



Universidade Federal do ABC
Centro de Engenharia, Modelagem & Ciências Sociais Aplicadas
Engenharia de Instrumentação, Automação e Robótica

Sistema de Treinamento para RCP com Realidade Virtual

Alexandre Lemes Santos

Santo André - SP, Junho de 2026

Alexandre Lemes Santos

Sistema de Treinamento para RCP com Realidade Virtual

Projeto de Graduação em Engenharia IAR apresentado como parte dos requisitos necessários para a obtenção do Título de Engenheiro de Controle e Automação

Universidade Federal do ABC – UFABC

Centro de Engenharia, Modelagem & Ciências Sociais Aplicadas

Engenharia de Instrumentação, Automação e Robótica

Orientador: Dr. Filipe Ieda Fazanaro

Coorientador: Dr. Mario Alexandre Gazziro

Santo André - SP

Junho de 2026

Dedico a todos aqueles que, de alguma forma, contribuíram de forma direta ou indireta para a realização deste trabalho, meu sinceros agradecimentos. Cada um teve um papel importante nesta conquista. .

Agradecimentos

Aos meus amigos, Danilo, Gabriel e João Vitor, que compartilharam comigo os desafios e o sucesso, servindo de inspiração e oferecendo apoio, incentivo e companheirismo ao longo dessa jornada.

À minha família, que sempre esteve ao meu lado, oferecendo amor, suporte e compreensão. Aos meus pais, pelo incentivo incondicional, pelos ensinamentos e por acreditarem em mim em todos os momentos

"Viva de tal maneira que você deseje a eternidade daquele instante"

Friedrich Nietzsche

Resumo

A ressuscitação cardiopulmonar (RCP) é uma intervenção de emergência vital em casos de parada cardíaca súbita, consistindo em um conjunto de manobras que incluem compressão torácica que visam manter a circulação sanguínea e a oxigenação dos órgãos vitais. Este projeto descreve a criação e a validação de um sistema embarcado acessível projetado para monitorar a eficácia de tais manobras. O objetivo principal é oferecer uma alternativa de baixo custo capaz de substituir equipamentos comerciais de alto valor financeiro, como o sistema de realidade virtual HTC-VIVE. Para isso, o dispositivo proposto utiliza um sensor inercial integrado a um microcomputador Raspberry Pi, permitindo medir a frequência das compressões torácicas e fornecer dados para que o socorrista possa corrigir o movimento, aumentando a efetividade da reanimação. Os testes práticos revelaram uma correlação de 97% entre as medições do protótipo e o padrão-ouro de mercado. Dessa forma, o estudo conclui que essa tecnologia simplificada é viável e eficaz para democratizar o acesso ao treinamento de RCP com alta qualidade.

Palavras-chaves: RCP, Sistema Inercial, Sistemas Embarcados, Realidade Virtual.

Abstract

Cardiopulmonary resuscitation (CPR) is a vital emergency intervention for sudden cardiac arrest, consisting of a set of maneuvers—including chest compressions—aimed at maintaining blood circulation and oxygenation to vital organs. This project describes the development and validation of an affordable embedded system designed to monitor the effectiveness of such maneuvers. The primary objective is to offer a low-cost alternative capable of replacing high-end commercial equipment, such as the HTC-VIVE virtual reality system. To this end, the proposed device utilizes an inertial sensor integrated with a Raspberry Pi microcomputer, measuring chest compression frequency and providing feedback for rescuers to correct their technique, thereby increasing resuscitation efficacy. Practical tests revealed a 97% correlation between the prototype's measurements and the market gold standard. Thus, the study concludes that this simplified technology is viable and effective in democratizing access to high-quality CPR training.

Keywords: CPR, Inertial System, Embedded Systems, Virtual Reality.

Lista de ilustrações

Figura 1 – Conexão entre módulo do sensor e o sistema embarcado.	9
Figura 2 – Sistema proposto para co-registro entre os sistemas embarcado e realidade virtual. Fonte: Imagem gerada por inteligência artificial (NANO BANANA2), 2026.	12
Figura 3 – Coleta de dados com co-registro na Sessão A, em 2 etapas, com destaque para o sistema comercial VR-CPR sendo executado no terminal ao lado direito da foto.	13
Figura 4 – Coleta de dados com co-registro na Sessão B, em 2 etapas, com destaque para o sistema embarcado construído com Raspberry Pi Zero 2W na parte inferior da foto.	13
Figura 5 – Módulo de unidade inercial utilizado no sistema embarcado, modelo MPU6050.	14
Figura 6 – Captura de tela do Software comercial modelo VR-CPR, apresentando o valor instantâneo da taxa de batimento cardíaco além do relógio do sistema PC, para sincronização com o relógio do sistema Linux no Raspberry PI para correlação posterior.	14
Figura 7 – Aceleração (azul) e resultado da detecção das compressões (pontos vermelhos) em função da massagem cardíaca realizada na Sessão A, Etapa 1.	15
Figura 8 – Aceleração (azul) e resultado da detecção das compressões (pontos vermelhos) em função da massagem cardíaca realizada na Sessão A, Etapa 2.	16
Figura 9 – Aceleração (azul) e resultado da detecção das compressões (pontos vermelhos) em função da massagem cardíaca realizada na Sessão B, Etapa 1.	16
Figura 10 – Aceleração (azul) e resultado da detecção das compressões (pontos vermelhos) em função da massagem cardíaca realizada na Sessão B, Etapa 2.	17

Sumário

1	INTRODUÇÃO	1
1.1	Objetivos	2
1.2	Justificativa	2
2	FUNDAMENTAÇÃO TEÓRICA	4
2.1	Ressuscitação Cardiopulmonar	4
2.2	Realidade Virtual	5
2.3	Sistemas de Realidade Virtual aplicados para RCP	5
2.4	Processamentos dos Dados	6
2.4.1	Modelo do Sinal e Baixa Relação Sinal-Ruído (SNR)	7
2.4.2	Variabilidade Morfológica e a Ambiguidade dos Máximos Locais	7
2.4.3	Distorção de Fase em Filtros Causais	8
2.4.4	Abordagens Matemáticas Avançadas	8
3	METODOLOGIA	9
3.1	Plataforma de Desenvolvimento	9
3.1.1	Raspberry Pi e Sistemas Embarcados	9
3.1.2	Sensor de Movimento	10
3.1.3	MicroPython para Aplicações Embarcadas	10
3.2	Escolha do Sensor Inercial: Praticidade, Custo-Benefício e Eficiência no Treinamento	11
3.3	Coleta de dados e Co-registro	11
4	RESULTADOS E DISCUSSÕES	15
5	CONCLUSÕES	19
	REFERÊNCIAS	20
	APÊNDICES	22
	APÊNDICE A – SOFTWARE DE COLETA DE DADOS INERCIAIS NO RASPBERRY	23
	APÊNDICE B – SOFTWARE DE PROCESSAMENTO DOS DADOS NO COMPUTADOR	25

APÊNDICE C – REGULAMENTAÇÃO E REFERENCIAÇÃO DE IMAGENS TÉCNICAS GERADAS POR INTELIGÊNCIA ARTIFICIAL	28
--	-----------

1 Introdução

A parada cardiorrespiratória (PCR) é uma condição crítica que interrompe abruptamente o fluxo de sangue e oxigênio para os órgãos vitais, causando danos cerebrais em poucos segundos e a morte celular em minutos ([International Liaison Committee on Resuscitation, 2021](#)). O impacto dessa condição na saúde pública é global e severo, sendo que a sobrevivência à alta hospitalar, em muitas regiões, gira em torno de apenas 8%.

Nesse cenário de emergência, a eficácia dos procedimentos de salvamento depende criticamente da instrução técnica e da atuação rápida tanto de profissionais da saúde quanto de socorristas não profissionais. Iniciar prontamente a ressuscitação cardiopulmonar (RCP) é o fator mais determinante para aumentar as chances de sobrevivência e reduzir sequelas neurológicas.

Para que a intervenção seja efetiva, não basta apenas executá-la; é imprescindível garantir a alta qualidade das compressões torácicas. A circulação mínima eficaz exige uma frequência rigorosa de 100 a 120 compressões por minuto (CPM) ([BERNOCHÉ et al., 2019](#)). Além da frequência, a profundidade é essencial: as diretrizes recomendam comprimir aproximadamente 5 centímetros, evitando compressões excessivas que ultrapassem 6 centímetros em adultos médios.

Desvios dessa faixa são prejudiciais: frequências abaixo de 100 CPM falham na oxigenação dos tecidos, enquanto taxas superiores a 120 CPM comprometem o retorno do sangue ao coração e sua consequente perfusão ([SUTTON, 2025](#)). Além da profundidade e da frequência, a biomecânica de uma RCP de alta qualidade exige o retorno completo do tórax após cada compressão (evitando apoiar o peso sobre o paciente) e a minimização máxima das interrupções. Alcançar e manter essa precisão motora sob pressão exige muito mais do que conhecimento teórico.

A literatura médica aponta que as habilidades práticas de suporte básico de vida decaem rapidamente, com evidências claras de perda de proficiência ocorrendo entre 3 a 12 meses após o treinamento inicial. Essa rápida degradação da memória motora torna a recapacitação periódica uma necessidade urgente. Para otimizar essa capacitação e garantir a correta biomecânica da técnica, as diretrizes atuais sugerem fortemente o uso de dispositivos que forneçam feedback diretivo e em tempo real sobre a taxa de compressão, profundidade, liberação do tórax e posição das mãos durante o treinamento ([PERKINS et al., 2021](#)).

Nos últimos anos, a educação em saúde tem se apoiado em inovações tecnológicas para superar as barreiras do ensino tradicional. O aprendizado gamificado, que inclui a realidade virtual (VR) e a realidade aumentada, tem se mostrado uma ferramenta

promissora e capaz de engajar fortemente os alunos. Softwares comerciais de VR, operados com hardwares de ponta como o HTC-VIVE, consolidaram-se como o padrão-ouro de alta fidelidade para o treinamento médico. Esses sistemas imersivos inserem o operador em cenários altamente realistas e capturam as métricas espaciais da RCP com extrema exatidão, fornecendo o feedback imediato necessário para a correção da postura e da força.

O grande obstáculo, contudo, é que o alto custo de aquisição e manutenção de simuladores de VR de alta fidelidade restringe severamente sua adoção em larga escala por universidades e centros de formação, elitizando o acesso ao treinamento de excelência. Embora o uso de simuladores de alta fidelidade seja a recomendação ideal quando há infraestrutura e recursos disponíveis, as diretrizes internacionais de ressuscitação reconhecem que alternativas de menor fidelidade e de menor custo são aceitáveis e necessárias para o treinamento em ambientes com restrições financeiras. Sendo a educação prática fundamental para encorajar a prontidão em salvar vidas, surge a imperativa necessidade de investigar e desenvolver sistemas de treinamento que equilibrem a captura precisa de parâmetros biomecânicos com a acessibilidade e o baixo custo, permitindo, assim, a democratização do ensino de RCP de alta qualidade.

1.1 Objetivos

Desenvolver um dispositivo eletrônico de baixo custo, baseado em sistema inercial, e validar sua qualidade de medição por meio do co-registro de dados com o sistema de realidade virtual HTC-VIVE (operando o software comercial VR-CPR). Dessa forma, buscase demonstrar a equivalência entre as tecnologias e democratizar o acesso a ferramentas objetivas de avaliação para o treinamento em RCP.

1.2 Justificativa

Diante das barreiras financeiras impostas pelos simuladores de alta fidelidade, justifica-se a urgente necessidade de desenvolver alternativas tecnológicas que aliem praticidade, baixo custo e eficácia comprovada. O emprego de sensores inerciais (IMUs) combinados com plataformas de prototipagem acessíveis, como a família de microcomputadores Raspberry Pi, tem demonstrado grande potencial na instrumentação de baixo custo. Ao contrário de sistemas complexos que exigem ambientes controlados, o monitoramento vestível em luvas permite transformar qualquer manequim de treinamento básico em uma estação de avaliação de desempenho.

A principal relevância deste trabalho, portanto, reside na validação científica rigorosa dessa alternativa de baixo custo. Ao promover o co-registro simultâneo entre o sistema embarcado acessível e o equipamento comercial de referência em VR, o projeto preenche a

lacuna existente entre a viabilidade econômica e a precisão laboratorial exigida na área médica. Comprova-se, assim, que é possível democratizar o acesso a ferramentas objetivas de feedback contínuo, potencializando a capacitação de excelência em Suporte Básico de Vida e contribuindo para um impacto social direto no atendimento de emergências cardiovasculares

2 Fundamentação Teórica

2.1 Ressuscitação Cardiopulmonar

A Ressuscitação Cardiopulmonar (RCP) é um conjunto de intervenções sequenciais realizadas com o objetivo de restaurar e manter artificialmente a perfusão dos tecidos (fluxo sanguíneo) durante uma Parada Cardiorrespiratória (PCR) (PANCHAL et al., 2020).

A PCR é um evento onde há uma interrupção súbita da atividade mecânica do coração, levando à ausência de fluxo de sangue, perda de consciência e falta de respiração normal. Nesse cenário, o foco da RCP é mitigar o dano sistêmico causado pela falta de oxigenação (isquemia) e preservar as funções do cérebro (neurológica) e do coração (miocárdio) até que a pessoa recupere a circulação de forma espontânea (PANCHAL et al., 2020). Como a RCP manual consegue gerar apenas cerca de 10% a 30% do débito cardíaco normal, o rigor técnico na execução é essencial para que ela seja considerada de alta qualidade e realmente aumente as chances de sobrevivência (PANCHAL et al., 2020; BERNOCHE et al., 2019). Seus principais fundamentos incluem:

- Sequência C-A-B: As manobras devem ser iniciadas diretamente pelas compressões torácicas (C), seguidas pela abertura de vias aéreas (A) e ventilação (B). Isso ocorre porque, logo após o colapso, o sangue do paciente ainda possui um bom nível de oxigênio, e atrasar as compressões prejudicaria a irrigação sanguínea do cérebro e do coração, que são os fatores mais críticos para a sobrevivência (TRAVERS et al., 2010).
- Métricas de compressão: Devem ser aplicadas de 100 a 120 compressões por minuto, com uma profundidade entre 5 cm e 6 cm no tórax do adulto. É fundamental permitir que o tórax retorne totalmente à sua posição original após cada compressão, pois isso garante que o coração se encha de sangue novamente (MERCHANT et al., 2020).
- Minimização de pausas: As interrupções (como para a troca de socorristas ou ventilação) devem durar no máximo 10 segundos. Socorristas treinados aplicam uma relação de 30 compressões para 2 ventilações, enquanto leigos sem treinamento são aconselhados a fazer apenas compressões contínuas (Hands-Only CPR), o que também possui alta taxa de eficácia (MERCHANT et al., 2020).
- Desfibrilação Precoce: A rápida integração do Desfibrilador Externo Automático (DEA) junto com as compressões é vital, pois a desfibrilação elétrica é o único tratamento eficaz contra as causas mais comuns de paradas súbitas em adultos (Fibrilação Ventricular e Taquicardia Ventricular sem Pulso) (PANCHAL et al., 2020).

2.2 Realidade Virtual

A Realidade Virtual (RV) é uma interface avançada de usuário que representa uma quebra de paradigma na interação homem-computador, deixando para trás a visualização passiva em telas bidimensionais para inserir o usuário diretamente dentro de um ambiente digital. Ela combina computação gráfica de alto desempenho, dispositivos de exibição e sensores para criar cenários tridimensionais alternativos que respondem em tempo real às ações biológicas do usuário (KIRNER, 2007).

Ao contrário da Realidade Aumentada (RA), que apenas adiciona elementos digitais ao mundo físico, a RV isola completamente o usuário do ambiente real, transportando-o para uma simulação 100% digital.

Para que um sistema seja considerado tecnicamente como Realidade Virtual, ele deve apresentar três propriedades fundamentais, conhecidas como a Tríade da RV:

- **Imersão:** É o sentimento psicológico de "estar lá" no ambiente simulado, obtido pelo isolamento dos estímulos do mundo real (visão, audição e tato) e pela sua substituição por estímulos digitais.
- **Interação:** É a capacidade do sistema de rastrear as ações do usuário (como andar ou mover as mãos e a cabeça) e gerar reações imediatas dentro do cenário virtual.
- **Imaginação:** Refere-se à capacidade de gerar mundos virtuais que convençam o cérebro do usuário de que aquele ambiente e suas regras físicas são reais e coerentes.

Em resumo, a Realidade Virtual transforma dados digitais em experiências tangíveis, sendo considerada a evolução definitiva das interfaces computacionais humanas

2.3 Sistemas de Realidade Virtual aplicados para RCP

A literatura recente tem explorado diversas metodologias voltadas ao fornecimento de dados para a avaliação da qualidade da RCP, buscando, sobretudo, reduzir os custos associados ao treinamento médico. De maneira geral, as abordagens vigentes na comunidade científica podem ser agrupadas em dois eixos principais:

- **Sistemas de Realidade Virtual no Treinamento Médico:** Investigações no campo da Realidade Virtual (VR) aplicada à saúde analisam o impacto do treinamento imersivo na retenção de habilidades motoras da RCP. Em uma ampla revisão sistemática, (ARTERO et al., 2023) corroboram a eficiência do uso da VR para o treinamento de manobras de reanimação, destacando o potencial desses sistemas para simular cenários de alta fidelidade e fornecer métricas objetivas de desempenho.

O rastreamento cinemático fornecido por controladores comerciais — a exemplo dos joysticks do sistema HTC-VIVE — permite mensurar variáveis críticas, como a profundidade e a taxa de compressão torácica, para posterior análise. Contudo, apesar da excelência técnica e da precisão no registro dos dados, as pesquisas frequentemente apontam o elevado custo de aquisição do hardware e das licenças de software comercial como barreiras limitantes para a sua ampla adoção em larga escala.

- Avaliação de RCP via Sensores Inerciais: Como alternativa viável e de baixo custo, o uso de sensores inerciais acoplados ao socorrista ganhou forte tração científica. O trabalho referencial de (GONZÁLEZ-OTERO et al., 2014) demonstrou a viabilidade de aplicar acelerômetros para extrair parâmetros de qualidade das compressões torácicas. Os autores evidenciaram que o sinal bruto de aceleração frequentemente sofre com derivas de integração e artefatos de movimento (ruídos). Para contornar isso, técnicas baseadas no processamento digital de sinais e filtros de frequências — abordagem semelhante à desenvolvida neste projeto — provaram ser altamente eficazes. Filtros digitais específicos permitem isolar com precisão os picos espectrais correspondentes às compressões nos dados coletados, mitigando ruídos e alcançando taxas de erro mínimas na aferição da frequência das manobras executadas.

O diferencial do presente trabalho é estabelecer um co-registro direto e simultâneo entre o sistema padrão-ouro de VR (óculos e faróis beacon do fabricante HTC-VIVE em conjunto com o software VR-CPR da empresa <<https://vr-cpr.com>>) e o microcontrolador Raspberry Pi, preenchendo a lacuna entre a viabilidade econômica dos sensores inerciais vestíveis e a validação laboratorial rigorosa exigida por sistemas médicos comerciais.

Para aprofundar a fundamentação teórica, é essencial discutir a natureza complexa dos sinais inerciais capturados durante a manobra. Diferente do Eletrocardiograma (ECG), que possui picos elétricos bem definidos, os dados gerados pela movimentação mecânica da RCP impõem desafios matemáticos específicos. A aceleração aplicada pelo socorrista gera sinais sujeitos a ruídos de alta frequência, tremores por fadiga muscular e vibrações de impacto mecânico. Essas interferências distorcem a forma de onda e exigem estratégias de filtragem digital para o correto isolamento e contagem dos ciclos periódicos de compressão.

2.4 Processamentos dos Dados

Embora a extração da frequência das compressões torácicas a partir de sensores inerciais (IMU) apresente grande potencial, a natureza mecânica dos movimentos de compressão introduz complexidades matemáticas não triviais. O principal desafio algorítmico reside no fato de que os movimentos capturados não geram impulsos ideais, mas sim assinaturas vibracionais compostas que variam dinamicamente.

2.4.1 Modelo do Sinal e Baixa Relação Sinal-Ruído (SNR)

Do ponto de vista da modelagem matemática, o sinal inercial bruto $y(t)$ capturado no tórax não é puramente composto pelas compressões. Ele pode ser descrito como uma combinação linear e não linear de múltiplas fontes:

$$y(t) = x(t) + r(t) + m(t) + n(t) \quad (2.1)$$

Onde:

- $x(t)$ representa o movimento de compressões torácicas.
- $r(t)$ é a componente de baixa frequência originada pela respiração (geralmente < 0.5 Hz).
- $m(t)$ engloba os artefatos de movimento do paciente (ruído de espectro amplo e alta amplitude).
- $n(t)$ é o ruído branco inerente aos sensores inerciais e à eletrônica do sistema.

A limitação algorítmica fundamental da detecção de picos simples é que, durante a presença de artefatos de movimento, a amplitude de $m(t)$ pode ser ordens de grandeza superior à de $x(t)$, reduzindo drasticamente a Relação Sinal-Ruído (SNR) e gerando falsos positivos na identificação dos batimentos.

2.4.2 Variabilidade Morfológica e a Ambiguidade dos Máximos Locais

No processamento clássico, um pico (ou máximo local) em um sinal contínuo $f(t)$ ocorre em um ponto t_0 que satisfaz as seguintes condições no cálculo diferencial:

$$f'(t_0) = 0 \quad \text{e} \quad f''(t_0) < 0 \quad (2.2)$$

No entanto, um único ciclo de compressão torácica possui uma cascata de vibrações correspondentes a diferentes fatores externos ao movimento de RCP. Isso significa que, em um intervalo correspondente a uma única compressão, a equação acima será satisfeita múltiplas vezes, gerando vários picos locais competitivos.

Além disso, a amplitude do pico dominante (geralmente o ponto AO) sofre modulação de amplitude impulsionada pela variação na compressão e retorno torácico e pelo movimento respiratório. Uma heurística de limiar fixo falhará repetidamente, pois um pico secundário durante a expiração pode ter uma magnitude maior do que o pico primário durante a inspiração.

2.4.3 Distorção de Fase em Filtros Causais

Para isolar a componente correspondente ao movimento de compressões torácicas, a literatura comumente emprega filtros passa-banda (como o filtro de Butterworth de ordem N). No entanto, filtros com Resposta ao Impulso Infinita (IIR) introduzem um atraso de fase não linear que varia com a frequência.

2.4.4 Abordagens Matemáticas Avançadas

Para contornar as limitações da detecção baseada apenas em limiares de amplitude, métodos matemáticos mais robustos frequentemente substituem o sinal original $x(t)$ por uma envoltória de energia. Uma abordagem clássica para destacar as contrações ventriculares enquanto se atenua as vibrações secundárias é a aplicação da Energia de Shannon. Para um sinal discretizado e normalizado $x[n]$, a envoltória de energia de Shannon $E[n]$ é definida como:

$$E[n] = -x^2[n] \log(x^2[n]) \quad (2.3)$$

A transformação do sinal por meio dessa formulação logarítmica amplifica de forma não linear as amostras de alta energia (como os picos AO e MC) e suprime o ruído de fundo, simplificando substancialmente a topologia do sinal e permitindo que algoritmos de detecção baseados em tempo (time-distance thresholds) operem com taxas de precisão significativamente maiores, mesmo sob variação externas ao movimento.

3 Metodologia

3.1 Plataforma de Desenvolvimento

A escolha da plataforma de desenvolvimento para este projeto é um elemento crucial para sua viabilidade e eficiência. A solução foi concebida para ser executada em um microcontrolador da família Raspberry Pi, programado com a linguagem MicroPython, uma combinação que oferece um equilíbrio ideal entre poder de processamento, flexibilidade de programação e custo-benefício.



Figura 1 – Conexão entre módulo do sensor e o sistema embarcado.

3.1.1 Raspberry Pi e Sistemas Embarcados

O Raspberry Pi é uma plataforma de hardware amplamente reconhecida no meio acadêmico e de engenharia para o desenvolvimento de sistemas embarcados e projetos de Internet das Coisas (IoT) (JUCÁ; PEREIRA, 2018; GHAEEL et al., 2021). Embora modelos mais recentes da fundação, como o Raspberry Pi Pico, se enquadrem na categoria de microcontroladores de alto desempenho, a plataforma é valorizada por sua capacidade de oferecer um ambiente de desenvolvimento robusto (JUCÁ; PEREIRA, 2018). O Raspberry Pi tem sido aplicado com sucesso na prototipagem e validação de conceitos, como em sistemas de automação industrial, demonstrando sua eficácia para tarefas que demandam um controle preciso de hardware e comunicação com sensores.

3.1.2 Sensor de Movimento

Para coletar os dados do movimento executado durante a Ressuscitação Cardiopulmonar (RCP), o socorrista utilizará uma luva equipada com um sensor inercial (IMU). Este sensor é fundamental para capturar as características dinâmicas das compressões torácicas.

Nessa abordagem de utilizar um sensor inercial acoplado a uma luva oferece um equilíbrio ideal. Ela capitaliza a capacidade do IMU de monitorar a cinemática da RCP com alta precisão e custo acessível, ao mesmo tempo em que proporciona flexibilidade. Isso permite que qualquer luva seja transformada em um dispositivo de medição e que o sistema seja facilmente utilizado com diferentes tipos de bonecos de treinamento, sem a necessidade de adquirir equipamentos especializados e caros. Essa versatilidade é crucial para democratizar o acesso a um sistema de avaliação da qualidade na prática da RCP, tornando o treinamento mais eficaz e amplamente disponível.

3.1.3 MicroPython para Aplicações Embarcadas

MicroPython é uma implementação otimizada da linguagem Python 3 que tem ganhado destaque em sistemas embarcados com recursos limitados (GASPAR; FABO, 2020). A utilização de linguagens de alto nível como Python é documentada na literatura por suas vantagens no desenvolvimento de software, especialmente para a criação de protótipos e para a manutenção de código (MENEZES, 2024; SKJUTAR; ÅSTRAND, 2024).

A escolha do MicroPython para este projeto é justificada por diversas vantagens:

- **Produtividade e Facilidade de Programação:** A sintaxe clara e a vasta base de conhecimento de Python simplificam o desenvolvimento do código, reduzindo o tempo de implementação e a curva de aprendizado, o que é um fator crucial em projetos de engenharia.
- **Aplicações em IoT e Automação:** Artigos de congressos têm demonstrado a eficácia do MicroPython como uma plataforma de desenvolvimento para aplicações de IoT e automação (GASPAR; FABO, 2020), reforçando sua adequação para projetos que exigem a integração de sensores e o processamento de dados. A flexibilidade do MicroPython permite o acesso direto aos pinos de entrada e saída (GPIOs) e a interfaces de comunicação, funcionalidades essenciais para a interação com sensores inerciais e outros componentes do sistema.

3.2 Escolha do Sensor Inercial: Praticidade, Custo-Benefício e Eficiência no Treinamento

A escolha do sensor inercial para ser acoplado à luva foi motivada por suas vantagens significativas em relação a outras tecnologias para monitoramento da RCP, especialmente em um contexto de treinamento, onde a praticidade, o baixo custo e a não invasividade são cruciais. Sensores inerciais, que tipicamente incorporam acelerômetros e giroscópios, conseguem medir diretamente a aceleração e a orientação no espaço. Isso permite que capturem de forma eficaz os padrões de movimento da mão do socorrista, que se correlacionam diretamente com a frequência das compressões da RCP (AASE et al., 2002).

Em comparação com outras opções de sensores e suas aplicações, incluindo aquelas que também utilizam IMUs:

- **Sensores de Pressão:** Embora eficazes na medição direta da profundidade das compressões, exigem contato direto e aplicação de força no tórax do boneco de treinamento (KIM et al., 2017). Isso pode tornar a configuração mais complexa, potencialmente interferir no fluxo das compressões e, em alguns casos, exigir modificações mais substanciais nos bonecos de treinamento existentes.
- **Sistemas Ópticos (Câmeras e Marcadores):** Oferecem alta precisão, mas geralmente requerem um ambiente controlado, calibração complexa e uma linha de visão desobstruída para os marcadores ou para o boneco. Isso os torna menos práticos para uso em treinamentos em diversos locais ou para autoaprendizagem, além de apresentarem um custo de implementação significativamente mais alto (ARANA et al., 2024).
- **Sensores Inerciais Incorporados a Coletes ou Bonecos de Treinamento:** Existem, de fato, bonecos de treinamento e coletes específicos no mercado que já vêm com sensores inerciais integrados para fornecer feedback sobre a RCP. Embora sejam soluções completas e eficazes, a principal desvantagem reside no custo elevado de aquisição e na falta de flexibilidade. Tais sistemas geralmente exigem a compra de um boneco ou colete dedicado, limitando sua aplicação a instituições ou indivíduos que podem arcar com o investimento inicial. Além disso, a manutenção ou atualização desses sensores pode ser mais complexa.

3.3 Coleta de dados e Co-registro

A coleta de dados foi realizada por meio de uma abordagem de co-registro. O sensor inercial do sistema foi instalado na região dorsal da mão em uma luva utilizada pelo socorrista. O socorrista vestiu esta luva enquanto manipulava o controle original do

sistema de realidade virtual HTC-VIVE, realizando a manobra de RCP em um boneco de treinamento (Figura 2).




Figura 2 – Sistema proposto para co-registro entre os sistemas embarcado e realidade virtual.

Fonte: Imagem gerada por inteligência artificial (NANO BANANA2), 2026.

Esse setup garantiu que ambos os sistemas (o embarcado de baixo custo e o comercial) capturassem o mesmo movimento simultaneamente. Para que os registros dos dois sistemas ficassem sincronizados, os relógios de ambos foram ajustados com o mesmo horário.

O movimento de compressão costuma variar entre 48 e 180 compressões por minuto (CPM), ou seja, de 0,80 Hz a 3,00 Hz, sendo a faixa ideal entre 100 a 120 CPM (de 1,67 Hz a 2,00 Hz). Portanto, a metodologia desse trabalho consistiu nas etapas:

1. Carregar os dados e calcular a taxa de amostragem (quantas leituras por segundo).
2. Filtrar o sinal: Usar um filtro passa-banda (Bandpass Filter) entre 0.8 Hz (48 CPM) e 3.0 Hz (180 CPM) para remover os movimentos de respiração (que são mais lentos, < 0.5 Hz) e ruídos de alta frequência.
3. Detecção de picos: Encontrar os picos do sinal filtrado (que representam os batimentos).
4. Cálculo do CPM: Calcular a média de tempo entre esses picos e converter para CPM.
5. Comparação dos CPMs: Comparar as taxas de batimento entre o que foi aferido pelo sistema embarcado com os valores obtidos no sistema comercial de realidade virtual.

O Raspberry Pi Pico coletou telemetria contínua durante o exercício. Os logs de dados brutos incluem métricas de tempo, registro de hora e os eixos espaciais do acelerômetro e giroscópio, além da temperatura. Uma amostra contínua da leitura demonstra

a oscilação constante do acelerômetro, capturando as compressões torácicas durante 2 sessões de aquisição do experimento, chamadas a partir de agora de Sessão A e Sessão B.

As Figuras 3 e 4 representam fotos realizadas respectivamente nas Sessões A e B da coleta de dados com co-registro de ambos os sistemas. Cada sessão gerou tanto um vídeo correspondente da gravação da saída de tela do sistema comercial de realidade virtual, assim como dois arquivos de log do sistema embarcado para cada vídeo, visto que cada treinamento virtual se dividia em duas etapas distintas, doravante chamadas de ‘Etapa 1’ e ‘Etapa 2’.



Figura 3 – Coleta de dados com co-registro na Sessão A, em 2 etapas, com destaque para o sistema comercial VR-CPR sendo executado no terminal ao lado direito da foto.



Figura 4 – Coleta de dados com co-registro na Sessão B, em 2 etapas, com destaque para o sistema embarcado construído com Raspberry Pi Zero 2W na parte inferior da foto.

As Figuras 5 e 6 representam fotos respectivamente da unidade inercial utilizada acoplada ao microcontrolador do sistema embarcado (modelo MPU6050), assim como a tela principal do software de treinamento de RCP de realidade virtual, VR-CPR, apresentando o valor instantâneo da taxa de compressão torácica durante a massagem cardíaca, com apresentação do relógio do sistema para correlação posterior com o sistema embarcado.




Figura 5 – Módulo de unidade inercial utilizado no sistema embarcado, modelo MPU6050.




Figura 6 – Captura de tela do Software comercial modelo VR-CPR, apresentando o valor instantâneo da taxa de batimento cardíaco além do relógio do sistema PC, para sincronização com o relógio do sistema Linux no Raspberry PI para correlação posterior.

4 Resultados e Discussões

A aplicação do algoritmo de filtragem sobre os dados brutos gerou uma visualização clara dos ciclos de compressão. Os gráficos das Figuras 7 à 10 ilustram as curvas suavizadas das acelerações nos eixos combinados x, y e z (sinal azul) ao longo do tempo para as duas Sessões (A e B) e ambas suas etapas (1 e 2).

Os pontos vermelhos marcam com precisão os picos de aceleração que corresponde a cada compressão detectada pelo algoritmo. Visualmente, a distribuição dos pontos vermelhos no gráfico demonstra a regularidade e a frequência da massagem cardíaca executada pelo socorrista.

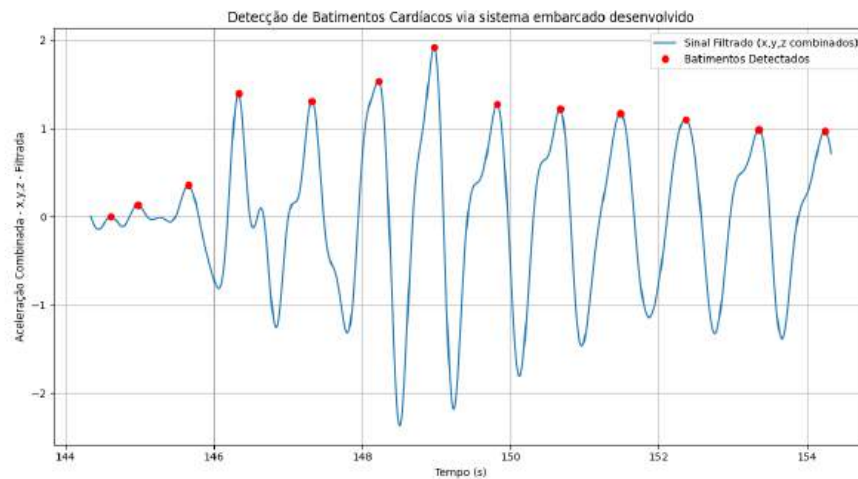


Figura 7 – Aceleração (azul) e resultado da detecção das compressões (pontos vermelhos) em função da massagem cardíaca realizada na Sessão A, Etapa 1.




Figura 8 – Aceleração (azul) e resultado da detecção das compressões (pontos vermelhos) em função da massagem cardíaca realizada na Sessão A, Etapa 2.

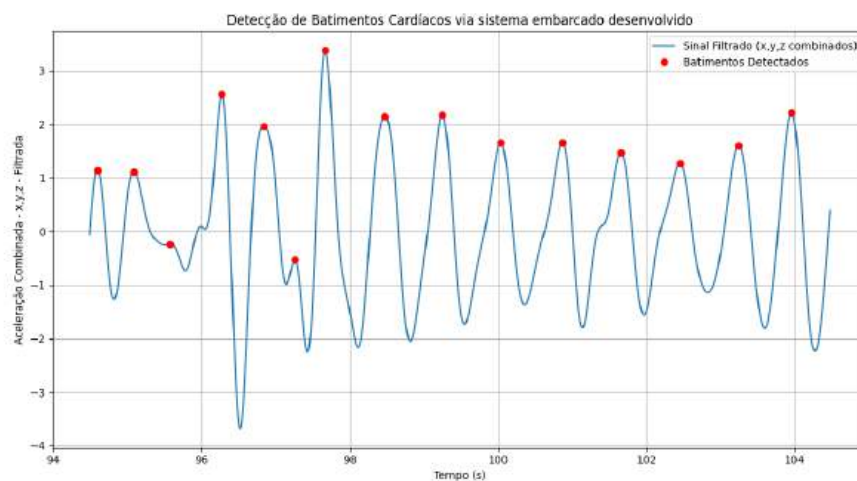


Figura 9 – Aceleração (azul) e resultado da detecção das compressões (pontos vermelhos) em função da massagem cardíaca realizada na Sessão B, Etapa 1.

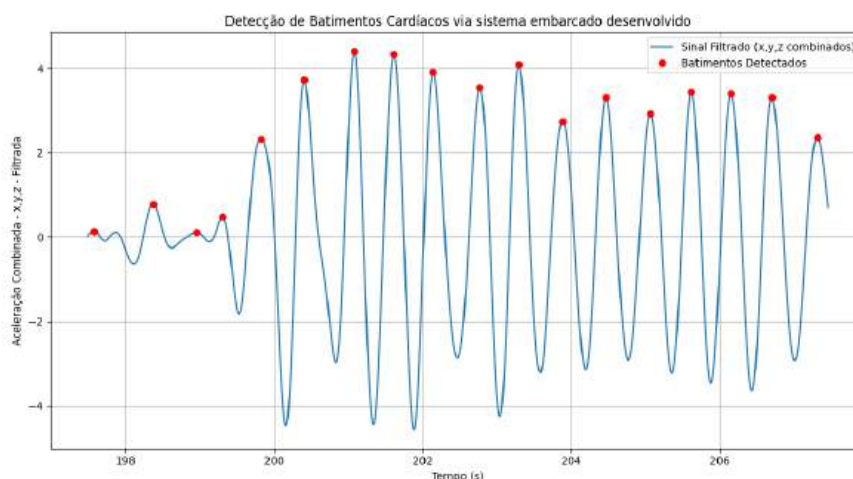


Figura 10 – Aceleração (azul) e resultado da detecção das compressões (pontos vermelhos) em função da massagem cardíaca realizada na Sessão B, Etapa 2.

Importante destacar que o resultado do sistema HTC-VIVE foi gravado em vídeo e atestou-se que a frequência visualizada e calculada pelo sistema embarcado é plenamente compatível com os dados do sistema comercial, conforme resultados na Tabela 1 de correlação entre os sistemas. A correlação de Pearson foi de 97%, comprovando a hipótese de que os sistemas são similares.

Tabela 1 – Comparação entre o CPM do Sistema Embarcado e de Realidade Virtual.

Sessão - Etapa	Sistema Embarcado	Realidade Virtual
Sessão A - Etapa 1	76,07 CPM	65,38 CPM
Sessão A - Etapa 2	74,99 CPM	65,44 CPM
Sessão B - Etapa 1	100,29 CPM	98,22 CPM
Sessão B - Etapa 2	104,33 CPM	101,75 CPM

A análise dos dados obtidos comprova a eficácia da abordagem proposta, revelando uma correlação de Pearson de 97% entre a frequência de compressões calculada pelo sistema embarcado de baixo custo e o sistema comercial de alta precisão (HTC-VIVE).

Esse nível de correlação evidencia que o sistema baseado no Raspberry Pi e sensor inercial (IMU) obteve sucesso em rastrear o padrão e a regularidade mecânica das compressões de forma plenamente compatível com o padrão-ouro.

Analisando especificamente os dados da Tabela 1, observa-se que na Sessão B os valores absolutos foram extremamente próximos entre as duas tecnologias, registrando, por exemplo, 100,29 CPM no sistema embarcado contra 98,22 CPM na Realidade Virtual, e 104,33 CPM contra 101,75 CPM, respectivamente.

No Sessão A, nota-se uma divergência maior nos valores exatos (aproximadamente 75-76 CPM no sistema embarcado versus 65 CPM no VR). No entanto, a correlação de

97% atesta que a variação cinemática da massagem cardíaca executada pelo socorrista foi acompanhada de maneira fidedigna pelo hardware acessível.

O sucesso na identificação dos picos valida a robustez do processamento digital de sinais escolhido para o projeto. Sensores inerciais vestíveis sofrem rotineiramente com a baixa Relação Sinal-Ruído (SNR) devido a artefatos de movimento do paciente e de respiração.

A aplicação do filtro passa-banda Butterworth (com frequências de corte de 0.8 Hz a 3.0 Hz) demonstrou ser perfeitamente capaz de isolar a frequência das compressões torácicas, removendo os ruídos indesejados.

Visualmente, a curva suavizada da aceleração nos eixos combinados (x, y, z) permitiu que o algoritmo marcasse com precisão os picos de cada compressão, comprovando a regularidade da massagem.

Dessa forma, os resultados alcançados atestam a hipótese central do estudo: é possível estabelecer um co-registro direto e simultâneo que preencha a lacuna entre a viabilidade econômica e o rigor exigido na área médica.

Fica demonstrado que a eletrônica embarcada de baixo custo pode fornecer métricas equivalentes às aquelas extraídas de sistemas de alto custo, democratizando o acesso a ferramentas objetivas de avaliação e feedback contínuo para o treinamento de Ressuscitação Cardiopulmonar (RCP).

5 Conclusões

Este estudo teve como objetivo central desenvolver e validar um sistema embarcado de baixo custo projetado para aferir a qualidade das compressões torácicas durante o treinamento de Ressuscitação Cardiopulmonar (RCP). O foco foi oferecer uma alternativa prática e econômica capaz de contornar a principal barreira das tecnologias de padrão-ouro atuais, como o sistema de Realidade Virtual HTC-VIVE: o seu alto custo de aquisição e manutenção, que restringe o acesso ao treinamento médico de excelência.

A solução tecnológica construída baseou-se em um microcomputador da família Raspberry Pi em conjunto com um sensor inercial (IMU) acoplado a uma luva. Essa escolha arquitetônica transformou movimentos mecânicos complexos em dados mensuráveis. O grande desafio associado aos sensores inerciais vestíveis — a baixa Relação Sinal-Ruído causada por artefatos de movimento e respiração — foi solucionado de forma eficaz pelo processamento digital de sinais. O uso de um filtro passa-banda Butterworth (com frequências de corte entre 0.8 Hz e 3.0 Hz) foi capaz de suprimir ruídos e isolar com precisão os picos correspondentes aos ciclos de compressão torácica.

Para atestar a confiabilidade clínica e laboratorial da ferramenta, o projeto empregou uma rigorosa metodologia de co-registro simultâneo, comparando o protótipo diretamente com o software comercial VR-CPR. A análise dos dados extraídos revelou uma correlação de Pearson de 97% entre as medições do sistema embarcado e o equipamento de alta fidelidade. Essa alta taxa de equivalência nas frequências computadas comprova que o hardware construído acompanhou fielmente a variação cinemática da massagem cardíaca.

Em suma, os resultados validam plenamente a hipótese da pesquisa. Conclui-se que o uso de componentes de hardware acessíveis, aliados a um algoritmo de processamento robusto, é capaz de substituir equipamentos comerciais de alto valor na avaliação de manobras de RCP. Essa tecnologia simplificada apresenta um elevado potencial de impacto social, democratizando o acesso a ferramentas objetivas de feedback contínuo e viabilizando a adoção em larga escala de treinamentos de alta qualidade em Suporte Básico de Vida por universidades e centros de formação

Referências

- AASE, S. O. et al. Compression depth estimation for cpr quality assessment using dsp on accelerometer signals. In: *Computers in Cardiology*. NIH Public Access, 2002. p. 397–400. Disponível em: <<https://doi.org/10.1109/10.983461>>. Citado na página 11.
- ARANA, C. et al. Inertial sensors for human motion analysis: A comprehensive review. *arXiv preprint arXiv:2401.12919*, 2024. Disponível em: <<https://doi.org/10.48550/arXiv.2401.12919>>. Citado na página 11.
- ARTERO, P. et al. Efficiency of virtual reality for cardiopulmonary resuscitation training of adult laypersons: A systematic review. *Medicine*, v. 102, p. e32736, 01 2023. Disponível em: <<https://doi.org/10.1097/MD.00000000000032736>>. Citado na página 5.
- BERNOCHE, C. et al. Atualização da diretriz de ressuscitação cardiopulmonar e cuidados cardiovasculares de emergência da sociedade brasileira de cardiologia – 2019. *Arquivos Brasileiros de Cardiologia*, Sociedade Brasileira de Cardiologia, v. 113, n. 3, p. 449–663, 2019. Disponível em: <<https://doi.org/10.5281/zenodo.20779051>>. Citado 2 vezes nas páginas 1 e 4.
- GASPAR, G.; FABO, P. Micropython as a development platform for IoT applications. In: *Advances in Intelligent Systems and Computing*. [S.l.]: Springer, 2020. v. 1120. ISBN 978-3-030-40617-5. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-030-51965-0_34>. Citado na página 10.
- GHAEL, H. D. et al. A review paper on Raspberry Pi and its applications. *International Journal of Advanced Engineering and Management*, v. 6, 2021. Disponível em: <<https://doi.org/10.5281/zenodo.20778593>>. Citado na página 9.
- GONZÁLEZ-OTERO, D. M. et al. A new method for feedback on the quality of chest compressions during cardiopulmonary resuscitation. *BioMed Research International*, v. 2014, n. 1, p. 865967, 2014. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1155/2014/865967>>. Citado na página 6.
- International Liaison Committee on Resuscitation. 2021 international consensus on cardiopulmonary resuscitation and emergency cardiovascular care science with treatment recommendations. *Circulation*, American Heart Association, v. 144, n. 24, p. e272–e394, 2021. Disponível em: <<https://doi.org/10.1161/CIR.0000000000001017>>. Citado na página 1.
- JUCÁ, S.; PEREIRA, R. *Aplicações Práticas de sistemas embarcados Linux utilizando Raspberry Pi*. [S.l.]: Pod Editora, 2018. ISBN 978-85-8225-212-3. Disponível em: <<https://doi.org/10.5281/zenodo.20778675>>. Citado na página 9.
- KIM, K.-R. et al. Novel chest compression depth measurement sensor using IR-UWB for improving quality of cardiopulmonary resuscitation. *Sensors*, MDPI, v. 17, n. 7, p. 1496, 2017. Disponível em: <<https://doi.org/10.3390/s17071496>>. Citado na página 11.
- KIRNER, C. *Realidade Virtual e Aumentada: Conceitos, Projeto e Aplicações*. [s.n.], 2007. Disponível em: <<https://doi.org/10.5281/zenodo.20779792>>. Citado na página 5.

- MENEZES, N. N. C. *Introdução à Programação com Python*. 4. ed. São Paulo: Novatec Editora, 2024. ISBN 978-85-7522-886-9. Citado na página 10.
- MERCHANT, R. M. et al. Part 1: Executive summary: 2020 american heart association guidelines for cardiopulmonary resuscitation and emergency cardiovascular care. *Circulation*, v. 142, n. 16_suppl_2, p. S337–S357, 2020. Disponível em: <<https://doi.org/10.1161/CIR.0000000000000918>>. Citado na página 4.
- PANCHAL, A. R. et al. Part 3: Adult basic and advanced life support: 2020 american heart association guidelines for cardiopulmonary resuscitation and emergency cardiovascular care. *Circulation*, v. 142, n. 16_suppl_2, p. S366–S468, 2020. Disponível em: <<https://doi.org/10.1161/CIR.0000000000000916>>. Citado na página 4.
- PERKINS, G. D. et al. European Resuscitation Council Guidelines 2021: Adult basic life support. *Resuscitation*, Elsevier, v. 161, p. 145–172, 2021. Disponível em: <<https://doi.org/10.1016/j.resuscitation.2021.02.003>>. Citado na página 1.
- SKJUTAR, F. A.; ÅSTRAND, M. *MicroPython Integration for Radar Specific Application: Is it worth it?* Dissertação (Master's Thesis) — Lund University, Lund, 2024. Disponível em: <<https://doi.org/10.5281/zenodo.20778953>>. Citado na página 10.
- SUTTON, R. M. Prearrest vital sign abnormalities are associated with adverse outcomes in pediatric icu cardiac arrest: a get with the guidelines-resuscitation analysis. *Resuscitation*, v. 216, p. 110846, 2025. ISSN 0300-9572. Disponível em: <<https://doi.org/10.1016/j.resuscitation.2025.110846>>. Citado na página 1.
- TRAVERS, A. H. et al. Part 4: Cpr overview. *Circulation*, v. 122, n. 18_suppl_3, p. S676–S684, 2010. Disponível em: <<https://doi.org/10.1161/CIRCULATIONAHA.110.970913>>. Citado na página 4.

Apêndices

APÊNDICE A – Software de Coleta de Dados Inerciais no Raspberry

```

1 import csv
2 import time
3 from datetime import datetime
4 from mpu6050 import mpu6050
5
6 # Inicializa o sensor (Certifique-se de que o Fast Mode 400kHz
   estã; ativo no boot)
7 sensor = mpu6050(0x68)
8
9 def coleta_post_processada():
10     nome_arquivo = "rcp_data_raw.csv"
11     # Lista para armazenar os dados na RAM
12     dados_memoria = []
13
14     print("--- SISTEMA DE CAPTURA RCP ---")
15     print("Aguardando ENTER para iniciar a captura...")
16     input()
17
18     start_time = time.time()
19     print("CAPTURANDO... Pressione Ctrl+C para PARAR e SALVAR.")
20
21     try:
22         while True:
23             # Leitura direta dos registros (Alta Velocidade)
24             t = time.time() - start_time
25             now = datetime.now()
26             agora = now.strftime("%H:%M:%S")
27             accel = sensor.get_accel_data()
28             gyro = sensor.get_gyro_data()
29             temp = sensor.get_temp()
30
31             # Armazena apenas os valores brutos na lista
32             dados_memoria.append([
33                 t,
34                 agora,

```

```
35         accel['x'], accel['y'], accel['z'],
36         gyro['x'], gyro['y'], gyro['z'],
37         temp
38     ])
39
40     # Sem time.sleep() e sem escrita em disco aqui
41
42 except KeyboardInterrupt:
43     print(f"\nCaptura interrompida. Total de amostras: {len(
44         dados_memoria)}")
45
46     # Agora sim, abrimos o arquivo e gravamos tudo de uma vez
47     print(f"Gravando dados em '{nome_arquivo}'... Por favor,
48         aguarde.")
49
50     try:
51         with open(nome_arquivo, mode='w', newline='') as
52             arquivo:
53                 escritor = csv.writer(arquivo)
54                 # Cabeçalho
55                 escritor.writerow(["t", "hora:min:seg", "ax", "ay",
56                     "az", "gx", "gy", "gz", "temp"])
57                 # Grava a lista completa
58                 escritor.writerows(dados_memoria)
59
60                 duracao = dados_memoria[-1][0] if dados_memoria else
61                     0
62                 taxa = len(dados_memoria) / duracao if duracao > 0
63                     else 0
64                 print(f"CONCLUÍDO! Taxa final atingida: {taxa:.2f} Hz
65                     ")
66
67     except Exception as e:
68         print(f"Erro ao salvar o arquivo: {e}")
69
70 if __name__ == "__main__":
71     coleta_post_processada()
```

APÊNDICE B – Software de Processamento dos Dados no Computador

```

1 import pandas as pd
2 import numpy as np
3 from scipy.signal import butter, filtfilt, find_peaks
4 import matplotlib.pyplot as plt
5
6 def calcular_frequencia_cardiaca(caminho_arquivo):
7     # 1. Carregar os dados
8     # Assumindo que as colunas são: t, hora_min_seg, ax, ay, az,
9     #     gx, gy, gz, temp
10    colunas = ['t', 'hora_min_seg', 'ax', 'ay', 'az', 'gx', 'gy',
11              'gz', 'temp']
12    df = pd.read_csv(caminho_arquivo, names=colunas, skiprows=1)
13    # skiprows=1 se houver cabeçalho
14
15    # 2. Calcular a Taxa de Amostragem (Fs - Frequência de
16    #     amostragem em Hz)
17    # A coluna 't' parece ser o tempo em segundos
18    tempo = df['t'].values
19    dt_medio = np.mean(np.diff(tempo))
20    fs = 1.0 / dt_medio
21    print(f"Taxa de amostragem estimada (Fs): {fs:.2f} Hz")
22
23    # 3. Escolher o sinal para análise
24    # Em sismocardiografia, o eixo Z (az) geralmente é
25    #     perpendicular ao peito e capta bem o batimento.
26    # Alternativamente, podemos usar a magnitude do vetor de
27    #     aceleração: sqrt(ax^2 + ay^2 + az^2)
28    sinal = df['az'].values
29
30    # Remove a média (tendência DC) do sinal
31    sinal = sinal - np.mean(sinal)
32
33    # 4. Filtragem Passa-Banda (Bandpass Filter)
34    # Frequência de corte inferior: 0.8 Hz (~48 BPM) para
35    #     remover respira o

```

```
29 # Frequência de corte superior: 3.0 Hz (~180 BPM) para
    # remover ruído de alta frequência
30 lowcut = 0.8
31 highcut = 3.0
32 nyquist = 0.5 * fs
33 low = lowcut / nyquist
34 high = highcut / nyquist
35
36 # Criação de um filtro Butterworth de ordem 4
37 b, a = butter(4, [low, high], btype='bandpass')
38 sinal_filtrado = filtfilt(b, a, sinal)
39
40 # 5. Detecção de Picos (Batimentos)
41 # O tempo mínimo entre os batimentos, assumindo um máximo
    # de 180 BPM (3 Hz) seria 1/3 = 0.33 segundos.
42 distancia_minima_amstras = int(0.33 * fs)
43
44 # Encontra os Índices dos picos no sinal filtrado
45 picos_indices, _ = find_peaks(sinal_filtrado, distance=
    distancia_minima_amstras)
46
47 if len(picos_indices) < 2:
48     print("Não foi possível detectar picos suficientes para
        calcular o BPM.")
49     return
50
51 # 6. Calcular a frequência cardíaca (BPM)
52 # Tempo correspondente a cada pico encontrado
53 tempo_picos = tempo[picos_indices]
54
55 # Diferença de tempo entre picos consecutivos (Intervalos RR
    # em segundos)
56 intervalos = np.diff(tempo_picos)
57
58 # Calcula a média do intervalo
59 intervalo_medio = np.mean(intervalos)
60
61 # Converte para Batimentos Por Minuto (BPM)
62 bpm = 60.0 / intervalo_medio
63 print(f"Frequência Cardíaca Estimada: {bpm:.2f} BPM")
64
65 # 7. (Opcional) Plotar os resultados para verificação
```

```
    visual
66     plt.figure(figsize=(12, 6))
67
68     # Vamos plotar apenas um trecho para facilitar a
        visualiza o (ex: primeiros 10 segundos)
69     limite = min(len(tempo), int(10 * fs))
70
71     plt.plot(tempo[:limite], sinal_filtrado[:limite], label='
        Sinal_Filtrado_(az)')
72
73     # Filtrar picos que est o dentro do limite do plot
74     picos_plot = [p for p in picos_indices if p < limite]
75     plt.plot(tempo[picos_plot], sinal_filtrado[picos_plot], "ro",
        label='Batimentos_Detectados')
76
77     plt.title("Detec o de Batimentos Cardiacos via
        Sismocardiografia")
78     plt.xlabel("Tempo (s)")
79     plt.ylabel("Acelera o Z Filtrada")
80     plt.legend()
81     plt.grid(True)
82     plt.show()
83
84 # Como usar:
85 # Substitua 'X.csv' pelo nome verdadeiro do seu arquivo.
86 calcular_frequencia_cardiaca('a.csv')
```

APÊNDICE C – Regulamentação e Referenciação de Imagens Técnicas Geradas por Inteligência Artificial

Regulamentação e Referenciação de Imagens Técnicas Geradas por Inteligência Artificial

Consolidação de Práticas baseadas nas Orientações Gerais da CAPES e Adaptações da ABNT

1. Introdução e Contextualização Normativa

O avanço acelerado das ferramentas de Inteligência Artificial (IA) Generativa trouxe profundas transformações para a produção científica global. No cenário brasileiro, a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), em estreita consonância com a Política de Integridade Científica do CNPq, preconiza que o uso dessas tecnologias deve ser pautado pela **transparência total, rastreabilidade e responsabilidade inalienável do pesquisador**.

É fundamental ressaltar que a CAPES não emite um manual autônomo de normas de formatação de texto; em vez disso, a agência adota formalmente os padrões estabelecidos pela Associação Brasileira de Normas Técnicas (ABNT). Portanto, para referenciar imagens técnicas (tais como diagramas estruturais, fluxogramas, esquemas conceituais ou modelagens visuais) geradas por algoritmos de IA, a comunidade acadêmica utiliza uma adaptação consolidada das normas existentes para documentos eletrônicos e softwares (notadamente a ABNT NBR 6023 e a ABNT NBR 14724).

2. Princípios Fundamentais de Integridade Acadêmica

Antes de proceder à inserção de qualquer elemento visual gerado por IA em dissertações, teses ou artigos científicos, o autor deve observar os seguintes preceitos éticos:

- **Responsabilidade Autoral Humana:** Ferramentas de IA não possuem personalidade jurídica ou intelectual e, por conseguinte, jamais podem ser listadas como coautoras de um trabalho científico. O pesquisador assume integral responsabilidade civil e acadêmica por eventuais imprecisões, alucinações técnicas ou infrações de direitos autorais cometidas pelo algoritmo.
- **Vedação à Fabricação de Dados:** É terminantemente proibido o emprego de IA generativa para falsificar, simular ou fabricar evidências empíricas primárias. Imagens como cromatografias, exames biomédicos reais, gráficos de resultados analíticos ou plotagens de dados experimentais devem derivar da pesquisa empírica, e não de comandos de texto (*prompts*). O uso de IA restringe-se a representações esquemáticas, conceituais ou ilustrativas.
- **Soberania Institucional:** Os regulamentos internos dos Programas de Pós-Graduação (PPGs) e as políticas editoriais de periódicos específicos possuem soberania. Caso a revista ou o programa proíba o uso de recursos gerados por IA, a norma local prevalece sobre qualquer recomendação de estilo.

3. Apresentação Gráfica no Corpo do Texto

Conforme a ABNT NBR 14724, qualquer ilustração deve ser identificada na parte superior por seu tipo, número de ordem de ocorrência no texto e respectivo título. Na parte inferior, deve-se indicar a fonte consultada, mesmo que seja o próprio autor. No caso de imagens geradas por IA, a indicação de fonte deve especificar o motor de geração e o ano.

EXEMPLO DE APLICAÇÃO NO TEXTO (FORMATO ABNT)

Figura 1 – Esquema conceitual de uma arquitetura de visão computacional embarcada

[Representação Visual Ilustrativa da Arquitetura do Sistema]

Fonte: Imagem gerada por inteligência artificial (DALL-E 3), 2026.

O texto impresso ou digital deve conter, obrigatoriamente, uma chamada direta para a ilustração em parágrafos anteriores à sua inserção (ex: "conforme ilustrado na Figura 1...").

4. Estrutura da Referência Bibliográfica (Fim do Documento)

Na lista de referências ao final do trabalho (organizada em ordem alfabética), a ferramenta de IA deve ser tratada sob a lógica de software ou documento eletrônico de acesso restrito ou dinâmico. A estrutura recomendada pela adaptação técnica da NBR 6023 é a seguinte:

ESTRUTURA PADRÃO PROPOSTA

ORGANIZAÇÃO DESENVOLVEDORA. **Nome da Ferramenta** (Versão). Local de publicação: Empresa/Plataforma, Ano de geração. Descrição do objeto gerado por comando de texto (prompt). Disponível em: <URL de acesso generalizado à ferramenta>. Acesso em: dia mês ano.

4.1. Exemplos Práticos de Referência

MIDJOURNEY INC. **Midjourney** (Versão 6.0). San Francisco: Midjourney Inc., 2026. Imagem técnica gerada por inteligência artificial a partir de comandos textuais específicos do autor. Disponível em: <https://www.midjourney.com>. Acesso em: 15 mar. 2026.

OPENAI. **ChatGPT** (Versão GPT-4 / DALL-E 3). San Francisco: OpenAI, 2026. Diagrama esquemático estrutural gerado por inteligência artificial generativa. Disponível em: <https://chat.openai.com>. Acesso em: 24 jun. 2026.

GOOGLE. **Gemini** (Versão Gemini 1.5 Pro). Mountain View: Google DeepMind, 2026. Representação gráfica vetorial gerada por inteligência artificial. Disponível em: <https://gemini.google.com>. Acesso em: 10 mai. 2026.

5. Declaração Obrigatória de Metodologia (Transparência Técnica)

A mera inserção da fonte sob a figura e a inclusão na lista de referências não esgotam o dever de transparência exigido pela avaliação da CAPES. O pesquisador deve registrar formalmente no corpo do texto (preferencialmente no capítulo de Metodologia, Materiais e Métodos, ou em um Apêndice dedicado) as especificidades operacionais da geração técnica.

Recomenda-se estruturar as seguintes informações em forma de tabela ou texto corrido:

Parâmetro Requerido	Detalhamento Técnico Esperado
Ferramenta e Versão	Especificação exata do motor de inferência (ex: Stable Diffusion XL, Firefly v3).
Engine / Parâmetros	Sementes numéricas (<i>seeds</i>), travas de proporção ou resoluções pré-definidas (se aplicável).
Comando de Entrada	A transcrição literal (ou traduzida) do <i>prompt</i> utilizado para obter a imagem técnica.
Justificativa de Uso	Explicação clara do motivo de se optar pela IA em detrimento de softwares tradicionais de desenho vetorial.

NOTA IMPORTANTE SOBRE A REPRODUTIBILIDADE

Dado que os modelos de IA Generativa operam sob matrizes probabilísticas não determinísticas, o mesmo *prompt* pode não gerar a mesma imagem futuramente. Por esta razão, a documentação rigorosa e o arquivamento seguro das imagens originais de alta resolução nos bancos de dados do laboratório/pesquisador são exigências críticas de reprodutibilidade científica.

6. Conclusão

A conformidade com as boas práticas de citação de inteligência artificial protege a produção científica do pesquisador contra alegações de má conduta acadêmica. Em síntese, o segredo do uso legítimo reside em nunca ocultar a mediação tecnológica, assegurando que o leitor e os avaliadores consigam distinguir com clareza o que constitui processamento manual, dado empírico e síntese algorítmica.