consumo Aproximado**
Ativo (Wi-Fi ON)	160–240 mA
Modem Sleep	30–50 mA
Light Sleep	~1 mA
Deep Sleep	~10 µA

2.4 MQTT (Message Queuing Telemetry Transport)

Em sistemas de Internet das Coisas (IoT), a comunicação entre dispositivos e a conexão com a Internet são requisitos essenciais para que os dispositivos possam interagir entre si e com sistemas de backend. O protocolo de comunicação MQTT (Message Queuing Telemetry Transport) tem se destacado como um padrão para a comunicação entre dispositivos em sistemas de IoT, devido às suas qualidades superiores em comparação com outros protocolos de comunicação.

O MQTT foi desenvolvido inicialmente pela IBM no final dos anos 90, com o objetivo de permitir a integração de sensores de petróleo a satélites, utilizando a infraestrutura dos protocolos TCP e IP. Com o tempo, o MQTT evoluiu para um protocolo mais abrangente, sendo utilizado em diversas aplicações de IoT. Em 2014, o protocolo foi formalizado como um padrão aberto, o que lhe conferiu maior suporte nas principais linguagens de programação e em diversas implementações de software livre, ampliando sua utilização em projetos de automação, monitoramento e sistemas embarcados (SONI; MAKWANA, 2017).

Como sugere seu nome, o MQTT é um protocolo de mensagens que suporta a comunicação assíncrona entre dispositivos. A principal característica dessa abordagem é o desacoplamento entre o emissor e o receptor das mensagens, tanto no tempo quanto no espaço. Isso torna o MQTT altamente escalável, adequado para ser utilizado em redes instáveis ou com baixa qualidade de conexão, como é comum em sistemas de IoT que operam em áreas remotas ou com infraestrutura limitada.

Uma das grandes vantagens do MQTT sobre outros protocolos de comunicação, como o HTTP, está no fato de que o MQTT opera de forma assíncrona. No HTTP, por exemplo, o cliente aguarda uma resposta do servidor para continuar a comunicação, o que

pode ser um problema em cenários de alta latência ou redes intermitentes. Já no MQTT, a comunicação é baseada em tópicos, onde os dispositivos podem enviar e receber mensagens de forma desacoplada e contínua, sem depender de uma resposta imediata. Isso torna o protocolo mais eficiente em termos de latência, permitindo que dispositivos mais simples e com menor poder de processamento se comuniquem de maneira eficaz e eficiente (SONI; MAKWANA, 2017).

Uma característica importante do MQTT, como destacado por (IBM, 2018), são os diferentes níveis de Qualidade de Serviço (QoS) disponíveis para garantir a entrega de mensagens. Esses níveis equilibram a confiabilidade da entrega das mensagens com a eficiência da transmissão, permitindo que o sistema seja ajustado conforme as necessidades da aplicação. Conforme ilustrado na Tabela abaixo (IBM, 2018).

Tabela 3 – Níveis de Qualidade de Serviço (QoS) no MQTT

Nível de QoS	**Descrição**
QoS 0	A mensagem é entregue no máximo uma vez, sem garantias de entrega. Ideal para aplicações onde a perda de dados não representa um problema.
QoS 1	A mensagem é entregue pelo menos uma vez, com confirmação de recebimento. Oferece maior garantia de entrega, mas pode resultar em mensagens duplicadas.
QoS 2	A mensagem é entregue exatamente uma vez, garantindo que não ocorra duplicação. Proporciona maior confiabilidade, porém com maior latência devido ao processo de verificação.

2.4.1 Funcionamento do MQTT

A base do funcionamento do protocolo MQTT (Message Queuing Telemetry Transport) é a definição de duas entidades principais na rede: broker e clientes. O broker é um servidor central que recebe e gerencia todas as mensagens enviadas pelos clientes, roteando essas mensagens para os destinos apropriados. Esse servidor se torna responsável por garantir que as informações cheguem corretamente a cada dispositivo inscrito nos tópicos pertinentes (USMANI, 2021).

Os clientes são dispositivos que se comunicam com o broker e podem ter diferentes funções dentro da rede. Eles podem ser tanto publishers quanto subscribers. Um publisher é o dispositivo que publica mensagens em um tópico específico, enquanto um subscriber é o dispositivo que se inscreve para receber mensagens de um ou mais tópicos. Os tópicos no MQTT servem como canais de comunicação, e são identificados por strings hierárquicas, permitindo uma organização eficiente dos dados (USMANI, 2021).

Com essa estrutura definida, o funcionamento do MQTT opera da seguinte maneira: o publisher publica mensagens em um tópico específico e o broker encaminha essas mensagens para todos os subscribers que estão inscritos nesse tópico. Como resultado,

a comunicação entre dispositivos ocorre de forma assíncrona e desacoplada, permitindo uma troca de informações eficiente, sem a necessidade de os dispositivos conhecerem uns aos outros diretamente. A Figura 9 representa de forma simplificada o funcionamento do protocolo.

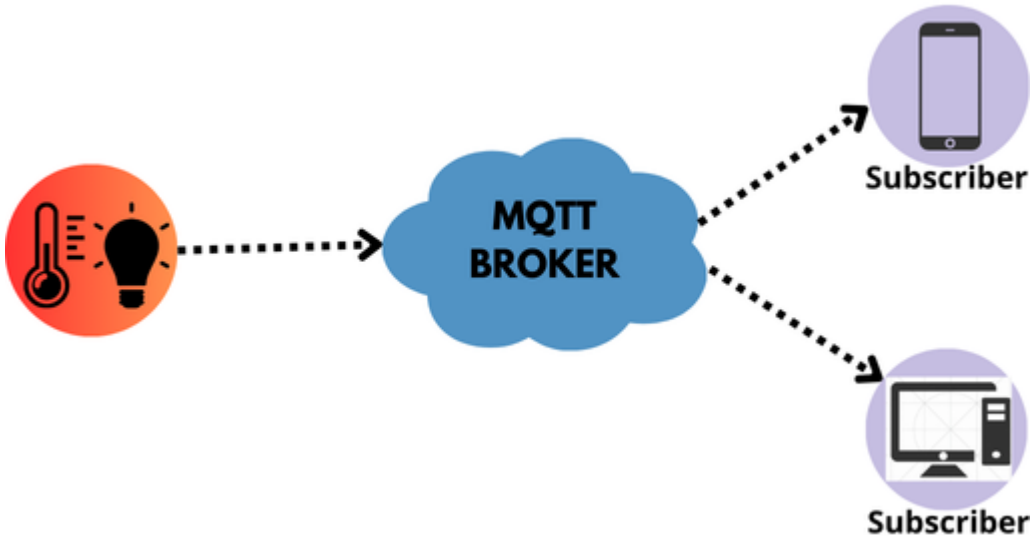


Figura 9 – Diagrama representando o funcionamento do protocolo MQTT

2.4.2 Escalabilidade com MQTT e Node-RED

A escalabilidade do sistema de comunicação é um fator crítico para aplicações em larga escala, como frotas de veículos com múltiplos motoristas. O protocolo **MQTT**, utilizado neste projeto, é reconhecido por sua leveza e eficiência em ambientes com conectividade limitada e múltiplos dispositivos.

Neste trabalho, foi utilizado o **Mosquitto MQTT Broker**, que suporta conexões simultâneas de centenas até milhares de dispositivos, dependendo da capacidade de hardware e da configuração do servidor (LIGHT, 2023). Em ambientes de teste, um Raspberry Pi pode lidar com algumas centenas de conexões simultâneas com QoS 0, enquanto servidores dedicados na nuvem, com maior poder de processamento e memória, são capazes de suportar escalas muito maiores (BURNETT; ZHANG; KUMAR, 2021). Para isso, é essencial empregar práticas como limitação de tamanho de mensagens, controle de sessões persistentes e monitoramento de desempenho em tempo real.

A escolha do nível de QoS (*Quality of Service*) também impacta diretamente na escalabilidade. O uso de **QoS 0** (entrega "no máximo uma vez") reduz a carga do broker e é ideal para dados que não exigem confirmação de entrega, como dados de sensores transmitidos em alta frequência. Em contrapartida, **QoS 1** ou **2**, embora ofereçam maior confiabilidade, aumentam o tráfego de rede e o uso de memória do broker.

O **Node-RED** atua como intermediário na visualização e processamento de dados,

mas possui limitações quanto ao número de fluxos simultâneos e à manipulação de grandes volumes de dados em tempo real. Para garantir escalabilidade, é recomendável que o Node-RED seja acoplado a um banco de dados robusto (como InfluxDB ou PostgreSQL), permitindo armazenamento eficiente e posterior análise. Além disso, arquiteturas distribuídas com múltiplos brokers MQTT (por exemplo, via clustering) e balanceadores de carga podem ser implementadas para lidar com redes de dispositivos em larga escala (MUNIZ; DIAS, 2022).

Essas estratégias garantem que o sistema proposto possa ser expandido para múltiplos usuários e veículos, mantendo a estabilidade, confiabilidade e eficiência na transmissão dos sinais fisiológicos monitorados.

2.5 Node-RED

Node-RED é uma plataforma de desenvolvimento baseada em fluxo para a construção de aplicações de automação e integração de sistemas. Ela foi projetada para permitir que usuários desenvolvam soluções rápidas e eficientes por meio de uma interface gráfica, onde é possível arranjar componentes (ou "nós") em fluxos lógicos. A plataforma é amplamente utilizada em sistemas IoT, automação residencial, monitoramento e controle de dispositivos e análise de dados em tempo real (IBM, 2020).

Sua arquitetura baseada em fluxo facilita o desenvolvimento sem a necessidade de escrever código de forma complexa, oferecendo uma abordagem mais visual e acessível. Isso torna o Node-RED uma excelente ferramenta para integrar diferentes dispositivos, e também para manipular e processar dados em tempo real. o Node-RED pode ser executado no dispositivo que atuará como broker (como um computador ou uma Raspberry Pi), intermediando a comunicação com os demais dispositivos da rede.

O espaço destinado à construção dos fluxos de nós é mostrado pela área (1) na Figura 10. Na barra lateral à esquerda, identificada por (2), encontra-se uma lista dos nós disponíveis para utilização. É possível adicionar novos nós além dos que vêm predefinidos no Node-RED. Para este projeto, foi instalado a biblioteca Node-RED Dashboard 2.0, conforme descrito na Figura 2. Finalmente, a barra lateral (3) contém três abas: uma exibe informações sobre a seleção atual, outra fornece ferramentas de depuração para facilitar a identificação de erros, e a última é dedicada à configuração do dashboard.

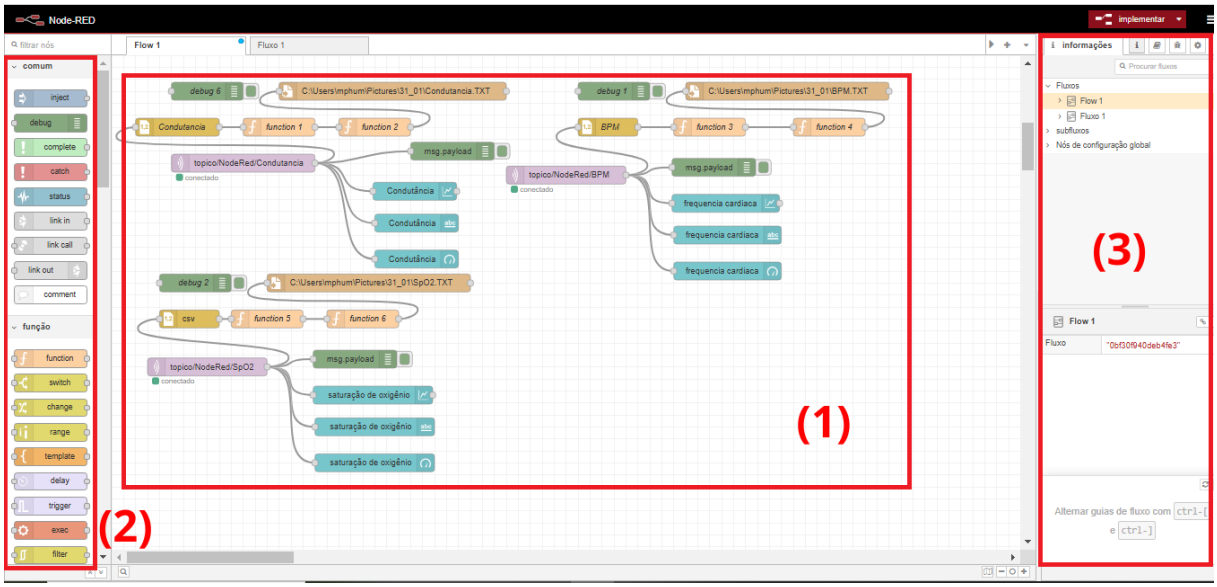


Figura 10 – Interface do Node-RED com suas principais áreas destacadas: (1) Área de construção de fluxos, onde os nós são interconectados para criar aplicações; (2) Barra lateral esquerda com a biblioteca de nós disponíveis, incluindo os adicionais (como o Node-RED Dashboard 2.0); (3) Barra lateral direita com abas de informações do nó selecionado, depuração e configuração do dashboard.

A Tabela 4 apresenta os nós utilizados neste trabalho, juntamente com uma breve descrição de sua função.

Tabela 4 – Nós do Node-RED

Nó	Descrição
csv	Converte entre uma cadeia de caracteres formatada em CSV e sua representação de objeto JavaScript, em qualquer direção.
debug	Mostra algumas propriedades de uma mensagem na barra lateral de debug.
escrever arquivo	Grava msg.payload em um arquivo, adicionando ao final ou substituindo o conteúdo existente. Alternativamente, pode-se excluir o arquivo.
function	Permite criar um bloco de função JavaScript que pode usar os dados de entrada para produzir uma saída.
mqtt in	Se conecta à um broker MQTT e se torna assinante do tópico especificado.
text	Exibirá um campo de texto não editável na interface do usuário.
chart	Plota o gráfico dos valores de entrada.
gauge	Adiciona um medidor visual à UI com os valores de entrada.

2.6 Mosquitto Broker

O Mosquitto Broker é uma implementação do protocolo MQTT, projetado para ser um servidor de mensagens leve, eficiente e escalável, com foco em soluções de Internet das Coisas (IoT). O MQTT é um protocolo de comunicação baseado na arquitetura publish/subscribe, onde dispositivos ou aplicações publicam mensagens em tópicos específicos e podem se inscrever nesses tópicos para receber as mensagens. Essa abordagem simplifica a comunicação entre dispositivos, minimizando o uso de recursos e permitindo uma maior flexibilidade em sistemas distribuídos (SONI; MAKWANA, 2017). O Mosquitto, sendo um broker MQTT de código aberto, facilita a comunicação entre clientes MQTT e oferece várias funcionalidades essenciais para sistemas IoT, como a gestão de tópicos, controle de qualidade de serviço (QoS) e segurança.

Uma das principais características do Mosquitto é a sua leveza e baixo consumo de recursos, o que o torna ideal para dispositivos com capacidade limitada, como microcontroladores e plataformas embarcadas, como o Raspberry Pi. Além disso, o Mosquitto se destaca pela escalabilidade, sendo capaz de suportar desde pequenas implementações, com apenas alguns dispositivos conectados, até sistemas de grande escala, de dispositivos interligados (SPOHN, 2022). A flexibilidade do protocolo MQTT permite que o Mosquitto gerencie diferentes níveis de Qualidade de Serviço (QoS), os quais garantem a entrega das mensagens com diferentes garantias de confiabilidade. O nível QoS 0 assegura que as mensagens sejam enviadas apenas uma vez, sem confirmação de recebimento, enquanto o QoS 1 garante que a mensagem seja entregue ao menos uma vez, com confirmação, e o QoS 2 proporciona uma entrega única e sem duplicação, ideal para cenários que exigem alta confiabilidade (RADWAN; ALVES-FOSS, 2024).

Além disso, o Mosquitto oferece recursos de segurança essenciais, como autenticação de usuários e criptografia via SSL/TLS, garantindo a proteção das mensagens em ambientes potencialmente inseguros, como a internet pública (BARANAUSKAS; TOLDINAS; LOZINSKIS, 2019). Esses recursos são especialmente importantes quando se lida com dados sensíveis em sistemas de monitoramento de saúde, automação industrial ou redes de sensores em áreas remotas. A facilidade de implantação do Mosquitto em diversas plataformas, como sistemas Linux, Windows e dispositivos embarcados, torna-o uma ferramenta amplamente adotada no desenvolvimento de soluções IoT. O Mosquitto é utilizado em uma variedade de aplicações, como automação residencial, monitoramento de saúde e agricultura inteligente, contribuindo para a implementação de soluções conectadas e eficientes em tempo real (MUKHERJI et al., 2019).

2.7 Filtros para processamento de sinais

Na área de processamento de sinais, tanto os filtros analógicos (ou filtros de sinais) quanto os filtros digitais são amplamente utilizados. A escolha entre eles depende de vários fatores, como as características do sinal, a natureza do sistema, as restrições de hardware e software, entre outros.

Para o projeto, que envolve a detecção de sonolência em motoristas usando sensores PPG e GSR, a abordagem mais adequada seria o uso de filtros digitais. Aqui estão algumas razões para essa escolha:

Flexibilidade: Os filtros digitais oferecem uma flexibilidade significativa em termos de projetar e ajustar as características de filtragem. É possível implementar diferentes tipos de filtros digitais, como filtros FIR (Resposta ao Impulso Finita) e IIR (Infinite Impulse Response), para atender às necessidades específicas do projeto.

Flexibilidade: Os filtros digitais oferecem uma flexibilidade significativa em termos de projetar e ajustar as características de filtragem. É possível implementar diferentes tipos de filtros digitais, como filtros FIR (Resposta ao Impulso Finita) e IIR (Infinite Impulse Response), para atender às necessidades específicas do projeto (PROAKIS; MANOLAKIS, 2021; IFEACHOR; JERVIS, 2013; MITRA, 2011; OPPENHEIM; SCHAFER; BUCK, 1999).

Precisão e Reprodutibilidade: Os filtros digitais permitem uma maior precisão e reprodutibilidade na resposta de frequência em comparação com os filtros analógicos. Isso é importante para garantir a qualidade da detecção de sonolência, pois deseja-se eliminar o ruído e obter um sinal limpo e confiável.

Facilidade de Implementação: Com o uso de um microcontrolador como o ESP32, é mais conveniente e eficiente implementar filtros digitais diretamente no código do dispositivo. Os filtros digitais podem ser implementados por meio de algoritmos em software, o que simplifica o processo de desenvolvimento e permite a atualização ou modificação dos filtros com facilidade.

Processamento de Sinais Complexos: No caso de sinais biomédicos, como PPG e GSR, que podem conter informações importantes relacionadas ao estado de sonolência, é necessário realizar análises mais complexas. Os filtros digitais fornecem uma base sólida para a implementação de técnicas avançadas de processamento de sinais, como filtragem adaptativa e técnicas de extração de características.

Portanto, considerando a flexibilidade, precisão, facilidade de implementação e capacidade de processar sinais complexos, os filtros digitais são a escolha mais adequada para o projeto de detecção de sonolência em motoristas usando sensores PPG e GSR.

Segundo (MAGSI et al., 2018), um dos desafios do processamento de sinais digitais,

é receber o sinal de informação sem perdas. Para isso, é importante reduzir a atenuação causada pelo ruído e melhorar o desempenho do sinal. O sinal digital é obtido por meio da conversão de um sinal analógico, sendo amostrado uniformemente a uma taxa de amostragem de acordo com o critério de Nyquist. Posteriormente, o sinal é quantizado e codificado para obter o sinal digital final.

Filtros digitais são algoritmos utilizados para processar sinais digitais, como áudio ou imagens, com o objetivo de eliminar ou atenuar componentes indesejáveis do sinal, como ruídos (MITRA, 2006; OPPENHEIM; SCHAFER, 2010; PROAKIS; MANOLAKIS, 2006; HUANG; BENESTY, 2014).

Existem diferentes tipos de filtros digitais, incluindo filtros passa-baixa, passa-alta, passa-faixa e rejeita-faixa. Esses filtros operam com base em técnicas de processamento digital, como a transformada discreta de Fourier (DFT) ou a transformada discreta de coseno (DCT), para realizar operações de filtragem no domínio da frequência ou do tempo.

Para eliminar ruídos de um sinal usando filtros digitais, é necessário identificar a natureza e as características do ruído presente. Em seguida, um filtro adequado é projetado e aplicado ao sinal para atenuar as frequências indesejadas. Existem várias técnicas e algoritmos para projetar filtros digitais, como a janela retangular, a janela de Hamming, a janela de Kaiser, entre outros (MITRA, 2006; OPPENHEIM; SCHAFER, 2010; PROAKIS; MANOLAKIS, 2006; HUANG; BENESTY, 2014).

2.8 Aspectos Éticos e Proteção de Dados

A condução deste projeto respeitou integralmente os princípios éticos da pesquisa com seres humanos, conforme estabelecido pela **Resolução nº 466/2012 do Conselho Nacional de Saúde** (Conselho Nacional de Saúde, 2012), bem como os dispositivos da **Lei Geral de Proteção de Dados Pessoais (LGPD – Lei nº 13.709/2018)** (BRASIL, 2018). Embora a pesquisa tenha sido limitada a um único voluntário, todas as diretrizes éticas aplicáveis foram rigorosamente seguidas.

Antes da coleta de dados, foi apresentado ao participante um Termo de Consentimento Livre e Esclarecido (TCLE), no qual foram detalhadas as finalidades da pesquisa, os procedimentos envolvidos, os riscos mínimos, os benefícios esperados, bem como o tratamento que seria dado aos dados pessoais e biométricos coletados. O participante foi informado sobre o seu direito de recusar ou interromper a participação a qualquer momento, sem qualquer prejuízo.

Em conformidade com a LGPD, os dados fisiológicos (frequência cardíaca, variabilidade da frequência cardíaca e condutância da pele) foram tratados como dados sensíveis, com rigoroso controle de acesso. Durante a coleta, os dados foram transmitidos direta-

mente para um computador pessoal dedicado à pesquisa, onde foram armazenados em ambiente seguro, criptografado, acessível apenas ao pesquisador responsável. Nenhuma informação de identificação pessoal (como nome, CPF ou imagem) foi vinculada aos dados fisiológicos.

Além disso, os dados foram anonimizados antes de qualquer análise, assegurando que não fosse possível a identificação do voluntário mesmo por terceiros com acesso aos registros. A divulgação dos resultados respeita o princípio da minimização, publicando apenas informações estatísticas e técnicas necessárias à validação do sistema.

Mesmo sem submissão formal a um comitê de ética, por tratar-se de um estudo exploratório com baixo risco e único voluntário, todas as práticas seguiram os preceitos da ética em pesquisa, visando garantir a integridade física, emocional e a dignidade do participante.

2.9 Estado da Arte

Nesta seção, apresenta-se um levantamento dos estudos científicos relacionados à detecção de sonolência em motoristas com base em sinais fisiológicos e comportamentais. A pesquisa bibliográfica foi realizada por meio da base de dados Scopus, utilizando palavras-chave como: "Drowsiness detection", "Wearable Driver Drowsiness", "Biomedical and Motion Sensors", "Driver Fatigue Detection by GSR and EMG", "Galvanic Skin Response", "Development of an IoT-Based Sleep Monitoring System", "Health Monitoring", "Photoplethysmography", "Oxygen Saturation", entre outras combinações. As Figuras 11 e 12 ilustram os principais autores e suas conexões com as palavras-chave utilizadas.

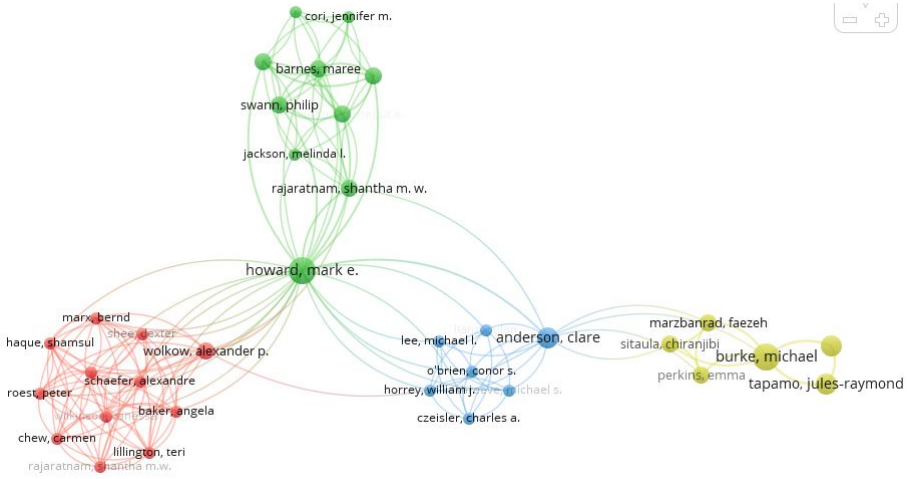


Figura 12 – Relação entre autores e tópicos sobre sonolência e sistemas vestíveis.

A detecção de sonolência em motoristas é um campo de pesquisa consolidado, com uma evolução notável nas técnicas e tecnologias empregadas. Uma análise da literatura inicial, predominantemente até 2015, revela um foco em abordagens unimodais, que

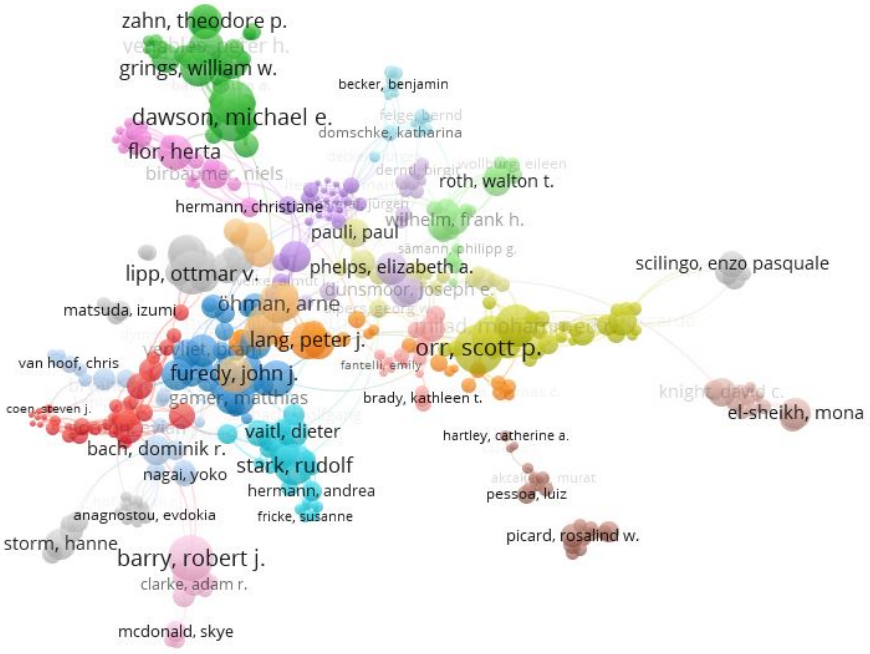


Figura 11 – Estudos associados às palavras-chave na base de dados Scopus.

utilizavam uma única fonte de dados para inferir o estado do condutor. Entre as mais comuns estavam as técnicas baseadas em visão computacional, que analisavam o fechamento ocular (PERCLOS) e a frequência de bocejos, e o uso de sensores invasivos como o eletroencefalograma (EEG) para monitorar a atividade cerebral. Embora eficazes em laboratório, essas abordagens apresentavam limitações significativas em cenários reais, como alta sensibilidade a variações de iluminação, custo elevado, complexidade computacional e desconforto para o usuário (SABET et al., 2012; LI; CHUNG, 2014).

Contudo, o cenário da pesquisa evoluiu significativamente nos últimos anos (2020 – 2024), impulsionado por avanços em Inteligência Artificial e pela viabilidade da fusão de sensores (abordagens multimodais). O paradigma atual concentra-se em combinar múltiplas fontes de dados — comportamentais, fisiológicos e até mesmo contextuais do veículo — para criar sistemas de detecção mais robustos, precisos e menos invasivos. Técnicas de aprendizado profundo tornaram-se o padrão, com Redes Neurais Convolucionais para análise de características faciais, e Redes Neurais Recorrentes ou Long Short-Term Memory para interpretar séries temporais de biossinais como a variabilidade da frequência cardíaca (HRV) e a resposta galvânica da pele (AHMED et al., 2024). Um exemplo proeminente é o trabalho de (ALGUINDIGUE et al., 2024), que demonstra a alta eficácia de modelos de deep learning aplicados a sinais de HRV e EDA para classificar níveis de sonolência com altíssima precisão.

A Tabela 5 apresenta uma comparação detalhada entre os trabalhos tradicionais e os mais recentes, destacando a transição das técnicas e, crucialmente, incluindo as métricas de desempenho que demonstram a superioridade das abordagens modernas.

Tabela 5 – Comparação aprimorada entre trabalhos sobre detecção de sonolência em motoristas.

Autor (Ano)	**Técnica / Modelo de IA**	**Sensores (Modalidades)**	**Métricas de Desempenho**	**Limitações**
Abordagens Tradicionais (Unimodais / Invasivas)				
(SABET et al., 2012) (2012)	Análise facial baseada em vídeo (PERCLOS, bocejo)	Câmera infravermelha	Não reportado (qualitativo)	Alto consumo computacional, sensibilidade à iluminação
(EBRAHIM; STOLZMANN; YANG, 2013) (2013)	Análise de movimentos oculares	Eletrodos de EOG	Não reportado (qualitativo)	Técnica invasiva, exige contato com a pele e gel condutor
(LI; CHUNG, 2014) (2014)	Combinação de EEG e detecção ocular	Capacete EEG + Câmera	Acurácia: 88.7%	Equipamentos intrusivos, caros e desconfortáveis, afetando a condução
Abordagens Modernas (Multimodais com IA e Deep Learning)				
(ALGUINDIGUE et al., 2024) (2024)	**Deep Learning (SNN, 1D-CNN, CRNN)**	**Fisiológicos (HRV, EDA) + Comportamentais (Eye-tracking)**	**Acurácia: 98.28% (HRV); 96.32% (EDA). F1-Score: 98% (HRV)**	**Modelo de eye-tracking com dificuldade devido a desequilíbrio no dataset**
(ZHANG et al., 2022) (2022)	Fusão Multimodal com CNN-LSTM	Câmera (PERCLOS, bocejo) + Sensor no volante (SWM)	Taxa de Detecção: 95.1%; Falsos Positivos: $< 5\%$	Sensível a condições de iluminação extremas; dependência de calibração
(DU et al., 2021) (2021)	Fusão de features com RNN	Câmera (frequência cardíaca via rPPG) + Dados faciais	Acurácia: 94.7%	Degradação de performance com movimentos bruscos da cabeça
(KASSEM; CHOWDHURY; ABAWAJY, 2021) (2021)	CNN para análise de comportamento facial	Câmera (análise de rosto e cabeça)	Acurácia de predição: 93.3%	Testado apenas em ambiente simulado; expressões faciais atuadas, não genuínas
(LEE; LEE; JEONG, 2020) (2020)	Machine Learning (SVM, Random Forest)	Sensores vestíveis (EDA, Temperatura) + Acelerômetro	Acurácia: 92.5%	Dependência de sensores vestíveis, que podem ser esquecidos ou causar desconforto

A análise comparativa evidencia uma clara transição de sistemas baseados em regras e métodos invasivos para sistemas inteligentes, multimodais e não invasivos, que alavancam o poder do aprendizado de máquina. As abordagens atuais não apenas alcançam métricas de desempenho superiores (acurácias consistentemente acima de 90%), mas também são mais práticas para implementação em veículos comerciais. Apesar do progresso, desafios persistem, como a generalização dos modelos para cenários de condução do mundo real não vistos em treinamento, o tratamento do desequilíbrio de classes nos datasets (onde estados de sonolência são mais raros) e a necessidade de sistemas computacionalmente eficientes para operar em hardware embarcado de baixo custo.

Com base na revisão do estado da arte, observa-se que os sensores PPG e GSR

apresentam vantagens significativas para a detecção de sonolência em motoristas. O PPG permite a monitorização contínua e não invasiva de parâmetros cardiovasculares, como frequência cardíaca e variabilidade da frequência cardíaca (HRV), que são indicadores sensíveis a estados de fadiga e estresse. Já o GSR fornece informações valiosas sobre a atividade do sistema nervoso simpático, captando alterações na condutância da pele associadas a transições entre vigília e sonolência. A combinação desses sinais fisiológicos em uma abordagem multimodal aumenta a robustez do sistema, reduzindo falsos positivos causados por variações individuais ou artefatos de movimento. Além disso, a portabilidade e o baixo custo desses sensores os tornam ideais para aplicações em ambientes reais de condução, superando limitações de técnicas invasivas ou dependentes de condições ambientais controladas.

3 Metodologia

Este capítulo apresenta a metodologia adotada para o desenvolvimento do sistema de detecção de sonolência em indivíduos, por meio da utilização dos sensores PPG e GSR, do microcontrolador ESP32 e da plataforma Node-RED. São descritas as etapas que compreendem a aquisição dos dados dos sensores, o processamento dos sinais, a análise e detecção de sonolência, a implementação do sistema no microcontrolador e a integração com o Node-RED para visualização e análise dos dados.

A Figura 13 ilustra a arquitetura geral da solução proposta. Nela, são representados os subsistemas empregados na composição do dispositivo. Ressalta-se que etapas como o classificador, os resultados e o sistema de alarme foram planejadas para desenvolvimento em trabalhos futuros.

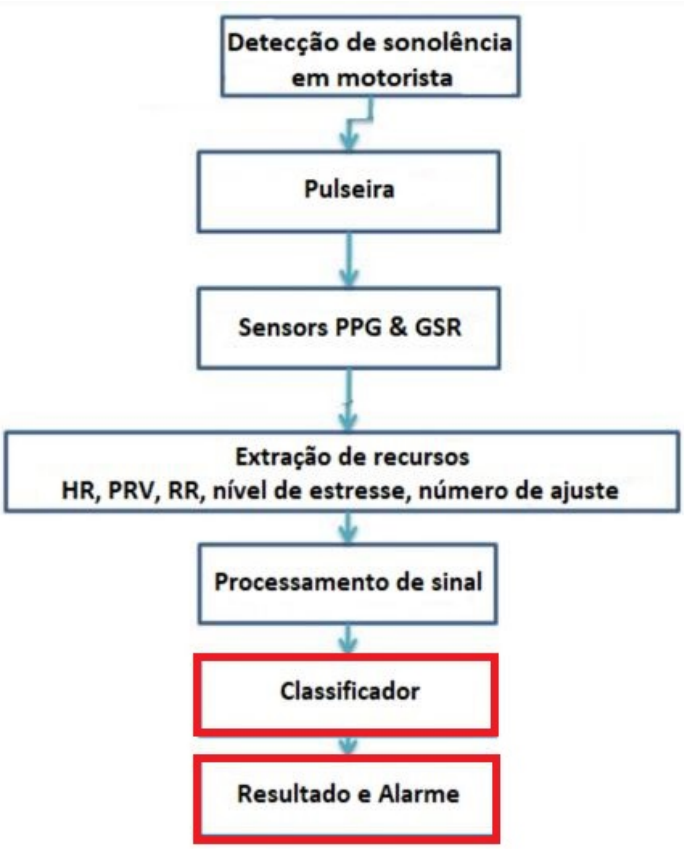


Figura 13 – Configuração do projeto, excetuando-se as etapas de classificação, resultados e alarme, previstas para trabalhos futuros.

O sistema proposto para detecção de sonolência opera como uma arquitetura coesa, onde os sensores PPG e GSR, o microcontrolador ESP32, o protocolo MQTT e a plataforma Node-RED interagem de forma complementar. Inicialmente, os sensores PPG e GSR capturam sinais fisiológicos (frequência cardíaca, saturação de oxigênio e condutância da pele), que são pré-processados pelo ESP32 para remoção de ruídos e extração de características. O ESP32, atuando como edge device, transmite esses dados via Wi-Fi para um broker MQTT (Mosquitto), utilizando tópicos. O Node-RED, configurado como subscriber, consome os tópicos MQTT em tempo real, processa os dados e os exibe em um dashboard interativo com gráficos dinâmicos e alertas. A Figura 14 ilustra esse fluxo, destacando a comunicação bidirecional entre os módulos e a escalabilidade do sistema, que permite a inclusão de novos sensores ou atuadores (como buzzers de alerta) sem modificações na arquitetura central.

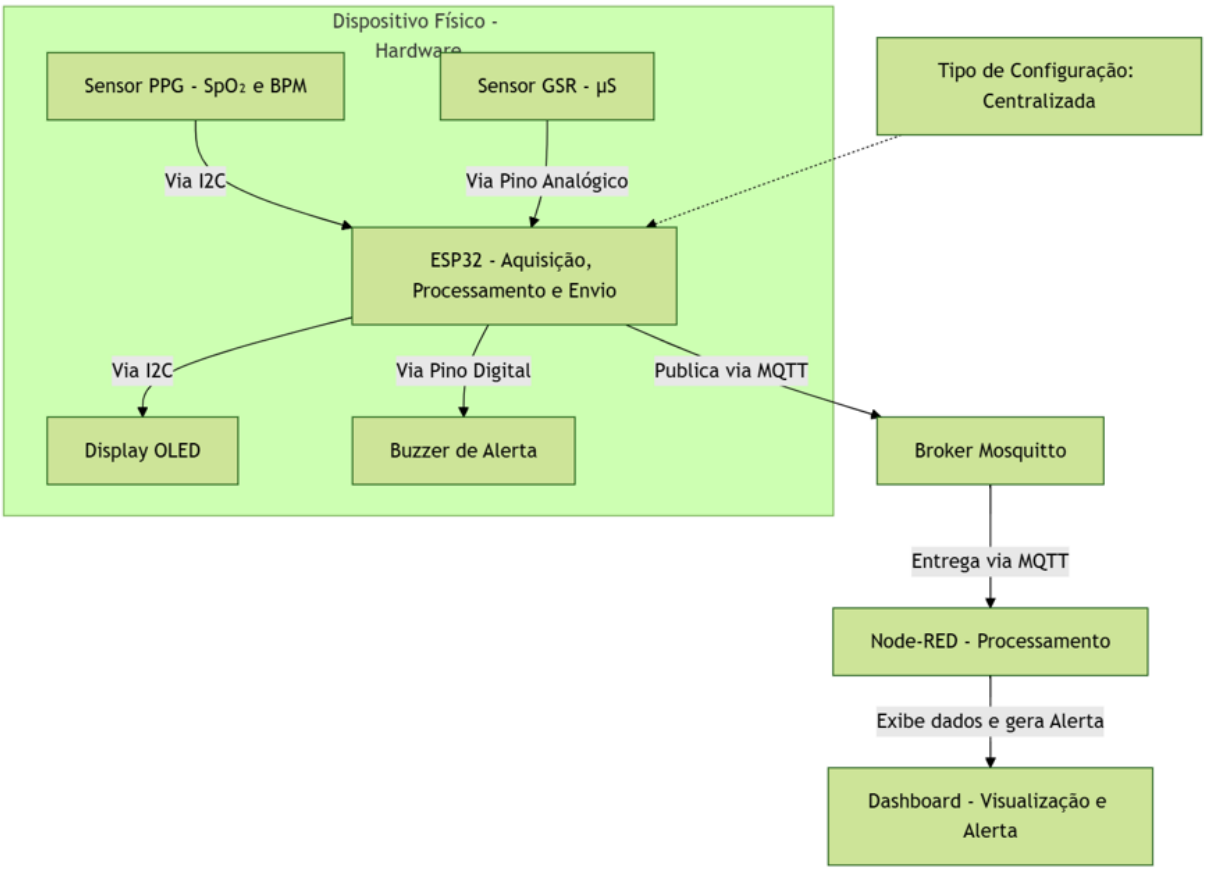


Figura 14 – Diagrama conceitual da interação entre os componentes do sistema. Os sensores PPG/GSR enviam dados ao ESP32, que os publica no Mosquitto Broker via MQTT. O Node-RED processa e visualiza os dados, podendo acionar alertas.

3.1 Requisitos de Hardware

A Figura 15 destaca os principais componentes do sistema, como os sensores MAX30102 e GSR, o microcontrolador ESP32, além dos componentes adicionais, como

o display OLED e o buzzer. Esses elementos têm como função apresentar informações ao condutor e emitir alertas sonoros, contribuindo assim para a detecção de sonolência.

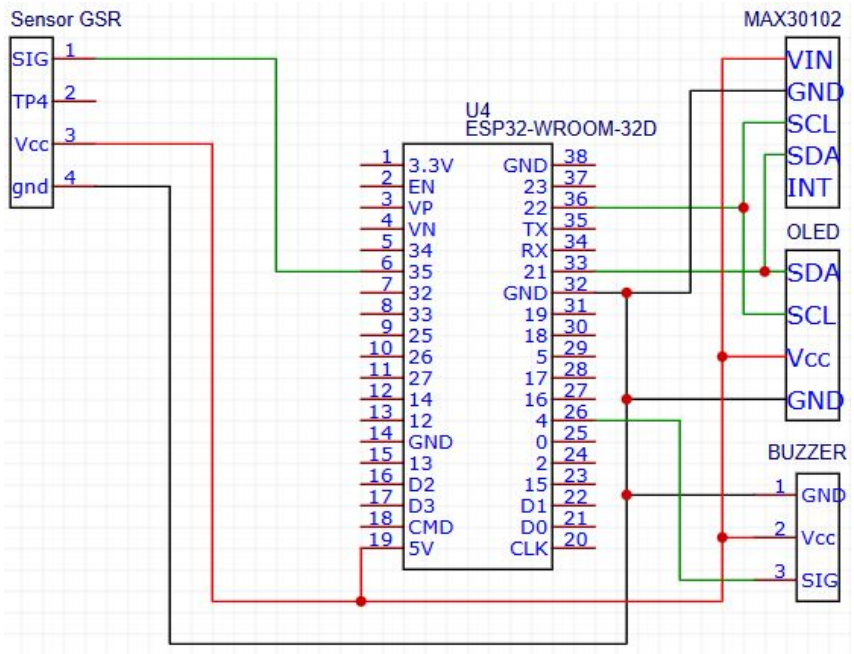


Figura 15 – Diagrama esquemático do sistema de detecção de sonolência em motoristas com sensores MAX30102 e GSR, ESP32, display OLED e buzzer.

A Figura 16 apresenta uma ilustração esquemática das conexões dos sensores PPG (MAX30102) e GSR (Resposta Galvânica da Pele) com a placa ESP32.

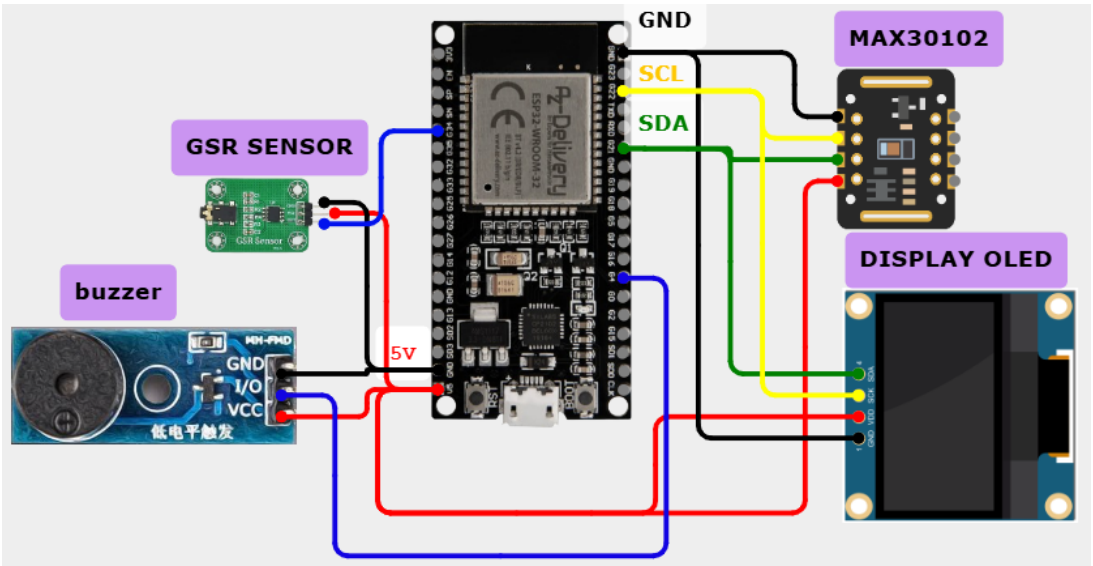


Figura 16 – Conexões dos sensores MAX30102, GSR, OLED e buzzer com a placa ESP32 para o sistema de detecção de sonolência.

Na Figura 16, observam-se as conexões do sistema. O sensor MAX30102 está conectado aos pinos 21 e 22 da ESP32, enquanto o sensor GSR está conectado ao pino

34. Os fios verdes representam a transmissão de dados entre sensores e a placa ESP32, incluindo o envio de dados para o display OLED. Os fios pretos representam as conexões de terra (GND), enquanto os fios vermelhos correspondem à alimentação (VCC).

Os pinos SCL e SDA do display OLED e do MAX30102 estão conectados, respectivamente, aos pinos 22 (SCL) e 21 (SDA) da ESP32, utilizando o protocolo de comunicação I2C. Já o buzzer está conectado ao pino 4 da ESP32, através do pino SIG, permitindo a emissão de alertas sonoros em situações críticas.

A ESP32 atua como unidade central do sistema, processando os dados provenientes dos sensores e acionando os dispositivos de saída (display OLED e buzzer), conforme necessário.

Para a implementação do sistema, foram utilizados os seguintes componentes de hardware:

- ESP32;
- Sensor GSR;
- Sensor PPG (MAX30102);
- Computador;
- Buzzer;
- Display OLED;
- Bateria.

A Tabela 6 apresenta as especificações técnicas dos componentes utilizados.

Tabela 6 – Especificações técnicas dos componentes utilizados no sistema

Nome do componente	**Especificações**
ESP32	WROOM-32D
Sensor GSR	V1.2
Sensor MAX30102	3,3 a 5 VDC, 2 cm × 2 cm × 1 cm, 20 g
Computador	USB 2.0, USB 3.2, USB-C 3.2
Buzzer	Tensão de trabalho: 2,5 a 8 V
	Tensão recomendada: 5 V
	Corrente máxima: 40 mA
	Diâmetro: 12 mm
	Altura: 10 mm
Display OLED	Tensão de operação: 2,2–5,5 V
	Controlador: SSD1306
	Cor: Azul
	Comunicação: I2C
	Resolução: 128 × 64
	Dimensões: 30 × 27 mm
	Peso: 10 g
	GND: GND
	VCC: 2,2–5,5 V
	SCL: Clock (nível alto: 2,2–5,5 V)
	SDA: Dados (nível alto: 2,2–5,5 V)
Bateria	5 V

A Figura 17 apresenta a disposição física dos principais componentes do sistema de detecção de sonolência, montados em uma estrutura compacta e funcional. Nela, é possível visualizar a organização interna do dispositivo, incluindo o sensor de batimentos cardíacos e oximetria (MAX30102), o sensor de resposta galvânica da pele (GSR), o microcontrolador ESP32, o display OLED e a bateria. Cada componente está conectado de forma estratégica à placa principal, respeitando os requisitos de comunicação e alimentação elétrica.

As setas na imagem indicam claramente a localização de cada elemento, facilitando o entendimento do funcionamento do sistema. O display OLED encontra-se na parte frontal da caixa, possibilitando a visualização em tempo real dos sinais monitorados. A bateria está posicionado debaixo da ESP32. Já os sensores GSR e MAX30102 estão acessíveis por meio de cabos, permitindo sua fixação no corpo do condutor durante a utilização.

A estrutura externa da caixa foi projetada para proteger os componentes internos, acesso aos conectores, como a porta USB utilizada para alimentação ou programação do sistema. Essa organização garante um sistema modular, seguro e de fácil manutenção.

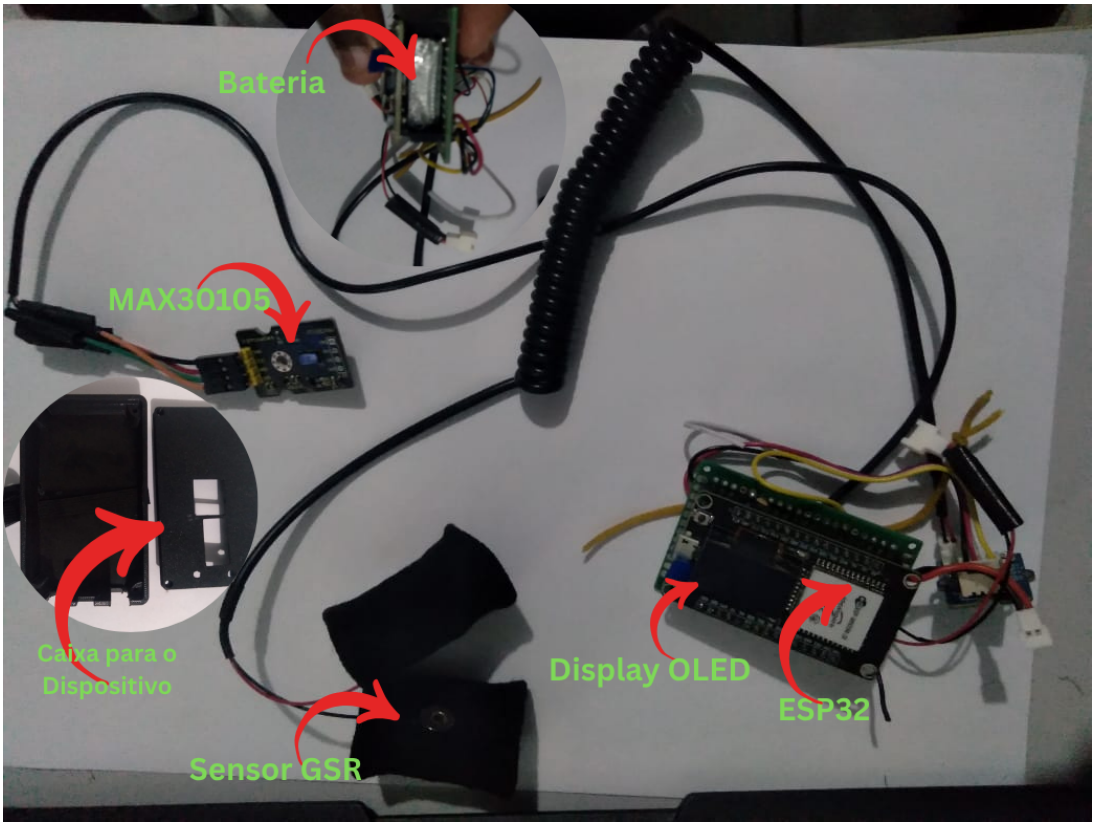


Figura 17 – Identificação dos principais componentes do sistema de detecção de sonolência, incluindo sensores GSR e MAX30102, display OLED, bateria e a placa ESP32. As setas indicam os componentes do sistema.

3.2 Configuração do Node-RED

A integração com a plataforma Node-RED, por meio do protocolo MQTT, é essencial para o monitoramento contínuo e em tempo real dos dados obtidos pelos sensores PPG (MAX30102) e GSR. Essa etapa abrange a configuração detalhada da comunicação e o desenvolvimento de um *dashboard* funcional, destinado à apresentação de parâmetros fisiológicos do indivíduo, tais como resistência da pele, saturação de oxigênio e frequência cardíaca.

Inicialmente, foi realizada a configuração dos nós no Node-RED, utilizando o protocolo MQTT para o recebimento das informações transmitidas pelos sensores, conforme ilustrado na Figura 18. Em sequência, desenvolveu-se o *dashboard* na mesma plataforma, com o objetivo de viabilizar a visualização em tempo real dos dados coletados, como demonstrado na Figura 19.

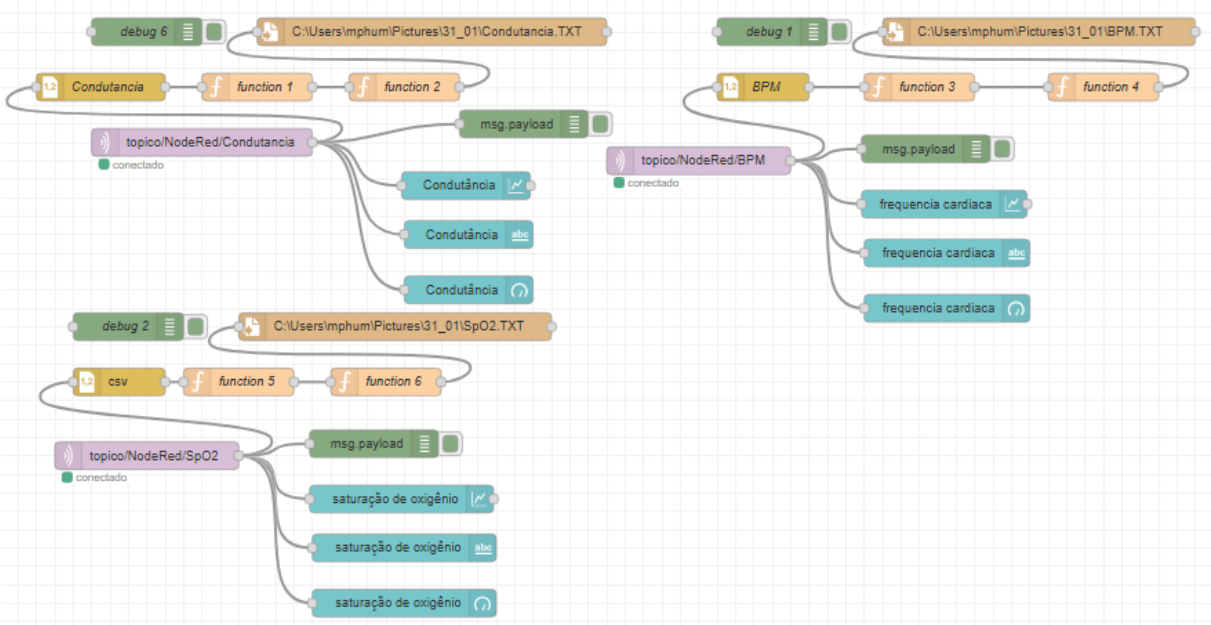


Figura 18 – Configuração dos nós no Node-RED para recepção dos dados dos sensores via MQTT.

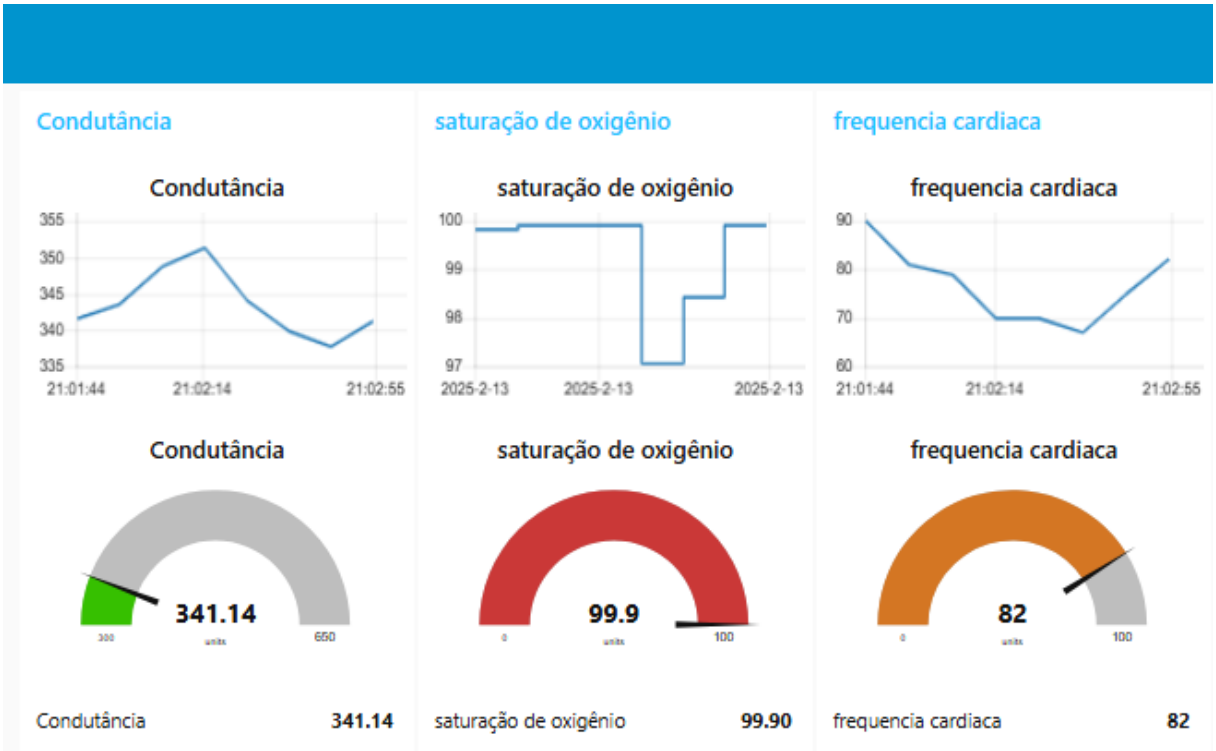


Figura 19 – Interface do *dashboard* desenvolvida no Node-RED para visualização dos dados em tempo real.

A Figura 20, apresenta a arquitetura conceitual do sistema proposto para a detecção de sonolência do indivíduo, por meio da integração dos sensores fisiológicos PPG (Photoplethysmography) e GSR (Galvanic Skin Response). O diagrama de blocos permite

visualizar a disposição funcional dos principais módulos envolvidos e o fluxo de dados entre eles, servindo como base para a compreensão das etapas metodológicas subsequentes.

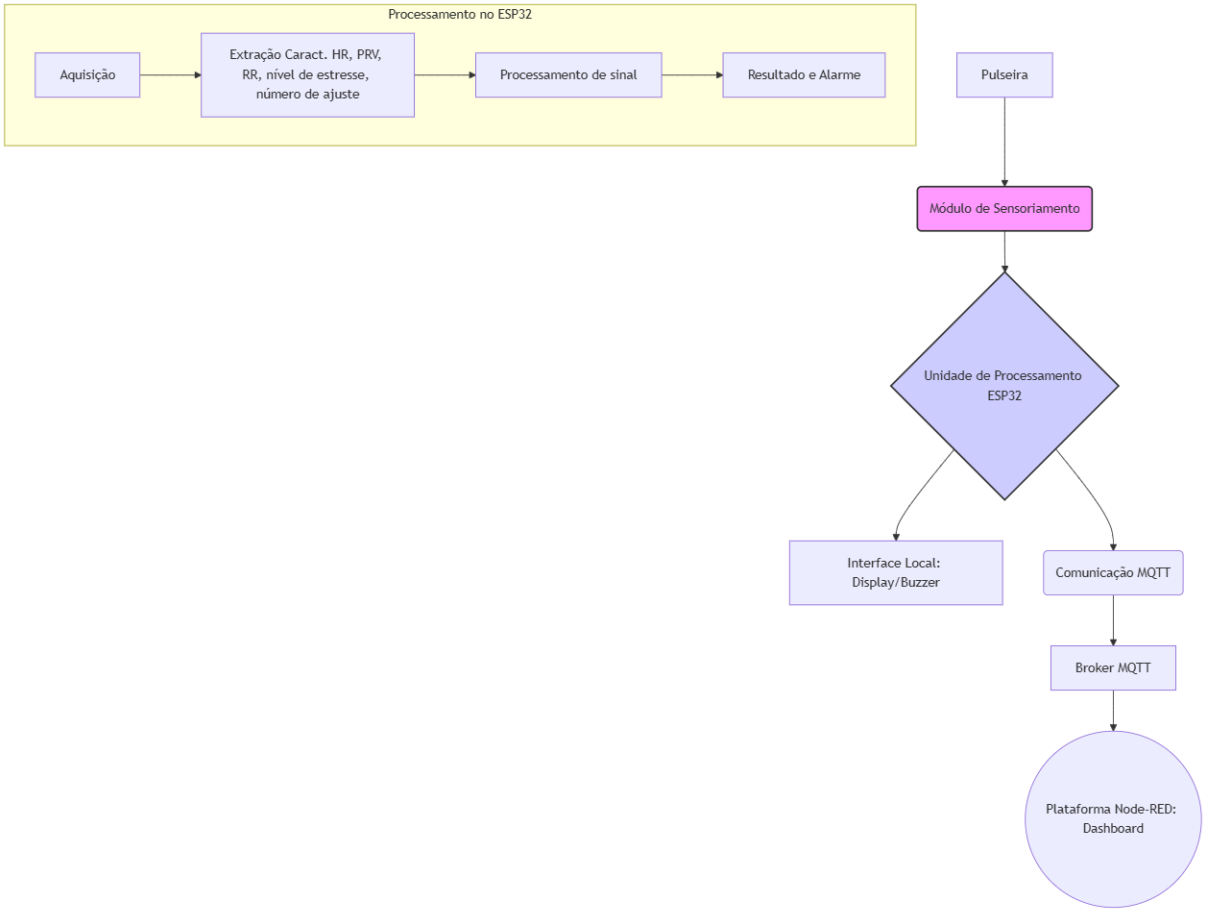


Figura 20 – Arquitetura conceitual do sistema proposto para detecção de sonolência.

Fonte: Elaborado pelo autor (2024).

O sistema tem início na aquisição de sinais fisiológicos no ambiente do condutor, utilizando sensores de PPG e GSR, que captam, respectivamente, a variação do fluxo sanguíneo e a resposta galvânica da pele. Esses dados são transmitidos ao microcontrolador ESP32, responsável pela execução das etapas de aquisição, pré-processamento, extração de características e detecção de sonolência, de forma embarcada.

O processamento local envolve a aplicação de técnicas de filtragem, identificação de padrões fisiológicos e análise temporal, com o objetivo de detectar indícios de sonolência. Caso o estado de sonolência seja identificado, o sistema aciona mecanismos de alerta locais, como display ou buzzer, além de enviar as informações, via protocolo MQTT, para um painel visual em uma plataforma de monitoramento baseada em Node-RED.

A comunicação entre os módulos permite não apenas a execução de alertas em tempo real, mas também o armazenamento e a visualização contínua dos parâmetros fisiológicos, possibilitando o acompanhamento do estado do indivíduo.

As etapas descritas no diagrama serão detalhadas nas seções seguintes deste capítulo, abrangendo desde a aquisição dos sinais até a implementação final do sistema no microcontrolador ESP32.

3.3 Aquisição dos dados dos sensores PPG e GSR

A aquisição dos sinais PPG e GSR é realizada por meio do microcontrolador ESP32, que atua como interface entre os sensores e o sistema de processamento de dados. O ESP32 é um microcontrolador versátil e de baixo custo, que oferece capacidades de comunicação sem fio, como Wi-Fi e Bluetooth, além de possuir conversores analógico-digitais (ADC) integrados. A Figura 21 ilustra o dispositivo de detecção de sonolência desenvolvido, composto pelos sensores, microcontrolador, display OLED e o buzzer.



Figura 21 – Dispositivo de detecção de sonolência utilizando sensores PPG e GSR integrados ao ESP32.

Para a aquisição do sinal PPG, é utilizado um sensor específico de fotopletismografia, geralmente composto por um emissor de luz, como um LED, e um fotodetector. O LED emite luz em uma determinada frequência ou comprimento de onda, que é absorvida pela pele e, posteriormente, detectada pelo fotodetector. A variação na intensidade da luz detectada está relacionada às variações no fluxo sanguíneo, permitindo a obtenção de informações fisiológicas relevantes, tais como:

- **Frequência Cardíaca**: A frequência cardíaca é obtida a partir do sensor PPG, que

mede as variações do fluxo sanguíneo no corpo. Durante a sonolência, a frequência cardíaca tende a diminuir. Portanto, uma diminuição significativa na frequência cardíaca em relação ao estado de vigília normal pode indicar sonolência.

- **Variabilidade da Frequência Cardíaca (HRV)**: A HRV é uma medida da variação dos intervalos entre os batimentos cardíacos. Durante a sonolência, a HRV tende a diminuir. Uma menor HRV está associada à atividade parassimpática aumentada e à atividade simpática reduzida, características do estado sonolento.
- **Amplitude da Onda PPG**: A amplitude da onda PPG representa as mudanças no volume sanguíneo nos vasos sanguíneos. Durante a sonolência, ocorrem variações na amplitude da onda PPG devido a alterações no tônus vascular. Uma diminuição significativa na amplitude da onda PPG pode indicar sonolência.
- **Tempo de Subida e Descida da Onda PPG**: O tempo necessário para a onda PPG atingir o pico (tempo de subida) e retornar ao seu nível basal (tempo de descida) também pode ser analisado. Durante a sonolência, esses tempos podem se tornar mais prolongados devido a mudanças na função vascular.
- **Índice de Pulso**: O índice de pulso é calculado como a razão entre a amplitude sistólica e a amplitude diastólica da onda PPG. Durante a sonolência, o índice de pulso tende a diminuir, indicando uma redução na diferença entre a pressão arterial sistólica e diastólica.

Para a aquisição do sinal GSR, utiliza-se um sensor específico que mede a condutância elétrica da pele, a qual varia conforme o estado emocional e fisiológico do indivíduo. O sensor é composto por dois eletrodos metálicos que são fixados à pele, geralmente nos dedos da mão. Durante a sonolência, a redução da atividade simpática leva a uma diminuição da condutância.

Durante a aquisição dos sinais PPG e GSR, é necessário considerar alguns aspectos importantes para garantir a qualidade e a confiabilidade dos dados. Esses aspectos incluem:

- **Posicionamento dos sensores**: o sensor PPG foi posicionado no dedo indicador da mão esquerda, enquanto os eletrodos GSR foram colocados nos dedos indicador e médio da mão direita;
- **Estabilidade do contato**: os sensores foram fixados com tiras elásticas para assegurar contato constante com a pele, minimizando artefatos de movimento;
- **Amostragem adequada**: a taxa de amostragem dos sinais foi fixada em 50 Hz, valor suficiente para capturar as variações fisiológicas relevantes com boa resolução temporal.

Após a aquisição, os dados são processados localmente pelo ESP32, onde são extraídas variáveis como batimentos por minuto (BPM), saturação de oxigênio (SpO2) estimada e condutância da pele. Esses dados são exibidos em tempo real por meio de um display OLED, enquanto alertas de sonolência podem ser ativados via buzzer. Simultaneamente, os dados são publicados em tópicos MQTT e disponibilizados em tempo real em uma interface desenvolvida no Node-RED.

3.4 Processamento dos sinais

Os sinais adquiridos pelos sensores PPG e GSR passam por um processo de processamento de sinal, etapa essencial para melhorar a qualidade dos dados, eliminar ruídos indesejados e extrair informações relevantes que serão utilizadas na detecção de sonolência.

O processamento dos sinais ocorre no microcontrolador ESP32, com o objetivo de reduzir os ruídos e garantir a fidelidade dos parâmetros fisiológicos obtidos.

- **Processamento de Sinal GSR**: O processamento do sinal GSR (Galvanic Skin Response) é essencial para medir a condutância da pele, que varia com a atividade das glândulas sudoríparas e pode indicar estados emocionais como a sonolência. A aquisição do sinal é captado por um sensor de condutância galvânica da pele, conectado a uma entrada analógica do microcontrolador ESP32. A partir da leitura analógica, o sinal é convertido em uma tensão proporcional à condutância da pele.

  Para suavizar o sinal e reduzir o ruído, utiliza-se uma Média Móvel Simples (SMA) com uma janela de 10 amostras, que calcula a média dos últimos valores lidos.

  A equação que define a SMA é dada por:

$$\mathrm{SMA}(t) = \frac{1}{N} \sum_{i=0}^{N-1} x(t-i) \tag{3.1}$$

  onde $N = 10$ representa o tamanho da janela e $x(t)$ corresponde ao valor da amostra no instante t.

  Com o sinal suavizado, a tensão resultante é utilizada para o cálculo da condutância da pele, expressa em microsiemens (μS), e da resistência cutânea, conforme as leis básicas da eletricidade.

- **Processamento de Sinal PPG**: O sinal PPG é obtido por meio do sensor MAX30102, que emite luz nas faixas vermelho e infravermelho e capta as variações no sinal refletido, causadas pelas mudanças no fluxo sanguíneo nos tecidos periféricos. Esse sinal apresenta uma componente contínua (DC) e uma componente alternada (AC), associadas respectivamente à absorção constante da luz pelos tecidos e às pulsações decorrentes do batimento cardíaco.

Para remoção de ruído de alta frequência, é utilizado um filtro digital exponencial passa-baixa com fator de amortecimento $\alpha = 0{,}95$, aplicado separadamente aos sinais vermelho e infravermelho:

$$\bar{x}(t) = \alpha \cdot \bar{x}(t-1) + (1-\alpha) \cdot x(t) \tag{3.2}$$

Após a filtragem, os picos do sinal infravermelho são identificados para cálculo da frequência cardíaca (HR), a partir do intervalo entre batimentos consecutivos. Ao mesmo tempo, a saturação de oxigênio no sangue (SpO_2) é estimada com base na razão entre os valores RMS (raiz média quadrática) das componentes vermelha e infravermelha do sinal, de acordo com a fórmula empírica:

$$SpO_2 = -23{,}3 \cdot (R - 0{,}4) + 120 \tag{3.3}$$

onde R representa a razão entre os sinais RMS normalizados.

Após o processamento, os parâmetros fisiológicos extraídos, como a condutância e a resistência da pele, a frequência cardíaca (HR) e a saturação de oxigênio no sangue (SpO_2), são transmitidos por meio do protocolo **MQTT** à plataforma **Node-RED**, onde são apresentados em tempo real por meio de uma interface gráfica. Simultaneamente, esses valores também são exibidos localmente em um display **OLED** conectado ao microcontrolador **ESP32**, permitindo o monitoramento direto, contínuo e sem a necessidade de dispositivos externos.

A combinação dos sinais GSR e PPG permite uma análise mais abrangente do estado fisiológico do motorista. Enquanto o GSR é sensível a alterações emocionais como sonolência e estresse, o PPG fornece indicadores vitais como frequência cardíaca e oxigenação do sangue. A integração desses sinais em um sistema embarcado permite uma detecção mais precisa de estados de sonolência, com acionamento de alertas sonoros e visuais quando necessário.

3.5 Protocolo Experimental para Validação Preliminar

A definição de limiares eficazes para a detecção de sonolência exige a coleta e análise de dados fisiológicos em condições controladas. Para este trabalho, foi desenvolvido um protocolo experimental com o objetivo de servir como uma prova de conceito (PoC), validando a funcionalidade do sistema embarcado e fornecendo uma base de dados inicial para a caracterização dos estados de vigília e sonolência. O desenho do estudo foi configurado como um estudo de caso único, utilizando o próprio autor como sujeito. A escolha por esta abordagem foi de natureza pragmática, alinhada ao escopo e às restrições de tempo de um Trabalho de Conclusão de Curso, e permitiu

focar na validação técnica do protótipo sem a complexidade logística e burocrática da condução de testes com múltiplos participantes, que exigiriam aprovação de um comitê de ética em pesquisa.

O protocolo foi executado da seguinte forma:

- **Ambiente de Coleta:** Os dados foram coletados em um ambiente interno controlado, com baixo ruído, iluminação constante e temperatura amena (aproximadamente 22°C), a fim de minimizar a influência de variáveis ambientais externas sobre os sinais fisiológicos.
- **Duração e Frequência:** Foram realizadas 5 sessões de coleta de dados em noites distintas. Cada sessão teve uma duração de 2 horas, iniciando-se às 22:00 e terminando à 00:00, período no qual o sujeito tipicamente experimenta um aumento natural da sonolência.
- **Procedimento da Sessão:** Durante cada sessão, o sujeito permaneceu sentado confortavelmente, com os sensores de PPG e GSR devidamente posicionados. Durante o estado de vigília, o sujeito manteve-se acordado e atento à leitura. Nos períodos de sonolência, o sujeito chegou a adormecer brevemente, mas teve-se o cuidado de manter a mão com os sensores imóvel e posicionada de forma a garantir a continuidade e a qualidade da coleta dos sinais fisiológicos.

A análise dos dados coletados sob este protocolo permitiu a observação de tendências claras. Os segmentos de dados rotulados como *sonolência* apresentaram, consistentemente, uma redução da frequência cardíaca e alterações específicas na condutância da pele. Foi a partir da média e do desvio padrão dos valores observados nestes episódios de *sonolência* que os limiares de detecção — frequência cardíaca média inferior a 60 BPM e condutância da pele entre 357,02 e 370,08 μS — foram estabelecidos para a implementação do sistema.

3.6 Implementação do sistema no microcontrolador ESP32

A implementação do sistema no microcontrolador ESP32 é uma etapa fundamental, pois permite a aquisição, o processamento dos sinais fisiológicos e a detecção de sonolência em tempo real, de forma embarcada, sem a necessidade de processamento externo. O ESP32, por sua capacidade de conectividade sem fio e desempenho computacional, mostrou-se ideal para este tipo de aplicação. A implementação do sistema no microcontrolador ESP32 envolve os seguintes passos:

Configuração do ambiente de desenvolvimento: O primeiro passo consistiu na preparação do ambiente de desenvolvimento. Foi utilizada a *Arduino IDE*, uma plataforma amplamente adotada na prototipagem eletrônica, por sua simplicidade

e vasta biblioteca de suporte. Para o desenvolvimento no ESP32, foi necessário instalar o *ESP32 Arduino Core*, que permite a programação da placa com a linguagem C/C++ por meio da IDE. Além disso, bibliotecas específicas foram adicionadas, como a `MAX30105` para o sensor de batimentos cardíacos e oxigenação do sangue, `Adafruit_SSD1306` para o controle do display OLED e `PubSubClient` para comunicação via protocolo MQTT.

Desenvolvimento do código: O código foi desenvolvido com o objetivo de realizar a leitura dos sinais dos sensores, aplicar técnicas de processamento e emitir alertas caso os parâmetros fisiológicos indicativos de sonolência fossem detectados.

Configuração dos pinos: Foi realizada a definição dos pinos digitais e analógicos utilizados no ESP32. O sensor óptico MAX30102, utilizado para leitura do sinal PPG (Photoplethysmogram), foi conectado via barramento I2C. O sensor GSR (Galvanic Skin Response), por sua vez, foi ligado a uma entrada analógica (pino 34). O buzzer foi conectado ao pino digital 4, permitindo a emissão de sinais sonoros de alerta.

Aquisição dos dados dos sensores: A aquisição dos dados do sensor MAX30102 foi realizada por meio da biblioteca `MAX30105`, que permite a coleta de sinais de luz infravermelha (IR) refletidos pela pele, usados para cálculo de batimentos cardíacos e estimativa de SpO_2 (saturação periférica de oxigênio). O sinal GSR foi lido diretamente pela porta analógica do microcontrolador, utilizando técnicas de Média Móvel Simples (SMA) para filtragem de ruídos.

Processamento dos sinais: O processamento dos sinais ocorre em tempo real, no próprio ESP32. No caso do sinal PPG, foi aplicada uma lógica de detecção de picos (batimentos) para calcular a frequência cardíaca (BPM). Também foram implementadas rotinas de cálculo para a média dos batimentos e estimativa de SpO_2, utilizando métodos de média ponderada e correções baseadas em variáveis de referência.

Para o sinal GSR, foi calculada a condutância da pele com base nos valores de tensão obtidos na entrada analógica. Essa condutância, expressa em microsiemens (μS), foi usada como indicador de alterações fisiológicas associadas à sonolência.

Detecção de sonolência: A lógica de detecção de sonolência foi baseada em dois parâmetros fisiológicos principais:

- Frequência cardíaca média inferior a 60 BPM;
- Condutância da pele entre 357,02 e 370,08 μS.

Esses limiares foram definidos com base em testes experimentais e estudos correlatos na literatura. Caso essas condições fossem simultaneamente atendidas, o sistema considerava que o motorista apresentava sinais de sonolência. Nesse cenário, o buzzer

era acionado, emitindo um alerta sonoro ao usuário. Simultaneamente, os valores medidos eram enviados via protocolo MQTT para uma interface remota no Node-RED, permitindo o monitoramento contínuo.

Figura 22: Diagrama de fluxo do sistema. O diagrama ilustra a lógica de funcionamento do sistema embarcado no ESP32 para detecção de sonolência. O fluxo inicia com a aquisição dos sinais fisiológicos pelos sensores MAX30102 (PPG) e GSR. Em seguida, os sinais passam por uma etapa de pré-processamento, incluindo filtragem e suavização dos dados. Após isso, são realizadas as operações de cálculo da frequência cardíaca (BPM), da estimativa de SpO_2 e da condutância da pele. Os dados processados alimentam a lógica de detecção de sonolência, que avalia os parâmetros fisiológicos em tempo real. Caso os limiares definidos sejam atingidos simultaneamente (BPM $<$ 60 e condutância entre 357,02 e 370,08 μS), o sistema aciona o buzzer para emitir um alerta sonoro ao usuário. Simultaneamente, os dados são transmitidos via MQTT para uma interface remota desenvolvida no Node-RED, permitindo o monitoramento contínuo do estado fisiológico do motorista. O sistema então retorna ao início do ciclo, garantindo monitoramento em tempo real.

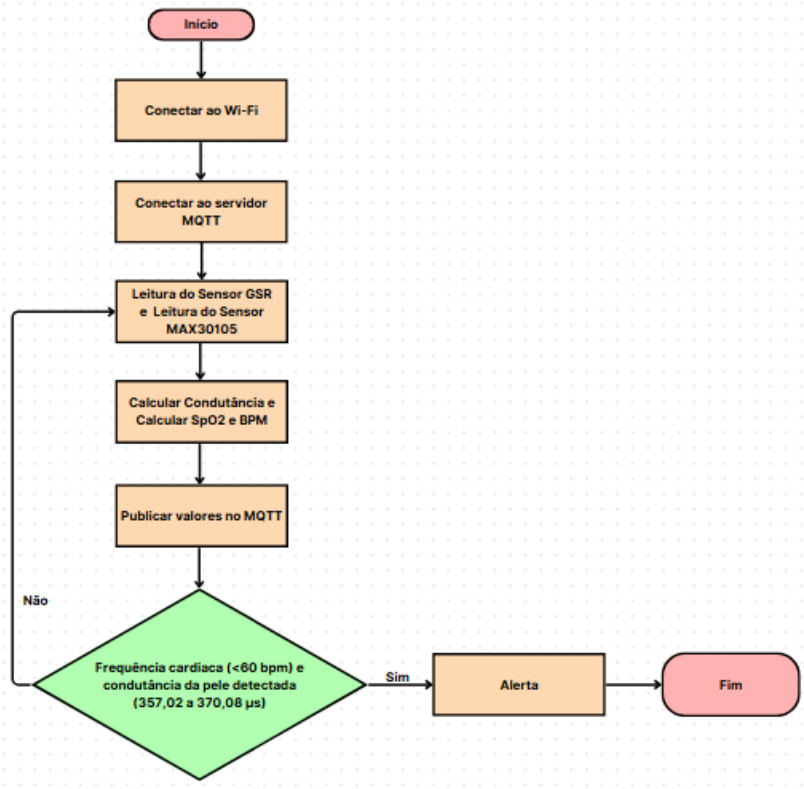


Figura 22 – Fluxo de funcionamento do sistema embarcado para detecção de sonolência. O diagrama representa as etapas sequenciais de aquisição, processamento e análise dos sinais fisiológicos no ESP32. A lógica envolve a leitura dos sensores MAX30102 e GSR, aplicação de filtros e cálculos de BPM, SpO_2 e condutância da pele. Caso os parâmetros indicativos de sonolência sejam detectados, o sistema aciona um alerta sonoro e transmite os dados via MQTT para monitoramento remoto em tempo real.

3.7 Critérios de Avaliação de Desempenho

Para avaliar a capacidade dos classificadores em distinguir corretamente entre os estados fisiológicos de "vigília"e "sonolência", foram utilizadas métricas clássicas de desempenho extraídas das matrizes de confusão de cada sensor. As métricas consideradas foram:

- **Sensibilidade (Recall):** Representa a capacidade do sistema de detectar corretamente um motorista sonolento. Uma baixa sensibilidade é perigosa, pois leva a falhas na detecção (falsos negativos). A sensibilidade é calculada por:

$$\text{Sensibilidade} = \frac{VP}{VP + FN}$$

  Essa métrica é fundamental em sistemas de monitoramento biomédico e em classificadores binários, onde minimizar falsos negativos é essencial (RAINIO; TEUHO; KLéN, 2024).

- **Especificidade:** Mede a capacidade do sistema de identificar corretamente um motorista em estado de vigília. Uma baixa especificidade torna o sistema irritante e inconfiável devido ao excesso de falsos alarmes (falsos positivos). A especificidade é dada por:

$$\text{Especificidade} = \frac{VN}{VN + FP}$$

  Sua aplicação é crítica em contextos em que alarmes falsos comprometem a confiança no sistema (RAINIO; TEUHO; KLéN, 2024).

- **Acurácia:** Representa a proporção total de classificações corretas realizadas pelo sistema, considerando tanto os estados de sonolência quanto de vigília. É dada por:

$$\text{Acurácia} = \frac{VP + VN}{VP + FN + VN + FP}$$

  Embora útil, a acurácia pode ser enganosa em cenários com classes desbalanceadas, sendo recomendada a análise combinada com outras métricas (RAINIO; TEUHO; KLéN, 2024).

4 Resultados e Análise

Este capítulo apresenta a avaliação quantitativa do sistema proposto para detecção de sonolência. A abordagem transita da simples comprovação de diferenças fisiológicas entre os estados de sono e vigília para uma rigorosa avaliação do desempenho do sistema como um classificador. Primeiramente, são apresentadas a análise estatística descritiva dos parâmetros biométricos (GSR, BPM e SpO_2) e a estratégia para mitigação de artefatos. Em seguida, o capítulo foca na avaliação de desempenho, utilizando métricas cruciais como sensibilidade e especificidade para quantificar a eficácia de cada sensor. Por fim, é realizada uma discussão crítica dos resultados, incluindo as limitações do estudo e uma proposta detalhada para validação futura contra um método padrão-ouro.

4.1 Análise Estatística e Pré-processamento dos Sinais

4.1.1 Mitigação de Artefatos no Pré-processamento

Sinais fisiológicos coletados em ambientes dinâmicos, como no interior de um veículo, estão inerentemente sujeitos a artefatos que podem comprometer a qualidade da medição. Para o sensor PPG (BPM e SpO_2), os principais desafios são artefatos de movimento (e.g., ajustes da mão no volante) e variações na pressão de contato. Para o sensor GSR, a qualidade e estabilidade do contato dos eletrodos são fundamentais.

Neste trabalho, o pré-processamento dos sinais foi um passo crucial para garantir a integridade dos dados. A aplicação de filtros, como a média móvel e o filtro exponencial, atuou como um filtro passa-baixas, atenuando ruídos de alta frequência e picos abruptos causados por movimentos. Essa etapa foi essencial para estabilizar as leituras e permitir uma análise fisiológica confiável. Contudo, reconhece-se que uma validação completa da robustez do sistema exigiria testes em condições de condução simulada, onde a frequência e a magnitude dos artefatos são mais representativas do cenário real de aplicação.

4.1.2 Análise Comparativa dos Parâmetros Fisiológicos

Para verificar se os parâmetros fisiológicos coletados apresentam variações estatisticamente significativas entre os estados de sono e vigília, foi realizado o teste t de Student com correção de Welch, adequado para amostras de tamanhos e variâncias distintas. As Figuras 23, 24 e 25 ilustram visualmente a distribuição dos dados para cada estado, enquanto as Tabelas 7, 8 e 9 sumarizam os resultados estatísticos.

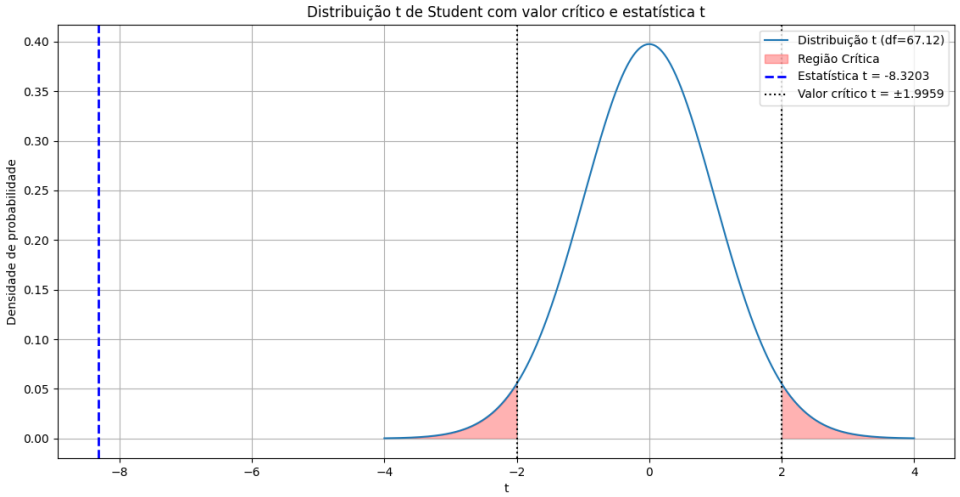


Figura 23 – Distribuição comparativa da Frequência Cardíaca (BPM) entre os estados de Sono (N=537) e Vigília (N=52).

Tabela 7 – Análise estatística da Frequência Cardíaca (BPM) usando o teste t de Welch.

Métrica	**Valor**
Média (sono)	57.80 BPM
Média (vigília)	71.73 BPM
Diferença de médias	-13.92 BPM
Estatística t (Welch)	-8.32
Valor-p (bicaudal)	< 0.0001

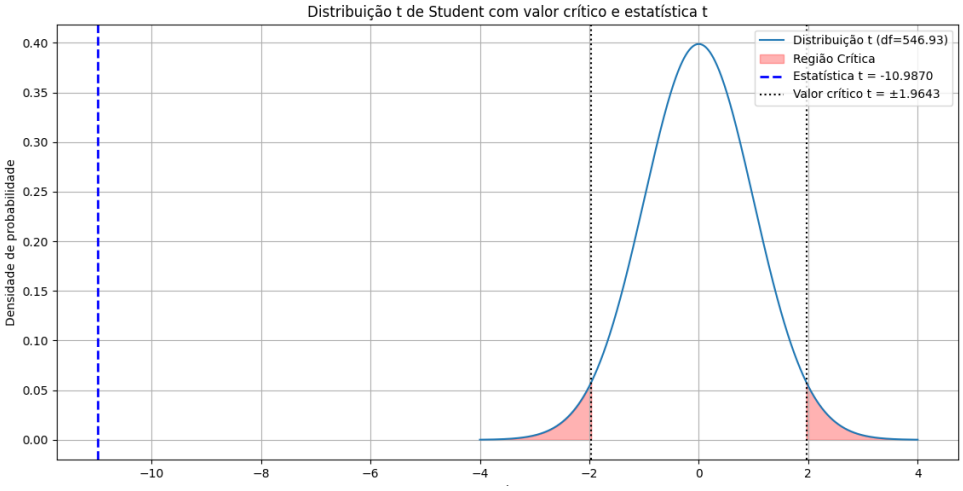


Figura 24 – Distribuição comparativa da Saturação de Oxigênio (SpO_2) entre os estados de Sono (N=537) e Vigília (N=55). Nota-se uma maior dispersão e uma leve redução da SpO_2 durante o sono.

Tabela 8 – Análise estatística da SpO_2 usando o teste t de Welch.

Métrica	**Valor**
Média (sono)	97.43 %
Média (vigília)	99.87 %
Diferença de médias	-2.43 %
Estatística t (Welch)	-10.98
Valor-p (bicaudal)	< 0.0001

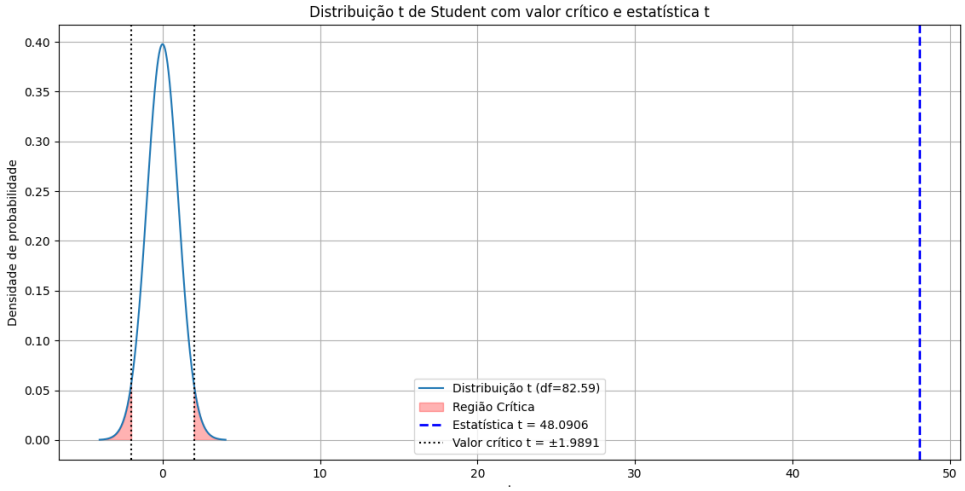


Figura 25 – Distribuição comparativa da Condutância da Pele (GSR) entre os estados de Sono (N=537) e Vigília (N=55). A condutância se mostrou consistentemente mais elevada durante o período de sono neste estudo.

Tabela 9 – Análise estatística da Condutância da Pele (GSR) usando o teste t de Welch.

Métrica	**Valor**
Média (sono)	364.35 µS
Média (vigília)	353.77 µS
Diferença de médias	10.58 µS
Estatística t (Welch)	48.09
Valor-p (bicaudal)	< 0.0001

Em todos os três parâmetros, o valor-p foi inferior a 0.0001, rejeitando a hipótese nula e confirmando que existem diferenças estatisticamente significativas entre as médias dos estados de sono e vigília. Esta constatação é a premissa fundamental para a construção de um sistema de detecção, mas não garante, por si só, sua eficácia. A avaliação de desempenho a seguir investiga a utilidade prática dessas diferenças.

4.2 Avaliação de Desempenho do Sistema de Detecção

A análise estatística confirma a separabilidade dos dados. Agora, o passo crucial é avaliar o quão bem um classificador simples, baseado em limiares, pode explorar essa

separabilidade para distinguir os estados. Para esta avaliação, o estado "dormindo"foi definido como a classe positiva ("Sonolento") e o estado "acordado"como a classe negativa ("Vigília"). O limiar teórico para cada sensor foi definido como a média entre as médias dos dois estados.

A Tabela 10 apresenta a matriz de confusão e as métricas de desempenho resultantes para cada sensor operando de forma independente.

Tabela 10 – Desempenho dos classificadores baseados em limiar único para cada parâmetro fisiológico, utilizando o estado "dormindo"como proxy para "sonolento".

Métrica	**GSR**	**PPG (BPM)**	**SpO_2**
Threshold Utilizado	359.06 µS	64.77 BPM	98.65 %
Verdadeiros Positivos (VP)	530	444	120
Falsos Negativos (FN)	7	93	417
Verdadeiros Negativos (VN)	54	40	55
Falsos Positivos (FP)	1	12	0
Sensibilidade (Recall)	**98.70%**	82.68%	22.35%
Especificidade	**98.18%**	76.92%	100.00%
Acurácia	98.65%	82.17%	29.56%

A análise da Tabela 10 revela que o sensor GSR emerge como o parâmetro mais robusto e equilibrado, alcançando uma sensibilidade de 98.70% e uma especificidade de 98.18%. Isso indica que o sistema baseado em GSR é altamente eficaz tanto para detectar a sonolência quanto para evitar falsos alarmes.

O PPG (BPM) apresenta um desempenho moderado. Embora sua acurácia seja de 82.17%, a sensibilidade de 82.68% implica que quase 18% dos eventos de sonolência não seriam detectados. A especificidade de 76.92% também aponta para uma taxa considerável de falsos positivos, o que poderia reduzir a confiança do motorista no sistema.

Por fim, a SpO_2, apesar de sua variação ser estatisticamente significativa, mostra-se inadequada como detector primário. A sensibilidade de apenas 22.35% é inaceitavelmente baixa para uma aplicação de segurança, pois o sistema falharia em alertar o motorista em mais de 77% das vezes.

4.3 Discussão dos Resultados e Proposta de Validação

4.3.1 Análise Crítica dos Sensores e Potencial para Fusão de Dados

Os resultados de desempenho demonstram que nem toda variável estatisticamente significativa se traduz em um bom preditor. O GSR foi o indicador mais confiável, provavelmente devido à sua forte correlação com a atividade do sistema nervoso autônomo,

que é profundamente modulado durante a transição vigília-sono. A frequência cardíaca (BPM) se mostrou um indicador secundário útil, mas menos confiável que o GSR.

A SpO_2 merece uma discussão particular. Sua baixa sensibilidade a desqualifica como variável primária. No entanto, sua especificidade perfeita (100%) neste conjunto de dados sugere um papel potencial em um modelo de fusão de dados. Em um sistema multimodal, uma queda acentuada na SpO_2, embora rara, poderia servir como um forte indicador secundário para confirmar um alarme gerado pelo GSR, ou para identificar eventos respiratórios (como apneias) que são uma causa conhecida de sonolência diurna (DHRUBA et al., 2021). Portanto, embora sua exclusão como variável primária seja justificada, sua inclusão em um modelo de classificação mais avançado (e.g., machine learning) pode agregar valor.

4.3.2 Proposta de Validação com Padrão-Ouro e Limitações do Estudo

A principal limitação deste estudo é a utilização do estado "dormindo"como um *proxy* para "sonolento". Embora fisiologicamente relacionado, o início da sonolência em um motorista é um processo gradual que não é perfeitamente capturado por uma coleta de dados durante o sono noturno.

Para validar robustamente a eficácia do sistema em um cenário de aplicação real, propõe-se um protocolo experimental futuro utilizando um padrão-ouro estabelecido:

- **Método Padrão-Ouro:** A Karolinska Sleepiness Scale (KSS), uma escala subjetiva de 9 pontos, seria utilizada. A KSS é um método validado e amplamente empregado na literatura para autoavaliação de sonolência em tempo real.
- **Protocolo Experimental:** O experimento envolveria voluntários em um simulador de direção por um período de 60 a 90 minutos, tipicamente em horários de baixa circadiana (e.g., início da tarde ou madrugada). A cada 10-15 minutos, a tarefa de direção seria interrompida para que o participante registrasse seu nível de sonolência na escala KSS. Os dados de GSR, PPG e SpO_2 seriam coletados continuamente.
- **Geração do *Ground Truth* e Validação:** As anotações da KSS seriam o nosso *ground truth*. Leituras com KSS ≥ 7 seriam rotuladas como "Sonolento"(classe positiva) e KSS ≤ 6 como "Vigília"(classe negativa). Esses rótulos seriam sincronizados com os segmentos correspondentes dos sinais fisiológicos, permitindo um novo cálculo da matriz de confusão, sensibilidade e especificidade, desta vez contra um padrão-ouro comportamental e não apenas fisiológico.

A implementação deste protocolo, mesmo que como uma proposta detalhada, fortalece o trabalho ao demonstrar uma compreensão clara dos passos necessários para levar um protótipo de laboratório a um sistema validado e confiável. Em suma, os resulta-

dos deste TCC validam a viabilidade do GSR como um forte indicador de sonolência e do BPM como um indicador secundário, estabelecendo uma base sólida para futuros desenvolvimentos e para a validação rigorosa aqui proposta.

4.3.3 Comparação com a Literatura e Diferenciais do Sistema Proposto

A análise crítica dos resultados deste trabalho ganha profundidade quando contextualizada com a literatura científica, conforme apresentado na Tabela 5. Os estudos mais antigos, como os de (SABET et al., 2012) e (EBRAHIM; STOLZMANN; YANG, 2013), dependiam de abordagens unimodais, muitas vezes invasivas (EOG) ou suscetíveis a condições ambientais (câmeras), sem reportar métricas quantitativas de desempenho. O trabalho de (LI; CHUNG, 2014), embora quantitativo, empregava equipamentos intrusivos (capacete de EEG), tornando sua aplicação prática inviável.

As abordagens mais recentes, por outro lado, demonstram o poder da fusão de dados e de modelos de inteligência artificial, alcançando acurácias consistentemente superiores a 90% (ZHANG et al., 2022; DU et al., 2021; KASSEM; CHOWDHURY; ABAWAJY, 2021; LEE; LEE; JEONG, 2020). É neste cenário que o presente trabalho oferece uma contribuição singular. Enquanto trabalhos de ponta como (ALGUINDIGUE et al., 2024) empregam arquiteturas de deep learning computacionalmente intensivas (SNN, 1D-CNN) para atingir uma acurácia de 98.28% com HRV, este estudo demonstra que um único parâmetro fisiológico (GSR), processado com um classificador de limiar extremamente simples, pode atingir um desempenho comparável (acurácia de 98.65%, sensibilidade de 98.70% e especificidade de 98.18%).

O diferencial fundamental deste sistema reside na sua eficiência e simplicidade. O resultado sugere que, para a detecção de estados de sonolência bem definidos, a seleção de um biomarcador robusto e fisiologicamente relevante (GSR) pode ser mais impactante do que a complexidade do algoritmo de classificação. Esta constatação é de grande relevância prática, pois aponta para a viabilidade de um sistema de baixo custo computacional, sem a necessidade de GPUs ou processadores de alto desempenho exigidos por modelos de deep learning.

Adicionalmente, o uso de sensores de contato como GSR e PPG oferece uma vantagem intrínseca sobre os sistemas baseados em câmera, como os de (ZHANG et al., 2022) e (KASSEM; CHOWDHURY; ABAWAJY, 2021), pois não são afetados por condições de iluminação adversas, uso de óculos de sol ou movimentos de cabeça que não alterem o contato do sensor. A simplicidade do modelo baseado em limiar também confere maior interpretabilidade em comparação com as "caixas-pretas"dos modelos de aprendizado profundo, facilitando a validação e certificação para aplicações de segurança.

5 Considerações finais

O presente trabalho apresentou uma análise aprofundada sobre o uso combinado de sensores de fotopletismografia (PPG) e resposta galvânica da pele (GSR) para o monitoramento de sinais fisiológicos associados à sonolência em motoristas. Através do desenvolvimento de um protótipo funcional baseado em uma pulseira vestível, integrada ao microcontrolador ESP32 e à plataforma Node-RED via protocolo MQTT, foi possível realizar a aquisição e o processamento dos sinais em tempo real. As variações observadas entre os estados de vigília e sonolência indicam que a proposta é viável tecnicamente e possui potencial de aplicação prática no aumento da segurança viária.

Os resultados obtidos demonstraram que a frequência cardíaca (BPM) é um marcador fisiológico eficaz para indicar a sonolência. Durante os períodos de transição para o sono, observou-se uma redução consistente da BPM, enquanto nos momentos de alerta, os valores eram significativamente mais altos. Esse padrão corrobora a literatura e reforça a utilidade da análise da frequência cardíaca como um indicativo do nível de alerta do motorista.

A saturação de oxigênio no sangue (SpO), por sua vez, apresentou variações mais sutis entre os estados analisados, mantendo-se relativamente estável durante a vigília. Embora menos sensível às mudanças de estado, a SpO se mostrou um parâmetro complementar útil, sobretudo quando analisado em conjunto com os demais sinais fisiológicos.

A resposta galvânica da pele (GSR) revelou-se um importante indicador da atividade do sistema nervoso simpático. Durante o sono, foi observada uma queda na condutância elétrica da pele, indicando menor atividade simpática, enquanto na vigília, a condutância aumentava. Essa diferença é crucial para a detecção de sonolência, uma vez que reflete diretamente o nível de excitação fisiológica do indivíduo, sendo um sinal confiável e não invasivo.

A arquitetura empregada com sensores vestíveis conectados ao ESP32 e transmissão de dados via MQTT para o ambiente Node-RED mostrou-se robusta e funcional. A integração dos componentes permitiu uma coleta eficiente e em tempo real dos dados, tornando a solução escalável e de baixo custo. A facilidade de reconfiguração do sistema, aliada à portabilidade da pulseira vestível, destaca-se como um diferencial em relação a abordagens mais complexas e invasivas.

Apesar dos resultados promissores, o sistema proposto apresentou limitações práticas relevantes, principalmente no que se refere à calibração dos sensores. Tradicionalmente, dispositivos baseados em resposta galvânica da pele (GSR) enfrentam dificuldades relacionadas às variações interindividuais de condutância elétrica. Estas variações podem ser

causadas por fatores fisiológicos (como idade, hidratação e nível basal de estresse), ambientais (como temperatura e umidade) e comportamentais (como movimentação ou suor). Em sistemas convencionais, essas diferenças exigiriam ajustes manuais ou reconfigurações para cada novo usuário.

Contudo, com o uso de modelos de aprendizado de máquina, essa necessidade pode ser substancialmente reduzida — ou até eliminada. Ao treinar algoritmos supervisionados (como random forests ou SVMs) ou redes neurais profundas (como LSTMs e CNNs) com um volume suficiente de dados multivariados, torna-se possível personalizar automaticamente os limiares de alerta e identificar padrões individuais de sonolência com alta acurácia. Em vez de calibrar sensores, o sistema pode calibrar o modelo: adaptando-se ao usuário conforme aprende seus padrões fisiológicos típicos em tempo real, sem intervenção manual.

Além disso, técnicas de aprendizado contínuo (*online learning*) podem ser incorporadas à arquitetura do sistema, permitindo que ele aprenda com novas situações e refine sua sensibilidade ao longo do tempo. Isso torna a solução não apenas adaptativa, mas também evolutiva — capaz de melhorar com o uso prolongado. Em versões futuras, o uso de IA embarcada diretamente no ESP32 (*Edge AI*), com modelos otimizados por frameworks como TinyML, poderá permitir esse tipo de inteligência diretamente no dispositivo, sem necessidade de conectividade contínua com a nuvem.

A coleta e o processamento de dados fisiológicos sensíveis exigem uma abordagem ética rigorosa. Todos os participantes da fase experimental foram informados sobre os objetivos do estudo e assinaram o termo de consentimento livre e esclarecido (TCLE), conforme as diretrizes da Resolução nº 466/2012 do Conselho Nacional de Saúde. Os dados foram anonimizados e armazenados de forma segura, com criptografia de ponta a ponta nas transmissões via MQTT. Adicionalmente, o projeto buscou estar em conformidade com a Lei Geral de Proteção de Dados (LGPD – Lei nº 13.709/2018), assegurando que as informações dos participantes não fossem compartilhadas ou identificadas.

Futuramente, caso o sistema seja comercializado, será essencial implementar mecanismos avançados de proteção de dados, como autenticação biométrica, segregação de perfis e auditoria de acessos. O respeito à privacidade do condutor é um pilar fundamental para a adoção ética e socialmente aceitável de sistemas biomédicos em ambientes veiculares.

Como próximos passos, propõe-se a realização de testes mais amplos com, pelo menos, 20 motoristas, utilizando simuladores de direção em sessões de 60 a 90 minutos por dia durante 30 dias. Este tipo de ensaio permitirá avaliar a robustez do modelo em diferentes perfis fisiológicos, além de testar a durabilidade e estabilidade do hardware em uso contínuo. Paralelamente, a coleta de dados mais extensa poderá alimentar modelos preditivos baseados em inteligência artificial, capazes de detectar padrões ainda mais sutis

de sonolência com alta precisão.

O sistema, ao invés de seguir um modelo estático e pré-definido, passará a operar com modelos dinâmicos, ajustados individualmente por meio de aprendizado incremental. Tal abordagem possibilita não apenas uma detecção mais precisa, mas também a antecipação da sonolência com base em predições de tendências fisiológicas, permitindo alertas mais precoces e eficazes.

A integração com ADAS (Advanced Driver Assistance Systems) também poderá evoluir, passando de simples comandos de alerta para uma fusão sensorial mais sofisticada. Por exemplo, os dados fisiológicos da pulseira podem ser correlacionados com informações de câmeras veiculares, sensores de faixa e GPS, criando um sistema de decisão multifatorial, onde a sonolência detectada pode influenciar diretamente o comportamento preditivo do carro — como ajustar a velocidade em função da fadiga do condutor.

A aplicação de modelos de IA treinados em nuvem e executados localmente (*Edge Computing*) é uma estratégia promissora para viabilizar a escalabilidade do sistema com inteligência embarcada. A utilização de modelos otimizados para microcontroladores (como os desenvolvidos com TensorFlow Lite for Microcontrollers) pode permitir que a pulseira opere de forma autônoma, com baixíssimo consumo de energia e sem necessidade de conexão contínua à internet.

Além disso, a flexibilidade da arquitetura baseada em MQTT permite a comunicação eficiente entre o dispositivo e servidores em nuvem, que podem realizar tarefas mais intensivas de reprocessamento e reentreinamento dos modelos periodicamente, atualizando os dispositivos no campo de forma transparente ao usuário. Esse ciclo contínuo de aprendizado, atualização e reimplantação é o que torna o sistema verdadeiramente escalável.

Em termos regulatórios, será necessário observar as exigências da ANVISA, caso o dispositivo venha a ser classificado como produto para saúde. A parceria com montadoras e centros de pesquisa automotiva também será essencial para validação em ambientes reais, bem como para viabilizar projetos-piloto em frotas comerciais ou veículos de teste.

Em síntese, este trabalho demonstrou a viabilidade de um sistema de detecção de sonolência com base em sinais fisiológicos, utilizando sensores não invasivos e tecnologias de baixo custo. A integração de conhecimentos em engenharia eletrônica, biomédica, inteligência artificial e Internet das Coisas permitiu o desenvolvimento de uma solução inovadora, portátil e com potencial de aplicação em larga escala.

Além da contribuição técnica, o impacto prático pode ser significativo. Estimativas baseadas em dados da ABRAMET sugerem que até 5% dos acidentes de trânsito estão associados à sonolência ao volante. A implementação de sistemas preventivos como o proposto neste projeto pode contribuir diretamente para a redução desses números, salvando

vidas e diminuindo os custos socioeconômicos associados a acidentes.

Por fim, o trabalho abre portas para futuras publicações em conferências nacionais e internacionais na área de engenharia biomédica, sistemas embarcados, inteligência artificial aplicada e segurança automotiva. A proposta aqui apresentada reforça o papel da engenharia como ferramenta essencial para a inovação responsável e a preservação da vida humana.

Reforçando o compromisso com a ciência aberta e a reprodutibilidade da pesquisa, o código-fonte, os dados experimentais e as configurações utilizadas neste projeto foram tornados publicamente acessíveis. Esta iniciativa visa não apenas validar os resultados aqui apresentados, mas também servir como base para futuros trabalhos e desenvolvimentos na área de monitoramento de sonolência. Os detalhes para acesso ao material podem ser encontrados no **Apêndice B**.

Referências

AHMED, S. G. et al. Ai innovations in rppg systems for driver monitoring: Comprehensive systematic review and future prospects. *IEEE Access*, 2024. Preprint, to appear in vol. 13, 2025. Citado na página 45.

AKAY, M. *Wiley Encyclopedia of Biomedical Engineering*. Hoboken, NJ, USA: Wiley-Interscience, 2006. 4152 p. Citado na página 24.

ALGUINDIGUE, J. et al. Biosignals monitoring for driver drowsiness detection using deep neural networks. *IEEE Access*, v. 12, p. 93075–93086, 2024. Citado 3 vezes nas páginas 45, 46 e 69.

ALLEN, J. Photoplethysmography and its application in clinical physiological measurement. *Physiological Measurement*, IOP Publishing, v. 28, n. 3, p. R1–R39, 2007. Citado 2 vezes nas páginas 23 e 24.

ALMARSHAD MD SAIFUL ISLAM, S. A.-A. M. A.; BAHAMMAM, A. S. Diagnostic features and potential applications of ppg signal in healthcare: A systematic review. 2022. Disponível em: <https://www.mdpi.com/2227-9032/10/3/547>. Citado 2 vezes nas páginas 9 e 26.

BABIUCH, M.; FOLTYNEK, P.; SMUTNý, P. Using the esp32 microcontroller for data processing. In: . [S.l.: s.n.], 2019. p. 1–6. Citado na página 33.

BARANAUSKAS, E.; TOLDINAS, J.; LOZINSKIS, B. Evaluation of the impact on energy consumption of mqtt protocol over tls. 05 2019. Citado na página 41.

BOUCSEIN, W. *Electrodermal Activity*. 2nd. ed. New York: Springer Science & Business Media, 2012. Citado 2 vezes nas páginas 30 e 31.

BOULNOIS, J.-L. Photophysical processes in recent medical laser developments: A review. *Lasers Med Sci*, v. 1, p. 47–66, 08 1986. Citado na página 26.

BRAITHWAITE, J. J. et al. A guide for analysing electrodermal activity (eda) skin conductance responses (scrs) for psychological experiments. *Psychophysiology*, v. 49, p. 1017–1034, 2013. Este artigo foi publicado em 'Technical Report, University of Birmingham, $B_I R_{I2}013'erevisadoem2015/2018.Acitaçãomaisformalseriaparaorelatóriotécnico, masareferência$

BRASIL. *Lei nº 13.709, de 14 de agosto de 2018*. 2018. <https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm>. Dispõe sobre a proteção de dados pessoais e altera a Lei nº 12.965, de 23 de abril de 2014 (Marco Civil da Internet). Citado na página 43.

BURNETT, S.; ZHANG, L.; KUMAR, N. Mqtt protocol performance and scalability in large-scale iot deployments. In: *IEEE International Conference on Internet of Things (iThings)*. [S.l.: s.n.], 2021. p. 112–117. Citado na página 38.

CASTANEDA, D. et al. A review on wearable photoplethysmography sensors and their potential future applications in health care. *International Journal of Biosensors & Bioelectronics*, v. 4, n. 4, p. 195–202, 2018. Citado na página 24.

CHEANG, P.; PECK, Y.; SMITH. *An overview of non-contact photoplethysmography*. 2003. Disponível em: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=86683b5f8ff3135b3ef7fae8a7928bc381a0a2a9>. Citado na página 23.

CHOI, A.; SHIN, H. Photoplethysmography sampling frequency: Pilot assessment of how low can we go to analyze pulse rate variability with reliability? *Physiological Measurement*, v. 38, 02 2017. Citado na página 27.

Conselho Nacional de Saúde. *Resolução nº 466, de 12 de dezembro de 2012*. 2012. <https://www.gov.br/conselho-nacional-de-saude/pt-br/atos-normativos/resolucoes/2012/resolucao-no-466.pdf/view>. Aprova diretrizes e normas regulamentadoras de pesquisas com seres humanos. Citado na página 43.

DAWSON, M. E.; SCHELL, A. M.; FILION, D. L. The electrodermal system. In: CACIOPPO, J. T.; TASSINARY, L. G.; BERNTSON, G. G. (Ed.). *Handbook of Psychophysiology*. 3rd. ed. Cambridge: Cambridge University Press, 2007. p. 159–181. Citado na página 31.

DHRUBA, A. R. et al. Development of an iot-based sleep apnea monitoring system for healthcare applications [retratado em: Computational and mathematical methods in medicine, 2023 nov 1; 2023:9850528]. *Computational and Mathematical Methods in Medicine*, v. 2021, p. 7152576, 2021. Disponível em: <https://doi.org/10.1155/2021/7152576>. Citado na página 68.

DU, G. et al. Vision-based fatigue driving recognition method integrating heart rate and facial features. *IEEE Transactions on Intelligent Transportation Systems*, v. 22, n. 5, p. 3089–3100, 2021. Citado 2 vezes nas páginas 46 e 69.

EBRAHIM, P.; STOLZMANN, W.; YANG, B. Eye movement detection for assessing driver drowsiness by electrooculography. In: . [S.l.: s.n.], 2013. p. 4142–4148. Citado 3 vezes nas páginas 19, 46 e 69.

ELGENDI, M. On the analysis of fingertip photoplethysmogram signals. *Current Cardiology Reviews*, v. 8, n. 1, p. 14–25, 2012. Citado 2 vezes nas páginas 23 e 24.

ELGENDI, M. et al. A systematic review of peak detection algorithms in photoplethysmogram signals. *IEEE Access*, v. 10, p. 15512–15528, 2022. Citado na página 29.

ESP-WROOM-32 Datasheet(PDF) - ESPRESSIF SYSTEMS (SHANGHAI) CO., LTD. <https://www.alldatasheet.com/datasheet-pdf/pdf/1179101/ESPRESSIF/ESP-WROOM-32.html>. Accessed: 2023-7-2. Citado na página 34.

ESP32-DevKitC V4 Getting Started Guide - ESP32 - — ESP-IDF Programming Guide latest documentation. <https://docs.espressif.com/projects/esp-idf/en/latest/esp32/hw-reference/esp32/get-started-devkitc.html>. Accessed: 2023-9-5. Citado 2 vezes nas páginas 9 e 34.

Espressif Systems. *ESP32 Power Management Overview*. 2022. Acesso em: 30 jun. 2025. Disponível em: <https://docs.espressif.com/projects/esp-idf/en/latest/esp32/api-reference/system/power_management.html>. Citado na página 35.

Espressif Systems. *ESP32 Technical Reference Manual*. [S.l.], 2023. Acesso em: 30 jun. 2025. Disponível em: <https://www.espressif.com/en/support/documents/technical-documents>. Citado na página 35.

FISCHER, C. et al. *An Algorithm for Real-Time Pulse Waveform Segmentation and Artifact Detection in Photoplethysmograms*. 2017. 372-381 p. Citado na página 23.

GUBBI, S. V.; AMRUTUR, B. Adaptive pulse width control and sampling for low power pulse oximetry. *IEEE Transactions on Biomedical Circuits and Systems*, v. 9, n. 2, p. 272–283, 2015. Citado na página 26.

HACHISUKA, S. Human and vehicle-driver drowsiness detection by facial expression. In: . [S.l.: s.n.], 2013. p. 320–326. Citado na página 19.

HUANG, Y.; BENESTY, J. (Ed.). *Audio Signal Processing for Next-Generation Multimedia Communication Systems*. [S.l.]: Springer, 2014. Citado na página 43.

IBM. *MQTT 3.1.1 Specification*. 2018. <https://www.ibm.com/docs/pt-br/ibm-mq/8.0?topic=concepts-qualities-service-provided-by-mqtt-client>. Acesso em: 27 jan. 2025. Citado na página 37.

IBM. *Node-RED: The flow-based development tool for the Internet of Things*. 2020. Acessado em: 28 jan. 2025. Disponível em: <http://ibm.com/docs/en/netcoolomnibus/8?topic=red-integrating-internet-things-using-node>. Citado na página 39.

IFEACHOR, E. C.; JERVIS, B. W. *Digital Signal Processing: A Practical Approach*. 2. ed. London: Pearson, 2013. Citado na página 42.

INDURSKY, P.; MARKELOV, V. The phenomenon of weak, unawakening afferent signals involvement in synchronization mechanisms of neuron activity during delta sleep-unawakening afferent signals involvement in synchronization mechanisms of neuron activity during delta international journal of sleep disorders international journal of sleep disorders scires literature-volume 1 issue 1-www.scireslit.com. *International Journal of Sleep Disorders*, v. 1, p. 7–12, 01 2017. Citado 2 vezes nas páginas 9 e 33.

KARLEN, W. et al. Multiparameter respiratory rate estimation from the photoplethysmogram. *IEEE Transactions on Biomedical Engineering*, v. 60, n. 7, p. 1946–1953, 2013. Citado na página 25.

KASSEM, H. A.; CHOWDHURY, M.; ABAWAJY, J. H. Drivers fatigue level prediction using facial, and head behavior information. *IEEE Access*, v. 9, p. 121686–121697, 2021. Citado 2 vezes nas páginas 46 e 69.

KIM, J.; PARK, K. Low power wearable sensing system using ppg and gsr for monitoring driver drowsiness. *Sensors*, v. 20, n. 3, p. 736, 2020. Citado na página 36.

KORKALAINEN, H. et al. Deep learning enables sleep staging from photoplethysmogram for patients with suspected sleep apnea. *Sleep*, v. 43, 05 2020. Citado 2 vezes nas páginas 9 e 26.

LAI, P.-H.; KIM, I. *Lightweight wrist photoplethysmography for heavy exercise: motion robust heart rate monitoring algorithm*. 2015. 6-11 p. Disponível em: <https://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/htl.2014.0097>. Citado na página 23.

LAWOYIN, S. et al. Detection methods for a low-cost accelerometer-based approach for driver drowsiness detection. In: . [S.l.: s.n.], 2014. v. 2014, p. 1636–1641. Citado na página 19.

LEE, B. G.; CHUNG, W.-Y. Driver alertness monitoring using fusion of facial features and bio-signals. *IEEE Sensors Journal - IEEE SENS J*, v. 12, p. 2416–2422, 07 2012. Citado na página 19.

LEE, B.-G.; LEE, S.-Y.; JEONG, S.-H. Driver drowsiness detection system based on fusion of wearable biosensors and machine learning. *Sensors*, v. 20, n. 4, p. 1131, 2020. Citado 2 vezes nas páginas 46 e 69.

LEE, H. et al. Wearable multichannel photoplethysmography framework for heart rate monitoring during intensive exercise. *IEEE Sensors Journal*, v. 18, n. 7, p. 2983–2993, 2018. Citado na página 26.

LENG, L.; LEE, B. G.; CHUNG, W.-Y. Wearable driver drowsiness detection system based on biomedical and motion sensors. In: . [S.l.: s.n.], 2015. p. 1–4. Citado na página 33.

LESTARI, G. R.; ABUZAIRI, T. Projeto de sensor galvânico portátil de resposta da pele para sensor de dor. In: *2020 International Conference on Smart Technology and Applications (ICoSTA)*. [S.l.: s.n.], 2020. p. 1–5. Citado 2 vezes nas páginas 30 e 31.

LI, G.; CHUNG, W.-Y. Estimation of eye closure degree using eeg sensors and its application in driver drowsiness detection. *Sensors (Basel, Switzerland)*, v. 14, p. 17491–17515, 09 2014. Citado 4 vezes nas páginas 19, 45, 46 e 69.

LIGHT, A. *Mosquitto MQTT Essentials*. 2023. Acesso em: 30 jun. 2025. Disponível em: <https://mosquitto.org>. Citado na página 38.

LIM, A.; CHIA, W.; CHIN, S. A mobile driver safety system: Analysis of single-channel eeg on drowsiness detection. In: . [S.l.: s.n.], 2015. Citado na página 19.

MAGSI, H. et al. Analysis of signal noise reduction by using filters. In: . [S.l.: s.n.], 2018. p. 1–6. Citado na página 42.

MITRA, S. K. *Digital Signal Processing: A Computer-Based Approach*. [S.l.]: McGraw-Hill Education, 2006. Citado na página 43.

MITRA, S. K. *Digital Signal Processing: A Computer-Based Approach*. 4. ed. New York: McGraw-Hill, 2011. Citado na página 42.

MUKHERJI, S. et al. Smart agriculture using internet of things and mqtt protocol. In: . [S.l.: s.n.], 2019. p. 14–16. Citado na página 41.

MUNIZ, R.; DIAS, R. Node-red para internet das coisas: Fluxos, escalabilidade e aplicações. *Revista Tecnologia em Foco*, v. 7, n. 2, p. 33–42, 2022. Citado na página 39.

NITZAN, M.; TAITELBAUM, H. The measurement of oxygen saturation in arterial and venous blood. *IEEE Instrumentation Measurement Magazine*, v. 11, n. 4, p. 9–15, July 2008. Citado 2 vezes nas páginas 28 e 29.

NOURBAKHSH, N. et al. Using galvanic skin response for cognitive load measurement in arithmetic and reading tasks. In: *Proceedings of the 24th Australian Computer-Human Interaction Conference*. New York, NY, USA: Association for Computing Machinery, 2012. (OzCHI '12), p. 420–423. ISBN 9781450314381. Disponível em: <https://doi.org/10.1145/2414536.2414602>. Citado na página 30.

OPPENHEIM, A. V.; SCHAFER, R. W. *Discrete-Time Signal Processing*. [S.l.]: Pearson Education, 2010. Citado na página 43.

OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. *Discrete-Time Signal Processing*. 2. ed. Upper Saddle River: Prentice Hall, 1999. Citado na página 42.

PAGLIARI, C.; OUTROS. Validation of polar elixir™ pulse oximeter against arterial blood gases during stepwise steady-state inspired hypoxia. *PubMed*, 2024. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38635406/>. Citado na página 29.

PETER, L.; NOURY, N.; CERNY, M. A review of methods for non-invasive and continuous blood pressure monitoring: Pulse transit time method is promising? *IRBM*, v. 35, 08 2014. Citado 2 vezes nas páginas 9 e 27.

Polícia Rodoviária Federal. *Dados Abertos da PRF*. Brasília, DF: [s.n.], 2024. Disponível em: <https://www.gov.br/prf/pt-br/acesso-a-informacao/dados-abertos/dados-abertos-da-prf>. Citado 2 vezes nas páginas 9 e 17.

PROAKIS, J. G.; MANOLAKIS, D. G. *Digital Signal Processing: Principles, Algorithms, and Applications*. [S.l.]: Pearson Education, 2006. Citado na página 43.

PROAKIS, J. G.; MANOLAKIS, D. G. *Digital Signal Processing: Principles, Algorithms, and Applications*. 5. ed. London: Pearson, 2021. Citado na página 42.

PURNAMASARI, P.; JUNIKA, T. Frequency-based eeg human concentration detection system methods with svm classification. In: . [S.l.: s.n.], 2019. p. 29–34. Citado na página 32.

RADWAN, N.; ALVES-FOSS, J. Mqtt in focus: Understanding the protocol and its recent advancements. v. 18, p. 1–14, 06 2024. Citado na página 41.

RAINIO, O.; TEUHO, J.; KLéN, R. Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, v. 14, n. 1, p. 6086, 2024. ISSN 2045-2322. Disponível em: <https://doi.org/10.1038/s41598-024-56706-x>. Citado na página 63.

RAMESH, M. V.; NAIR, A.; KUNNATH, A. T. Real-time automated multiplexed sensor system for driver drowsiness detection. In: . [S.l.: s.n.], 2011. p. 1–4. ISBN 978-1-4244-6250-6. Citado na página 19.

SABET, M. et al. A new system for driver drowsiness and distraction detection. In: . [S.l.: s.n.], 2012. Citado 4 vezes nas páginas 19, 45, 46 e 69.

SEDGHAMIZ, H. Heart rate variability analysis using ppg and ecg signals: A review. *Biomedical Signal Processing and Control*, v. 45, p. 230–244, 2018. Citado na página 29.

SONI, D.; MAKWANA, A. A survey on mqtt: A protocol of internet of things(iot). In: . [S.l.: s.n.], 2017. Citado 3 vezes nas páginas 36, 37 e 41.

SPIGULIS, J. et al. *Simultaneous recording of skin blood pulsations at different vascular depths by multiwavelength photoplethysmography*. Optica Publishing Group, 2007. 1754–1759 p. Disponível em: <https://opg.optica.org/ao/abstract.cfm?URI=ao-46-10-1754>. Citado na página 23.

SPOHN, M. On mqtt scalability in the internet of things: Issues, solutions, and future directions. *Journal of Electronics and Electrical Engineering*, p. 4, 10 2022. Citado na página 41.

SYSOEV, M. et al. Classificação de sensores de estresse e revisão de algoritmos de análise de estresse. *Nome da revista*, XX, n. XX, p. 9, 2014. Citado na página 30.

USMANI, M. F. *MQTT Protocol for the IoT - Review Paper*. 2021. Citado na página 37.

WANG, C.; ZHENG, Y. Home-telecare of the elderly living alone using a new designed ear-wearable sensor. In: *Proceedings of the 2008 5th International Summer School and Symposium on Medical Devices and Biosensors*. Hong Kong, China: [s.n.], 2008. p. 71–74. Citado na página 26.

XU, L. et al. Sober-drive: A smartphone-assisted drowsy driving detection system. In: . [S.l.: s.n.], 2014. p. 398–402. ISBN 978-1-4799-2358-8. Citado na página 19.

ZHANG, Z. et al. A multimodal fusion approach for driver drowsiness detection combining visual features and vehicle data. *IEEE Transactions on Intelligent Transportation Systems*, v. 23, n. 7, p. 8358–8369, 2022. Citado 2 vezes nas páginas 46 e 69.

ZHAO, D. et al. Sfst: A robust framework for heart rate monitoring from photoplethysmography signals during physical activities. *Biomedical Signal Processing and Control*, v. 33, p. 316–324, 2017. ISSN 1746-8094. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1746809416302178>. Citado 3 vezes nas páginas 9, 24 e 25.

ZILBERG, E. et al. Methodology and initial analysis results for development of non-invasive and hybrid driver drowsiness detection systems. In: . [S.l.: s.n.], 2007. p. 16 – 16. ISBN 978-0-7695-2846-5. Citado na página 19.

APÊNDICE A – Código-fonte do ESP32 (Representado em imagens)

```
#include <Adafruit_GFX.h>    // Biblioteca para gráficos no display OLED
#include <Adafruit_SSD1306.h> // Biblioteca para controle do display OLED
#include "MAX30105.h"         // Biblioteca para sensor MAX30105 (PPG - fotopletismografia)
#include "heartRate.h"        // Biblioteca para cálculo de frequência cardíaca
#include <WiFi.h>             // Biblioteca para conexão WiFi
#include <PubSubClient.h>     // Biblioteca para protocolo MQTT

MAX30105 particleSensor;      // Objeto para o sensor MAX30105
```

Figura 26 – Inclusão de bibliotecas e inicialização de objetos globais.

```
// Configurações da rede Wi-Fi
const char* ssid = "MPHUMAPO_2G";     // SSID da rede WiFi
const char* password = "MPHUMAPO";     // Senha da rede WiFi
const char* mqttServer = "192.168.0.64"; // Endereço do servidor MQTT
int port = 1883;                       // Porta do servidor MQTT
String stMac;                          // Para armazenar endereço MAC
char mac[50];                          // Buffer para endereço MAC como char array
char clientId[50];                     // ID do cliente MQTT

// Configurações do Buzzer
#define BUZZER_PIN 4  // Pino GPIO onde o buzzer está conectado

// Configurações do sensor GSR (Resistência Galvânica da Pele)
const int sensorPin = 34; // Pino analógico do sensor GSR
const int bufferSize = 10; // Tamanho do buffer para média móvel simples (SMA)
float sensorBuffer[bufferSize]; // Buffer para armazenar valores do GSR
int bufferIndex = 0; // Índice atual no buffer

// Variáveis para cálculo de batimentos cardíacos
const byte RATE_SIZE = 4; // Tamanho do array para média de batimentos
byte rates[RATE_SIZE];    // Array para armazenar batimentos
byte rateSpot = 0;        // Posição atual no array rates
long lastBeat = 0;        // Tempo do último batimento detectado
float beatsPerMinute;     // BPM atual
int beatAvg;              // Média de BPM

// Variáveis para cálculo de SpO2 (Saturação de Oxigênio)
double avered = 0;        // Média do sinal vermelho (RED)
double aveir = 0;         // Média do sinal infravermelho (IR)
double sumirrms = 0;      // Soma dos quadrados do IR
double sumredrms = 0;     // Soma dos quadrados do RED

double SpO2 = 0;          // Valor calculado de SpO2
double ESpO2 = 60.0;      // Valor estimado de SpO2 (valor inicial)
double FSpO2 = 0.7;       // Fator de filtro para SpO2 estimado
double frate = 0.95;      // Filtro passa-baixa para valores IR/RED
int i = 0;                // Contador de amostras
int Num = 30;             // Número de amostras para calcular SpO2

#define FINGER_ON 7000    // Valor mínimo de IR para detectar dedo no sensor
#define MINIMUM_SPO2 60.0 // Valor mínimo plausível de SpO2

// Configuração de intervalo para publicação MQTT
unsigned long lastPublishTime = 0;
const long publishInterval = 10000;  // Intervalo de 10 segundos

// Configurações do display OLED
#define SCREEN_WIDTH 128  // Largura do display em pixels
#define SCREEN_HEIGHT 64  // Altura do display em pixels
#define OLED_RESET    -1  // Pino de reset (não utilizado)
Adafruit_SSD1306 display(SCREEN_WIDTH, SCREEN_HEIGHT, &Wire, OLED_RESET);
```

Figura 27 – Definição de constantes e variáveis para conectividade, sensores e controle do sistema.

```
// Configurações do display OLED
#define SCREEN_WIDTH 128  // Largura do display em pixels
#define SCREEN_HEIGHT 64  // Altura do display em pixels
#define OLED_RESET    -1  // Pino de reset (não utilizado)
Adafruit_SSD1306 display(SCREEN_WIDTH, SCREEN_HEIGHT, &Wire, OLED_RESET);
// Bitmaps para exibição no OLED (coração, SpO2, GSR)
static const unsigned char PROGMEM logo2_bmp[] =
{
    0x00, 0x00, 0x00, 0x07, 0x03, 0x00, 0x1f, 0x8f, 0xc0, 0x1f, 0xdf, 0xe0, 0x3f, 0xff, 0xe0, 0x3f,
    0xff, 0xf0, 0x7f, 0xdf, 0xf0, 0x7f, 0xdf, 0xf0, 0x3f, 0x57, 0xe0, 0x1f, 0x17, 0xe0, 0x00, 0x00,
    0x00, 0x0f, 0xb7, 0x80, 0x07, 0xef, 0x00, 0x03, 0xef, 0x00, 0x01, 0xfe, 0x00, 0x01, 0xfc, 0x00,
    0x00, 0xf8, 0x00, 0x00, 0x70, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00
};
// LOGO CORAÇÃO 2     -- --COLOQUEI AQUI DE NOGO A FUNÇÃO DA LOGO DO CORAÇÃO
static const unsigned char PROGMEM logo3_bmp[] =
{
    0x00, 0x00, 0x00, 0x07, 0x03, 0x00, 0x1f, 0x8f, 0xc0, 0x1f, 0xdf, 0xe0, 0x3f, 0xff, 0xe0, 0x3f,
    0xff, 0xf0, 0x7f, 0xdf, 0xf0, 0x7f, 0xdf, 0xf0, 0x3f, 0x57, 0xe0, 0x1f, 0x17, 0xe0, 0x00, 0x00,
    0x00, 0x0f, 0xb7, 0x80, 0x07, 0xef, 0x00, 0x03, 0xef, 0x00, 0x01, 0xfe, 0x00, 0x01, 0xfc, 0x00,
    0x00, 0xf8, 0x00, 0x00, 0x70, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00
};
// LOGO SP02
static const unsigned char PROGMEM O2_bmp[] =
{
    0x00, 0x00, 0x00, 0x01, 0xe1, 0xe0, 0x07, 0xfb, 0xf0, 0x0f, 0xff, 0xf0, 0x1f, 0x7f, 0xf0, 0x3c,
    0x1f, 0xf0, 0x39, 0xcf, 0xe0, 0x7b, 0xef, 0x80, 0x73, 0xef, 0x80, 0x7b, 0xe7, 0x80, 0x79, 0xcb,
    0x80, 0x3c, 0x1b, 0x00, 0x3f, 0xf7, 0x00, 0x1f, 0xef, 0x00, 0x1f, 0xc2, 0x00, 0x3f, 0xf8, 0x00,
    0x3f, 0xe0, 0x00, 0x3f, 0x00, 0x00, 0x1e, 0x00, 0x00, 0x0c, 0x00, 0x00, 0x00, 0x00, 0x00, 0x00
};
static const unsigned char PROGMEM gsr_sensor[] =
{
    0x00, 0x30, 0x00, 0x00, 0xf8, 0x00, 0x01, 0x4e, 0x00, 0x01, 0x4a, 0x00, 0x07, 0x7a, 0x00, 0x0f,
    0x7a, 0x00, 0x09, 0xfa, 0x00, 0x09, 0xfb, 0x80, 0x09, 0xf3, 0xc0, 0x09, 0xd2, 0x40, 0x08, 0x92,
    0x40, 0x08, 0x92, 0x40, 0x08, 0x90, 0x40, 0x08, 0x90, 0x40, 0x0c, 0x90, 0xc0, 0x04, 0x50, 0x80,
    0x06, 0x71, 0x80, 0x03, 0xff, 0x00, 0x03, 0x03, 0x00, 0x03, 0xff, 0x00, 0x01, 0xfe, 0x00
};
```

Figura 28 – Configuração do display OLED e definição dos bitmaps para os ícones.

```
93  // Objetos para WiFi e MQTT
94  WiFiClient espClient;
95  PubSubClient client(espClient);
96
97  void setup_wifi() {
98    delay(10);
99    Serial.println();
100   Serial.print("Conectando-se a ");
101   Serial.println(ssid);
102
103   WiFi.begin(ssid, password);
104
105   while (WiFi.status() != WL_CONNECTED) {
106     delay(500);
107     Serial.print(".");
108   }
109
110   Serial.println("");
111   Serial.println("WiFi conectado");
112   Serial.println("Endereço IP: ");
113   Serial.println(WiFi.localIP());
114 }
115
116 void callback(char* topic, byte* payload, unsigned int length) {
117   // Função para tratar mensagens recebidas (não implementada neste código)
118 }
119
120 void reconnect() {
121   // Reconecta ao servidor MQTT se a conexão for perdida
122   while (!client.connected()) {
123     Serial.print("Tentando se reconectar ao servidor MQTT...");
124     if (client.connect(clientId)) {
125       Serial.println("Conectado");
126     } else {
127       Serial.print("Falha na conexão, rc=");
128       Serial.print(client.state());
129       Serial.println(" Tentando novamente em 5 segundos");
130       delay(5000);
131     }
132   }
133 }
```

Figura 29 – Funções responsáveis pela conexão à rede Wi-Fi e pelo gerenciamento da comunicação com o servidor MQTT.

```
135 float calculateSMA(float *values, int numValues) {
136   // Calcula a média móvel simples (SMA) dos valores
137   float sum = 0;
138   for (int i = 0; i < numValues; i++) {
139     sum += values[i];
140   }
141   return sum / numValues;
142 }
143
144 void setup() {
145   Serial.begin(115200); // Inicia comunicação serial com baud rate 115200
146   setup_wifi();         // Conecta ao WiFi
147   client.setServer(mqttServer, port);
148   client.setCallback(callback);
149
150   // Configura ID do cliente MQTT baseado no MAC address
151   stMac = WiFi.macAddress();
152   stMac.toCharArray(mac, 50);
153   sprintf(clientId, "ESP32Client-%s", mac);
154
155   // Inicializa o display OLED
156   display.begin(SSD1306_SWITCHCAPVCC, 0x3C);
157   display.display();
158   delay(3000);
159
160   // Inicializa o sensor MAX30105
161   if (!particleSensor.begin(Wire, I2C_SPEED_FAST)) {
162     Serial.println("Não foi possível encontrar o MAX30102");
163     while (1); // Loop infinito se o sensor não for encontrado
164   }
165
166   // Configura parâmetros do sensor MAX30105
167   byte ledBrightness = 0x7F; // Intensidade do LED (127 em decimal)
168   byte sampleAverage = 4;     // Número de amostras para média
169   byte ledMode = 2;          // Modo de operação (RED + IR)
170   int sampleRate = 800;       // Taxa de amostragem em Hz
171   int pulseWidth = 215;       // Largura de pulso em microsegundos
172   int adcRange = 16384;       // Faixa do ADC
173   particleSensor.setup(ledBrightness, sampleAverage, ledMode, sampleRate, pulseWidth, adcRange);
174   particleSensor.enableDIETEMPRDY(); // Habilita leitura de temperatura
175
176   // Configura intensidade dos LEDs
177   particleSensor.setPulseAmplitudeRed(0x0A); // Vermelho com intensidade baixa
178   particleSensor.setPulseAmplitudeGreen(0);  // LED verde desligado
179 }
```

Figura 30 – Implementação da função média móvel simples e Função setup que inicializa todos os componentes de hardware e software do dispositivo.

```
void loop() {
  // Verifica e mantém conexão MQTT
  if (!client.connected()) {
    reconnect();
  }
  client.loop();

  // Leitura e processamento do sensor GSR
  float sensorValue = analogRead(sensorPin); // Lê valor bruto do GSR
  sensorBuffer[bufferIndex] = sensorValue;   // Armazena no buffer
  bufferIndex = (bufferIndex + 1) % bufferSize; // Atualiza índice circular

  // Cálculo de condutância e resistência da pele
  float smaValue = calculateSMA(sensorBuffer, bufferSize); // Média móvel
  float voltage = smaValue * (3.3 / 4095); // Converte para tensão (0-3.3V)
  float conductance = 1000 / voltage;      // Calcula condutância (µS)
  float resistance = voltage / (0.001 * conductance); // Calcula resistência (kΩ)

  // Exibe valores no monitor serial
  Serial.print("Valor Sensor GSR: " + String(sensorValue));
  Serial.print("condutância: " + String(conductance));

  // Leitura do sensor PPG (MAX30105)
  long irValue = particleSensor.getIR(); // Lê valor IR para detectar dedo

  if (irValue > FINGER_ON ) { // Se dedo está no sensor
    if (checkForBeat(irValue) == true) { // Detecta batimento cardíaco
      long delta = millis() - lastBeat;  // Calcula intervalo entre batimentos
      lastBeat = millis();               // Atualiza tempo do último batimento
      beatsPerMinute = 60 / (delta / 1000.0); // Calcula BPM

      if (beatsPerMinute < 255 && beatsPerMinute > 20) { // Filtra valores inválidos
        rates[rateSpot++] = (byte)beatsPerMinute; // Armazena no array
        rateSpot %= RATE_SIZE;                    // Índice circular
        beatAvg = 0;                              // Calcula média
        for (byte x = 0 ; x < RATE_SIZE ; x++) beatAvg += rates[x];
        beatAvg /= RATE_SIZE;
      }

      // Atualiza display OLED
      display.clearDisplay();
      display.drawBitmap(0, 0, logo3_bmp, 21, 21, WHITE); // Ícone de coração
      display.setTextSize(2);
      display.setTextColor(WHITE);
```

Figura 31 – Parte inicial do loop principal, focada na leitura do GSR, detecção de batimentos, cálculo de BPM e atualização visual no display OLED.

```
      // Exibe BPM
      display.setCursor(30, 0);
      display.print(beatAvg);
      display.println(" BPM");

      // Exibe SpO2
      display.drawBitmap(0, 22, O2_bmp, 21, 21, WHITE); // Ícone SpO2
      display.setCursor(30, 22);
      if (beatAvg > 30) display.print(String(ESpO2) + "%");
      else display.print("---- %" );

      // Exibe GSR
      display.drawBitmap(0, 42, gsr_sensor, 21, 21, WHITE); // Ícone GSR
      display.setCursor(30, 42);
      display.print(conductance); // Valor de condutância
      display.print(" uS");       // Unidade (microsiemens)

      display.display(); // Atualiza display
    }

    // Cálculo de SpO2
    uint32_t ir, red;
    double fred, fir;
    particleSensor.check(); // Verifica novos dados no sensor

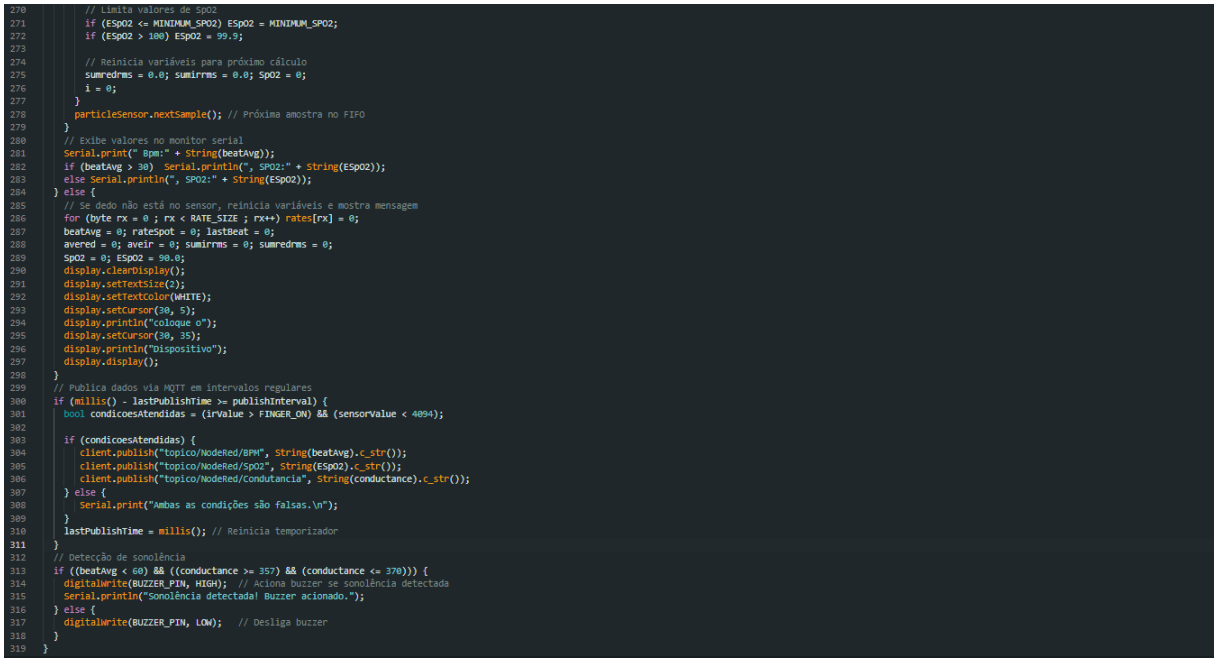
    if (particleSensor.available()) {
      i++;
      ir = particleSensor.getFIFOIR();  // Lê valor IR do buffer FIFO
      red = particleSensor.getFIFORed(); // Lê valor RED do buffer FIFO
      fir = (double)ir;
      fred = (double)red;

      // Filtro passa-baixa para os sinais
      aveir = aveir * frate + (double)ir * (1.0 - frate);
      avered = avered * frate + (double)red * (1.0 - frate);

      // Cálculo RMS para razão R
      sumirrms += (fir - aveir) * (fir - aveir);
      sumredrms += (fred - avered) * (fred - avered);

      if ((i % Num) == 0) { // A cada Num amostras, calcula SpO2
        double R = (sqrt(sumirrms) / aveir) / (sqrt(sumredrms) / avered);
        SpO2 = -23.3 * (R - 0.4) + 120; // Fórmula empírica para SpO2
        ESpO2 = FSpO2 * ESpO2 + (1.0 - FSpO2) * SpO2; // Filtro de estimativa
```

Figura 32 – Continuação do loop - Algoritmo de cálculo de SpO2 e tratamento de ausência de leitura.



```
        // Limita valores de SpO2
        if (ESpO2 <= MINIMUM_SPO2) ESpO2 = MINIMUM_SPO2;
        if (ESpO2 > 100) ESpO2 = 99.9;

        // Reinicia variáveis para próximo cálculo
        sumredrms = 0.0; sumirrms = 0.0; SpO2 = 0;
        i = 0;
       }
       particleSensor.nextSample(); // Próxima amostra no FIFO
     }
     // Exibe valores no monitor serial
     Serial.print(" Bpm:" + String(beatAvg));
     if (beatAvg > 30)  Serial.println(", SPO2:" + String(ESpO2));
     else Serial.println(", SPO2:" + String(ESpO2));
   } else {
     // Se dedo não está no sensor, reinicia variáveis e mostra mensagem
     for (byte rx = 0 ; rx < RATE_SIZE ; rx++) rates[rx] = 0;
     beatAvg = 0; rateSpot = 0; lastBeat = 0;
     avered = 0; aveir = 0; sumirrms = 0; sumredrms = 0;
     SpO2 = 0; ESpO2 = 90.0;
     display.clearDisplay();
     display.setTextSize(2);
     display.setTextColor(WHITE);
     display.setCursor(30, 5);
     display.println("coloque o");
     display.setCursor(30, 35);
     display.println("Dispositivo");
     display.display();
   }
   // Publica dados via MQTT em intervalos regulares
   if (millis() - lastPublishTime >= publishInterval) {
     bool condicoesAtendidas = (irValue > FINGER_ON) && (sensorValue < 4094);

     if (condicoesAtendidas) {
       client.publish("topico/NodeRed/BPM", String(beatAvg).c_str());
       client.publish("topico/NodeRed/SpO2", String(ESpO2).c_str());
       client.publish("topico/NodeRed/Condutancia", String(conductance).c_str());
     } else {
       Serial.print("Ambas as condições são falsas.\n");
     }
     lastPublishTime = millis(); // Reinicia temporizador
   }
   // Detecção de sonolência
   if ((beatAvg < 60) && ((conductance >= 357) && (conductance <= 370))) {
     digitalWrite(BUZZER_PIN, HIGH);  // Aciona buzzer se sonolência detectada
     Serial.println("Sonolência detectada! Buzzer acionado.");
   } else {
     digitalWrite(BUZZER_PIN, LOW);   // Desliga buzzer
   }
 }
```

Figura 33 – Trecho final do loop principal, responsável por Publicação de dados via MQTT e lógica de alerta de sonolência.

APÊNDICE B – Disponibilidade de Dados e Código-Fonte

Com o objetivo de promover a transparência, a reprodutibilidade e o avanço da pesquisa na área, o código-fonte desenvolvido para o microcontrolador ESP32, os arquivos de configuração do Node-RED e o conjunto de dados fisiológicos coletados durante os experimentos descritos neste trabalho estão disponíveis no Google Drive aqui.

Os materiais podem ser acessados no Google Drive:

Localização:
https://drive.google.com/drive/folders/1vjONn1eJzRZn6UqJ5KQjIIAps7r7L7At?usp=sharing

Conteúdo do Google Drive:

- **Código-fonte do ESP32:** Firmware completo (.ino) com as bibliotecas necessárias para a aquisição e processamento dos sinais dos sensores PPG (MAX30102) e GSR, controle do display OLED e comunicação MQTT.
- **Dados Experimentais:** Conjunto de dados anonimizados em formato CSV, contendo as leituras de frequência cardíaca (BPM), saturação de oxigênio (SpO2) e condutância da pele (GSR) para os estados de vigília e sonolência.
- **Configuração Node-RED:** Arquivo JSON contendo o fluxo (flow) do dashboard utilizado para a visualização dos dados em tempo real.

O material é disponibilizado sob a licença MIT, que permite o uso, a cópia, a modificação e a distribuição, com a devida atribuição ao trabalho original.