

UNIVERSIDADE FEDERAL DE OURO PRETO  
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS  
DEPARTAMENTO DE COMPUTAÇÃO

FELIPE BRAZ MARQUES

**WEARABLES PARA APOIO NO TRATAMENTO DE ALZHEIMER**

Ouro Preto  
2026

FELIPE BRAZ MARQUES

**WEARABLES PARA APOIO NO TRATAMENTO DE ALZHEIMER**

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como parte dos requisitos necessários para a obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Ricardo Augusto Rabelo Oliveira

Ouro Preto  
2026



## FOLHA DE APROVAÇÃO

**Felipe Braz Marquez**

**Wearables para Apoio no Tratamento de Alzheimer**

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Ciência da Computação

Aprovada em 3 de Março de 2026

### Membros da banca

Ricardo Augusto Rabelo Oliveira (Orientador) - Doutor - Universidade Federal de Ouro Preto  
Fernando Cortez Sica (Examinador) - Doutor - Universidade Federal de Ouro Preto  
Carlos Frederico Marcelo da Cunha Cavalcanti (Examinador) - Doutor - Universidade Federal de Ouro Preto

Ricardo Augusto Rabelo Oliveira, Orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 03/02/2026



Documento assinado eletronicamente por **Ricardo Augusto Rabelo Oliveira Morato, PROFESSOR DE MAGISTERIO SUPERIOR**, em 04/03/2026, às 18:25, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Fernando Cortez Sica, PROFESSOR DE MAGISTERIO SUPERIOR**, em 04/03/2026, às 23:45, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Carlos Frederico Marcelo da Cunha Cavalcanti, PROFESSOR DE MAGISTERIO SUPERIOR**, em 05/03/2026, às 22:58, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **1068238** e o código CRC **6D94C4D6**.

Dedico este trabalho à minha família, em especial aos meus pais, pelo apoio constante. À minha avó Judith, que não apenas inspirou este estudo através de sua jornada com o Alzheimer, mas que é a razão de cada linha escrita. E à memória do meu avô Helvencio Braz, presente em meu coração e em minhas conquistas.

# Agradecimentos

Agradeço primeiro a Deus por ter-me dado a oportunidade de vivenciar a UFOP. Agradeço novamente aos meus pais pelo apoio incondicional do início ao fim dessa jornada, vocês são a minha base. Grato pelas amizades que construí ao longo da caminhada, em especial a *Gangue dos Pedros*, vocês tornaram esse caminho agradável e leve. Obrigado também a todo corpo docente do DECOM pelos ensinamentos.

*“Meu caminho até aqui só eu sei o que trilhei, espinho ou fruto colhido vem do que plantei.”*  
*Souto MC, Música Poetas no Topo 3.3, 2020.*

# Resumo

A Doença de Alzheimer impõe desafios relacionados à segurança, ao acompanhamento contínuo e à resposta rápida a eventos de risco, como quedas, que podem comprometer a autonomia e a integridade física do paciente. Neste trabalho, é desenvolvido e avaliado um sistema vestível **integralmente baseado em processamento local (edge-only)**, sem uso de serviços em nuvem, voltado à **detecção automática de quedas** em pacientes com Alzheimer. A abordagem proposta utiliza sensores inerciais (IMU) e técnicas de **Tiny Machine Learning** executadas diretamente em um microcontrolador de baixo consumo, preservando a privacidade dos dados e reduzindo a latência de resposta. A metodologia contempla: (i) a implementação de um Wearable Node responsável pela aquisição, pré-processamento e segmentação temporal dos sinais inerciais; (ii) o desenvolvimento de um método baseline baseado em regras heurísticas; (iii) o treinamento e embarque de modelos TinyML compactos e quantizados para classificação de quedas; e (iv) a avaliação experimental do sistema em cenários controlados, considerando diferentes posições do dispositivo no corpo do usuário. O desempenho é analisado por meio de métricas como acurácia, sensibilidade, especificidade, latência e consumo energético. Os resultados obtidos demonstram a viabilidade do uso de TinyML embarcado para detecção de quedas em tempo real, evidenciando os trade-offs entre robustez, custo computacional e posicionamento do dispositivo, e reforçando o potencial de soluções vestíveis edge-only para apoio ao cuidado de pacientes com Doença de Alzheimer.

**Palavras-chave:** Computação de borda. Dispositivos vestíveis. Alzheimer. Tiny Machine Learning. Detecção de quedas.

# Abstract

Alzheimer's disease poses significant challenges related to patient safety, continuous monitoring, and timely response to critical events such as falls, which may severely affect patient autonomy and physical integrity. This work presents the development and experimental evaluation of a **fully edge-based (edge-only)** wearable system, without cloud services, aimed at the **automatic detection of falls** in patients with Alzheimer's disease. The proposed approach relies on inertial sensors (IMU) and **Tiny Machine Learning** techniques executed directly on a low-power microcontroller, ensuring data privacy and low-latency response. The methodology includes: (i) the implementation of a Wearable Node responsible for signal acquisition, preprocessing, and temporal segmentation; (ii) the development of a rule-based heuristic baseline; (iii) the training and deployment of compact, quantized TinyML models for fall classification; and (iv) an experimental evaluation under controlled scenarios, considering different device positions on the user's body. System performance is assessed using metrics such as accuracy, sensitivity, specificity, latency, and energy consumption. The results demonstrate the feasibility of embedded TinyML for real-time fall detection, highlighting trade-offs between robustness, computational cost, and device placement, and reinforcing the potential of edge-only wearable solutions to support Alzheimer's care.

**Keywords:** Edge computing. Wearable devices. Alzheimer's disease. Tiny Machine Learning. Fall detection.



# Lista de Figuras

|                                                              |    |
|--------------------------------------------------------------|----|
| Figura 4.1 – Matriz de Confusão do modelo treinado . . . . . | 15 |
|--------------------------------------------------------------|----|

# Lista de Abreviaturas e Siglas

|         |                                                                                  |
|---------|----------------------------------------------------------------------------------|
| ABNT    | Associação Brasileira de Normas Técnicas                                         |
| AES     | Advanced Encryption Standard — Padrão de Criptografia Avançada                   |
| BLE     | Bluetooth Low Energy — Bluetooth de baixo consumo                                |
| CNNs 1D | Convolutional Neural Networks 1D — Redes Neurais Convolucionais Unidimensionais  |
| CSV     | Comma-Separated Values — Valores Separados por Vírgula                           |
| DA      | Doença de Alzheimer                                                              |
| DECOM   | Departamento de Computação                                                       |
| EH      | Edge Hub                                                                         |
| FC      | Frequência Cardíaca                                                              |
| FR      | Frequência Respiratória                                                          |
| GDPR    | General Data Protection Regulation — Regulamento Geral sobre a Proteção de Dados |
| GPS     | Global Positioning System — Sistema de Posicionamento Global                     |
| GSM     | Global System for Mobile Communications                                          |
| HIPAA   | Health Insurance Portability and Accountability Act                              |
| HRV     | Heart Rate Variability — Variabilidade da Frequência Cardíaca                    |
| IA      | Inteligência Artificial                                                          |
| IDE     | Integrated Development Environment — Ambiente de Desenvolvimento Integrado       |
| IMU     | Inertial Measurement Unit — Unidade de Medição Inercial                          |
| INT8    | Integer 8-bit — Representação inteira em 8 bits                                  |
| IoT     | Internet of Things — Internet das Coisas                                         |
| K-NN    | K-Nearest Neighbors                                                              |
| LLM     | Large Language Model — Modelo de Linguagem de Grande Porte                       |

|         |                                                        |
|---------|--------------------------------------------------------|
| MLP     | Multilayer Perceptron — Perceptron Multicamadas        |
| PPG     | Photoplethysmography — Fotopletismografia              |
| QR code | Quick Response code                                    |
| RMS     | Root Mean Square — Raiz da Média dos Quadrados         |
| S/MIME  | Secure/Multipurpose Internet Mail Extensions           |
| SBC     | Single-Board Computer — Computador de Placa Única      |
| TinyML  | Tiny Machine Learning                                  |
| TPU     | Thermoplastic Polyurethane — Poliuretano Termoplástico |
| UFOP    | Universidade Federal de Ouro Preto                     |
| Wi-Fi   | Wireless Fidelity                                      |
| WN      | Wearable Node                                          |

# Lista de Símbolos

|           |                            |
|-----------|----------------------------|
| $\Gamma$  | Letra grega Gama           |
| $\Lambda$ | Lambda                     |
| $\zeta$   | Letra grega minúscula zeta |
| $\in$     | Pertence                   |

# Sumário

|          |                                                                      |           |
|----------|----------------------------------------------------------------------|-----------|
| <b>1</b> | <b>Introdução</b>                                                    | <b>1</b>  |
| 1.0.1    | Justificativa                                                        | 2         |
| 1.0.2    | Objetivos                                                            | 2         |
| 1.0.3    | Organização do Trabalho                                              | 3         |
| <b>2</b> | <b>Revisão Bibliográfica</b>                                         | <b>4</b>  |
| 2.1      | Fundamentação Teórica                                                | 4         |
| 2.1.1    | Wearables e Internet das Coisas no Contexto da Saúde                 | 4         |
| 2.1.2    | Computação de Borda                                                  | 5         |
| 2.1.3    | TinyML no Monitoramento e Apoio ao Tratamento da Doença de Alzheimer | 6         |
| 2.1.4    | Plataformas de Monitoramento e Intervenção                           | 7         |
| 2.1.5    | Privacidade, Segurança e Usabilidade                                 | 7         |
| 2.2      | Trabalhos Relacionados                                               | 7         |
| <b>3</b> | <b>Desenvolvimento</b>                                               | <b>9</b>  |
| 3.1      | Arquitetura do Sistema                                               | 9         |
| 3.2      | Plataforma de Hardware e Software                                    | 9         |
| 3.3      | Aquisição dos Dados Inerciais                                        | 10        |
| 3.4      | Pré-processamento e Segmentação                                      | 10        |
| 3.5      | Extração de Características                                          | 11        |
| 3.6      | Abordagens de Detecção de Quedas                                     | 11        |
| 3.7      | Treinamento e Embarque do Modelo TinyML                              | 12        |
| 3.8      | Fluxo de Processamento do Sistema                                    | 12        |
| 3.9      | Limitações e Considerações Práticas                                  | 12        |
| <b>4</b> | <b>Resultados</b>                                                    | <b>13</b> |
| 4.1      | Visão Geral dos Experimentos                                         | 13        |
| 4.2      | Resultados do Dataset Coletado                                       | 13        |
| 4.3      | Avaliação do Modelo em Ambiente Offline                              | 14        |
| 4.3.1    | Métricas de Classificação                                            | 14        |
| 4.4      | Resultados da Quantização do Modelo                                  | 15        |
| 4.5      | Resultados da Inferência Embarcada                                   | 16        |
| 4.6      | Análise Qualitativa dos Erros                                        | 16        |
| 4.7      | Discussão dos Resultados                                             | 16        |
| 4.8      | Considerações Finais do Capítulo                                     | 17        |
| <b>5</b> | <b>Considerações Finais</b>                                          | <b>18</b> |
| 5.1      | Conclusão                                                            | 18        |
| 5.2      | Trabalhos Futuros                                                    | 19        |
| 5.3      | Publicações Realizadas                                               | 19        |

**Referências . . . . . 20**

# 1 Introdução

A Doença de Alzheimer (DA) é uma condição neurodegenerativa progressiva caracterizada por declínio cognitivo, perdas de memória e alterações comportamentais, afetando diretamente a autonomia funcional do paciente e aumentando a sobrecarga sobre familiares, cuidadores e serviços de saúde. Estimativas globais indicam que, em 2020, aproximadamente 55 milhões de pessoas viviam com algum tipo de demência, com projeções de crescimento contínuo nas próximas décadas em razão do envelhecimento populacional ([Alzheimer's Disease International, 2024](#)). Nesse contexto, estratégias que promovam segurança, monitoramento contínuo e resposta rápida a eventos de risco tornam-se cada vez mais relevantes.

Tecnologias vestíveis ([wearables](#)), associadas à Internet of Things (IoT), ou em português Internet das Coisas, e a técnicas de Inteligência Artificial (IA), emergem como alternativas promissoras para o acompanhamento contínuo de pacientes, possibilitando a detecção de padrões de atividade, alterações fisiológicas e eventos críticos, como quedas ([STAVROPOULOS et al., 2020](#); [MENON et al., 2024](#)). Dispositivos vestíveis modernos são capazes de integrar sensores inerciais e fisiológicos a plataformas computacionais de baixo custo e reduzido consumo energético, tornando viável sua adoção em cenários domiciliares e de cuidado prolongado.

A literatura recente evidencia que muitos desses sistemas são estruturados em arquiteturas IoT tradicionais, nas quais os dados coletados pelos sensores são transmitidos para processamento remoto, geralmente em servidores em nuvem ([SALEHI et al., 2022](#)). Embora essa abordagem permita o uso de modelos mais complexos, ela introduz limitações importantes, como latência adicional, dependência de conectividade, maior consumo energético e riscos à privacidade dos dados de saúde. Em resposta a essas limitações, o paradigma de computação de borda ([edge computing](#)) tem se consolidado na área de saúde digital, ao deslocar o processamento para mais próximo da fonte dos dados, reduzindo atrasos, tráfego de rede e exposição de informações sensíveis ([RANCEA; ANGHEL; CIOARA, 2024a](#)).

No contexto específico de dispositivos vestíveis, as restrições de memória, processamento e bateria impõem a adoção de técnicas de [extreme edge computing](#), como modelos compactos, quantização e fluxos de processamento enxutos ([COVI et al., 2021](#)). Nesse cenário, o paradigma de [Tiny Machine Learning](#) (TinyML) destaca-se por permitir a execução de modelos de aprendizado de máquina diretamente em microcontroladores, viabilizando inferência local em tempo real com baixo consumo energético. Estudos aplicados à saúde e ao cuidado de pacientes com Alzheimer já demonstram a viabilidade de inferência embarcada para reconhecimento de atividades e detecção de eventos, preservando a privacidade dos dados e oferecendo respostas rápidas em ambientes com recursos limitados ([CHOKRI et al., 2022](#)).

Dentre os eventos críticos associados à progressão da DA, as quedas representam um dos

principais riscos à integridade física do paciente, estando associadas a hospitalizações, perda de independência e aumento da mortalidade. A detecção automática de quedas por meio de sensores inerciais constitui, portanto, uma funcionalidade central em sistemas vestíveis de apoio ao cuidado, especialmente quando realizada de forma autônoma, confiável e independente de conectividade externa.

Neste contexto, este trabalho propõe e avalia um sistema vestível **integralmente baseado em processamento local (edge-only)**, sem uso de serviços em nuvem, para a detecção de quedas em pacientes com Doença de Alzheimer. A contribuição central do trabalho reside na investigação comparativa entre abordagens baseadas em regras heurísticas e modelos TinyML embarcados, analisando seu desempenho, robustez e viabilidade em um microcontrolador de baixo consumo, bem como o impacto da posição do dispositivo no corpo do usuário.

### 1.0.1 Justificativa

A progressão da Doença de Alzheimer impõe desafios significativos relacionados à segurança do paciente e à necessidade de monitoramento contínuo. Quedas são eventos frequentes nesse contexto e podem resultar em consequências graves, especialmente quando não há resposta imediata do cuidador. Sistemas vestíveis capazes de detectar quedas em tempo real podem contribuir para a mitigação desses riscos, apoiando intervenções mais rápidas e promovendo maior autonomia e qualidade de vida ao paciente (MENON et al., 2024).

Apesar dos avanços recentes, muitas soluções propostas na literatura ainda dependem de processamento remoto e conectividade contínua, o que pode comprometer a latência, a confiabilidade e a privacidade dos dados (SALEHI et al., 2022). Além disso, há uma carência de estudos experimentais que avaliem, de forma sistemática, a viabilidade de técnicas de TinyML embarcadas em microcontroladores para detecção de quedas, considerando restrições reais de hardware e consumo energético (COVI et al., 2021).

Ao adotar uma abordagem edge-only, este trabalho alinha-se às recomendações de manter dados sensíveis de saúde no próprio dispositivo, reduzindo riscos à privacidade e dependência de infraestrutura externa (RANCEA; ANGHEL; CIOARA, 2024a). A análise comparativa entre métodos heurísticos e modelos TinyML, aliada à avaliação do impacto da posição do dispositivo, contribui para uma compreensão mais aprofundada dos trade-offs envolvidos no projeto de sistemas vestíveis confiáveis e eficientes para apoio ao cuidado de pacientes com Alzheimer.

### 1.0.2 Objetivos

Para a realização da pesquisa, tem-se como objetivo principal projetar, implementar e avaliar experimentalmente um sistema vestível, sem uso de nuvem, baseado em processamento local e Tiny Machine Learning, capaz de detectar quedas em pacientes com Doença de Alzheimer de forma rápida, eficiente e energeticamente viável.



Para alcançar esse objetivo, os seguintes objetivos específicos se fazem necessários serem alcançados:

- a) Implementar um sistema vestível baseado em *Inertial Measurement Unit* (IMU) para aquisição contínua de sinais de movimento, com segmentação temporal adequada à detecção de quedas.
- b) Desenvolver uma abordagem baseline baseada em regras heurísticas para detecção de quedas, utilizando limiares de aceleração, mudança de orientação e períodos de inatividade.
- c) Projetar e treinar modelos TinyML compactos para classificação de quedas e atividades da vida diária, adequados à execução embarcada em microcontroladores.
- d) Comparar experimentalmente as abordagens heurística e TinyML, avaliando métricas como acurácia, sensibilidade, especificidade, latência e taxa de falsos positivos.
- e) Avaliar os custos computacionais do sistema embarcado, incluindo tempo de inferência e consumo energético, discutindo os trade-offs entre desempenho e eficiência.

### 1.0.3 Organização do Trabalho

O [Capítulo 2](#) apresenta a revisão bibliográfica, abordando os fundamentos de wearables em saúde, computação de borda e aprendizado de máquina aplicado a sinais inerciais, bem como os principais trabalhos relacionados. O [Capítulo 3](#) descreve a metodologia adotada, incluindo a arquitetura do sistema, os métodos de detecção de quedas e o protocolo experimental. O [Capítulo 4](#) reúne os resultados obtidos e sua discussão à luz do estado da arte. Por fim, o [seção 5.1](#) apresenta as considerações finais, limitações do estudo e direções para trabalhos futuros.

## 2 Revisão Bibliográfica

Esta revisão bibliográfica está organizada em três eixos principais: (i) fundamentos teóricos sobre *wearables*, IoT e computação de borda aplicados à saúde; (ii) o papel do TinyML no processamento local e contínuo de sinais biomédicos relacionados ao Alzheimer; e (iii) trabalhos relacionados, nos quais são comparadas arquiteturas, métodos e resultados de sistemas já desenvolvidos.

### 2.1 Fundamentação Teórica

#### 2.1.1 Wearables e Internet das Coisas no Contexto da Saúde

Stavropoulos et al. (2020) conduziram uma revisão sistemática que mostrou que entre 2010 e 2020, 63% dos estudos já integram sensores vestíveis em arquiteturas IoT, destacando a crescente adoção de IA para processar esses dados em tempo real. Pesquisas mais recentes focadas em Alzheimer reforçam a tendência: Salehi et al. (2022) catalogam pulseiras, cintos, óculos e smart-socks conectados por Wi-Fi (*Wireless Fidelity*), Bluetooth Low Energy (BLE) e Global System for Mobile Communications (GSM) para monitorar atividades diárias e detecção de quedas, apontando ganhos de autonomia e redução de custos clínicos (SALEHI et al., 2022). Um mapeamento de Menon et al. (2024) confirma que *wearables* compõem o núcleo das tecnologias assistivas mais promissoras para pacientes com demência, impulsionadas por avanços em sensores miniaturizados e aprendizado de máquina embarcado (MENON et al., 2024).

Em sistemas modernos, a coleta de sinais ocorre na camada de sensores (p. ex. acelerômetro, fotopletismografia (PPG), GPS), conectados a um microcontrolador ou SBC que executa filtragem e pré-processamento local antes de transmitir dados via Wi-Fi, BLE ou GSM a uma plataforma em nuvem/borda. Alguns autores descrevem essa abordagem em um protótipo de pulseira para Alzheimer, estruturada em cinco níveis (sensoriamento → comunicação → armazenamento → classificação K-NN → aplicativo móvel), evidenciando a importância de pipelines fim-a-fim para suporte clínico (YADAV; COLABORADORES, 2020).

Segundo Stavropoulos et al. (2020) e Menon et al. (2024), algumas das principais características que esses sistemas devem apresentar são:

- **Confiabilidade:** medições e alertas devem ser consistentes e robustos mesmo em ambientes com conectividade intermitente;
- **Consciência de contexto:** a fusão de múltiplos sensores deve ampliar a percepção situacional do usuário;

- **Facilidade de uso:** a interação deve ser mínima, privilegiando interfaces intuitivas ou até invisíveis;
- **Mobilidade e baixa intrusividade:** o design físico deve preservar livre movimentação, conforto e estética aceitável para uso prolongado.

Trabalhos de revisão salientam barreiras recorrentes: autonomia de bateria, ergonomia, interoperabilidade entre dispositivos heterogêneos e proteção de dados sensíveis (HIPAA/GDPR) (STAVROPOULOS et al., 2020). Mani, Singh e Litoriya (2024b) acrescentam que a precisão de sensores e a ausência de validações clínicas em larga escala ainda limitam a adoção em ambientes reais (MANI; SINGH; LITORIYA, 2024a).

Estudos recentes demonstram que wearables podem ir além do monitoramento passivo, fornecendo intervenções ativas e feedback em tempo real. Pinnelli et al. (2024) propõem um patch multiparamétrico baseado em IMUs capaz de extrair FC, FR e nível de atividade com erro  $< 2\%$  em voluntários, destacando design em TPU para conforto prolongado (PINNELLI et al., 2024). Chokri e Others (2022) implementam reconhecimento facial embarcado em um colar Raspberry Pi, preservando privacidade via esteganografia e S/MIME enquanto enviam alertas de geofencing ao cuidador (CHOKRI et al., 2022). Esses exemplos comprovam a viabilidade de algoritmos de IA locais e ressaltam a necessidade de equilibrar desempenho, segurança e usabilidade.

### 2.1.2 Computação de Borda

A computação de borda (edge computing) é um modelo distribuído que transfere o processamento e o armazenamento de dados para mais próximo da fonte de geração, tal como dispositivos IoT, smartphones ou gateways locais (RANCEA; ANGHEL; CIOARA, 2024b). Essa aproximação reduz a dependência de data centers centralizados e, conseqüentemente, minimiza a latência e o consumo de banda, ao mesmo tempo em que melhora o desempenho geral do sistema.

Rancea, Anghel e Cioara (2024b) destacam sete características essenciais desse paradigma: (i) **proximidade** às fontes de dados, que possibilita processamento em tempo real; (ii) **baixa latência**, vital para aplicações sensíveis a atrasos; (iii) **redução de banda**, pois apenas dados relevantes precisam ser enviados à nuvem; (iv) **segurança e privacidade** aprimoradas, já que informações sensíveis podem permanecer locais; (v) **suporte à mobilidade**, acomodando dispositivos que mudam de localização; (vi) **consciência de localização**, permitindo a entrega de serviços regionais; e (vii) **heterogeneidade**, graças ao suporte a diversos dispositivos, protocolos e modelos de dados (RANCEA; ANGHEL; CIOARA, 2024b).

No contexto da saúde, a computação de borda tem potencial para transformar serviços de e-Health ao levar a análise e a tomada de decisão para dentro de hospitais, residências ou até mesmo wearables. Entre os benefícios apontados estão: (a) decisões em tempo real, cruciais em situações de emergência; (b) mitigação de violações de dados ao manter informações pessoais

no perímetro local; (c) economia de largura de banda e custos operacionais, enviando apenas o estritamente necessário à nuvem; e (d) possibilidade de personalização de modelos de IA, que aprendem com sinais monitorados continuamente para prever problemas de saúde (RANCEA; ANGHEL; CIOARA, 2024b).

Apesar das vantagens, permanecem desafios como a heterogeneidade dos dispositivos, a ausência de padrões de nomenclatura, a necessidade de orquestração de recursos e preocupações adicionais de segurança decorrentes da descentralização. Tais questões reforçam a importância de pesquisas que combinem técnicas de privacidade, métodos de otimização de IA e estratégias de offloading computacional adequadas aos cenários de saúde conectada (RANCEA; ANGHEL; CIOARA, 2024b).

### 2.1.3 TinyML no Monitoramento e Apoio ao Tratamento da Doença de Alzheimer

O TinyML é um paradigma emergente que permite a execução de modelos de aprendizado de máquina, incluindo redes neurais profundas compactadas, diretamente em microcontroladores de ultra-baixo consumo energético (ALAJLAN NORAH N.; IBRAHIM, 2022). Diferentemente das abordagens tradicionais baseadas em nuvem ou edge computing, o TinyML viabiliza inferência local contínua, reduzindo latência, consumo de energia e exposição de dados sensíveis.

No contexto da DA, o TinyML apresenta potencial significativo para aplicações como monitoramento contínuo de sinais fisiológicos, análise de padrões de movimento, reconhecimento de atividades da vida diária, detecção de alterações comportamentais e suporte à identificação precoce de comprometimento cognitivo. (SOUFYA; AITHAL; BAPPALIGE, 2023) destacam que a combinação de TinyML com dispositivos vestíveis permite o acompanhamento em tempo real do estado cognitivo do paciente, possibilitando intervenções antecipadas e maior personalização do cuidado (SOUFYA; AITHAL; BAPPALIGE, 2023).

Além disso, o processamento local viabilizado pelo TinyML favorece a preservação da privacidade, uma vez que dados sensíveis podem ser analisados diretamente no dispositivo, sendo transmitidos apenas alertas ou informações agregadas ao cuidador ou profissional de saúde. Essa característica é particularmente relevante em aplicações voltadas a pacientes com Alzheimer, cuja vulnerabilidade exige rigor ético no tratamento das informações (ALAJLAN NORAH N.; IBRAHIM, 2022).

Revisões sistemáticas (YAHYATI et al., 2025) recentes apontam que aplicações de TinyML na área da saúde concentram-se majoritariamente em tarefas de classificação de sinais biomédicos, detecção de eventos e reconhecimento de padrões temporais, utilizando sensores inerciais, sinais cardíacos, áudio e biomarcadores. Tais capacidades alinham-se diretamente às demandas do cuidado em Alzheimer, em que pequenas variações comportamentais podem indicar progressão da doença.

Apesar do potencial, desafios permanecem, incluindo limitações de memória, interpretabilidade dos modelos, qualidade dos dados coletados e validação clínica em larga escala. Ainda assim, a literatura converge ao apontar o TinyML como um caminho promissor para sistemas assistivos mais autônomos, escaláveis e acessíveis no contexto da saúde cognitiva.

#### 2.1.4 Plataformas de Monitoramento e Intervenção

Arquiteturas típicas incluem um módulo de sensoriamento (aceleração, giroscópio, frequência cardíaca, GPS), um microcontrolador para pré-processamento e um gateway IoT que se comunica com a nuvem. Em alguns sistemas, a análise ocorre no *edge*, reduzindo latência e dependência de conectividade, enquanto outros utilizam plataformas como Ubidots ou Blynk para visualização remota e configuração de alertas em smartphones de cuidadores (DIVYASHREE; PUSHPA; COLABORADORES, 2021).

#### 2.1.5 Privacidade, Segurança e Usabilidade

Considerando a sensibilidade dos dados de saúde, estudos têm incorporado técnicas de criptografia (AES, S/MIME) e esteganografia para comunicação segura entre dispositivo e servidor, bem como autenticação de usuários por reconhecimento facial ou QR code embutido no wearable (CHOKRI et al., 2022; AHMED; AL-NEAMI, 2020). Além disso, a aceitação do usuário final, pacientes com declínio cognitivo, exige interfaces simples e lembretes contextuais para medicação, hidratação e atividades diárias (STAVROPOULOS et al., 2020).

### 2.2 Trabalhos Relacionados

A literatura recente (Alzheimer's Disease International, 2024) aponta para um rápido avanço das soluções vestíveis baseadas em IoT destinadas a apoiar pessoas com Alzheimer, um público estimado em cerca de 55 milhões de indivíduos no mundo em 2020, com projeções de crescimento que podem alcançar 78 milhões em 2030 e 139 milhões em 2050. Nesse contexto, o monitoramento contínuo surge como estratégia essencial para garantir segurança e qualidade de vida quando o cuidador não está presente. Diversos estudos convergem no uso de pulseiras, *smartwatches* e outros dispositivos vestíveis equipados com sensores fisiológicos e botões de emergência, geralmente associados a aplicativos móveis que funcionam como *assistentes pessoais inteligentes*. Apesar dos benefícios, limitações persistem: a autonomia energética ainda é reduzida, obrigando recargas frequentes; o conforto e a adesão permanecem desafios diante de dispositivos volumosos; e a dependência de conectividade ou processamento remoto restringe a execução de algoritmos mais complexos nos próprios dispositivos.

Alguns trabalhos exploraram diretamente dispositivos de rastreamento e monitoramento. Javheri et al. (2024) revisaram soluções de *smart wristwear* com GPS, QR code para dados médicos e plataforma móvel, destacando usabilidade e baixo custo (JAVHERI et al., 2024). Divyashree,

Pushpa e colaboradores (2021) propuseram um relógio inteligente baseado em NodeMCU com sensoriamento multiparamétrico e alertas automáticos via aplicativo (DIVYASHREE; PUSHPA; COLABORADORES, 2021), enquanto Pinnelli et al. (2024) demonstraram a viabilidade de um sistema multiparamétrico com IMUs para acompanhar a carga psicofísica de pacientes e cuidadores em programas “Walk and Talk” . No campo da IoT pervasiva, Yadav e colaboradores (2020) desenvolveram uma plataforma que integra sensores de temperatura, pressão e movimento com microcontrolador e servidor em nuvem, fornecendo suporte em tempo real a pacientes. Paralelamente, surgiram iniciativas voltadas ao apoio cognitivo, como os estudos de Menon et al. (2024) e Ahmed e Al-Neami (2020), que avaliaram sistemas de reconhecimento facial e dispositivos biomédicos assistivos baseados em IA para auxiliar pacientes a lembrar nomes e rostos, favorecendo interações sociais.

Além das propostas de dispositivos e plataformas, destacam-se revisões de literatura que sistematizam os avanços da área. Menon et al. (2024) realizaram um levantamento abrangente sobre tecnologias assistivas para Alzheimer, incluindo IA, IoT, robótica e computação vestível, e enfatizaram desafios como consumo energético e privacidade de dados (MENON et al., 2024). Já Pradhan e Singh (2020) investigaram sensores IoT ambientais e vestíveis para monitorar padrões de atividade, sono e sedentarismo, sugerindo perfis comportamentais preditivos para riscos associados à doença (PRADHAN; SINGH, 2020). Em conjunto, esses trabalhos indicam que o estado da arte já oferece integração madura de sensores e conectividade, mas carece de soluções que unam processamento generativo totalmente *on-device*, eficiência energética compatível com uso prolongado e mecanismos leves de notificação que transmitam apenas alertas relevantes ao cuidador.

## 3 Desenvolvimento

Este capítulo descreve, de forma detalhada, as etapas de concepção e implementação do sistema proposto. Inicialmente, é apresentada a arquitetura edge-only adotada, bem como a plataforma de hardware e software utilizada no desenvolvimento do Wearable Node. Em seguida, são descritos o protocolo de aquisição dos dados inerciais, as estratégias de pré-processamento e segmentação, e o processo de extração de características estatísticas. Posteriormente, são apresentadas as abordagens de detecção de quedas, incluindo o método heurístico de referência e o modelo TinyML baseado em MLP, bem como as etapas de treinamento, quantização e embarque do modelo no microcontrolador. Por fim, é detalhado o fluxo completo de processamento do sistema e discutidas as principais limitações e considerações práticas da solução desenvolvida.

### 3.1 Arquitetura do Sistema

O sistema desenvolvido neste trabalho consiste em um dispositivo vestível voltado ao apoio de pacientes com Doença de Alzheimer, concebido para operar de forma integralmente local (*edge-only*), sem dependência de serviços em nuvem ou conectividade contínua. Essa decisão arquitetural foi motivada por requisitos de privacidade, confiabilidade e baixa latência, fundamentais em aplicações assistivas e de monitoramento contínuo de saúde.

A solução baseia-se no paradigma de *Tiny Machine Learning*, no qual modelos de aprendizado de máquina compactos são executados diretamente em microcontroladores de baixo consumo energético. Dessa forma, todo o processamento, desde a aquisição dos sinais até a inferência final, ocorre localmente no próprio dispositivo, eliminando a necessidade de transmissão de dados sensíveis para servidores externos.

A arquitetura é composta por um único nó vestível, denominado *Wearable Node (WN)*, responsável pela aquisição dos sinais inerciais, pré-processamento, extração de características e detecção de eventos críticos, em especial quedas. Essa abordagem caracteriza um cenário de computação de borda extrema, no qual a tomada de decisão ocorre no ponto mais próximo possível da fonte de dados.

### 3.2 Plataforma de Hardware e Software

O Wearable Node foi implementado utilizando o microcontrolador Arduino Nano 33 BLE, que integra uma IMU composta por acelerômetro e giroscópio triaxiais. Esse dispositivo foi escolhido por oferecer um bom equilíbrio entre capacidade de processamento, disponibilidade de sensores integrados e baixo consumo energético, além de ampla documentação e suporte

comunitário.

O desenvolvimento do firmware foi realizado na Arduino IDE versão 2.3.6, utilizando as bibliotecas `Arduino_LSM9DS1@1.1.1` para acesso aos sensores inerciais, `ArduinoBLE@1.5.0` para comunicação sem fio durante a fase de coleta e depuração, e a biblioteca `TensorFlow Lite Micro Library for Arduino` para execução dos modelos de aprendizado de máquina embarcados.

### 3.3 Aquisição dos Dados Inerciais

A etapa de aquisição de dados foi conduzida de forma controlada, com o objetivo de construir um dataset representativo das atividades de interesse e adequado às restrições do sistema embarcado. O dispositivo foi fixado na região da cintura do voluntário, posição frequentemente adotada na literatura por apresentar boa correlação com o movimento global do corpo e fornecer medidas estáveis da aceleração do centro de massa (STAVROPOULOS et al., 2020; PRADHAN; SINGH, 2020).

Os sinais do acelerômetro e do giroscópio foram amostrados a uma frequência aproximada de 45 Hz, valor suficiente para capturar padrões associados tanto a atividades da vida diária quanto a eventos abruptos, como quedas. Durante a coleta, os dados foram transmitidos via Bluetooth Low Energy para um computador, onde foram armazenados em arquivos no formato CSV, mantendo cada atividade em arquivos separados, de modo a evitar contaminação entre classes.

O protocolo experimental adotado contemplou cinco classes: caminhada, parado, sentar, deitar e queda simulada. Para atividades contínuas, como caminhada e parado, cada repetição teve duração de 30 segundos, sendo realizadas cinco repetições por atividade. Já para atividades pontuais ou de curta duração, como sentar, deitar e quedas simuladas, foram realizados dez eventos independentes para cada classe. Esse procedimento resultou em um conjunto de dados balanceado em termos de diversidade de movimentos, respeitando limitações práticas de tempo e segurança durante a coleta.

Ressalta-se que o conjunto de dados foi obtido a partir de um único voluntário homem e jovem, o que restringe a generalização dos resultados. Ainda assim, o objetivo principal foi avaliar a viabilidade técnica da inferência embarcada, e não a criação de um modelo clínico definitivo.

### 3.4 Pré-processamento e Segmentação

Após a aquisição, os sinais inerciais foram organizados em janelas temporais de um segundo, correspondentes a aproximadamente 45 amostras por eixo. Embora não tenha sido aplicada filtragem digital explícita (como filtros passa-baixa ou Butterworth), a própria segmentação



em janelas e a extração de características estatísticas contribuíram para suavização do ruído de alta frequência.

Para padronização dos dados, foi aplicada normalização do tipo Z-score (StandardScaler), na qual cada atributo é transformado com base em sua média e desvio padrão calculados no conjunto de treinamento. Essa etapa reduz diferenças de escala entre características e melhora a estabilidade do processo de treinamento do modelo.

Optou-se por não utilizar filtros digitais mais sofisticados a fim de manter o custo computacional reduzido e preservar a simplicidade da implementação embarcada, alinhando-se às restrições do paradigma TinyML.

### 3.5 Extração de Características

Para cada janela temporal, foram extraídas características estatísticas clássicas no domínio do tempo, amplamente utilizadas em sistemas de reconhecimento de atividades humanas. Entre as características extraídas, destaca-se o valor RMS (*Root Mean Square*), definido como a raiz da média dos quadrados das amostras do sinal dentro da janela temporal. O RMS é amplamente utilizado em análise de sinais por representar a intensidade média do movimento, sendo especialmente sensível a variações abruptas e impactos, características típicas de eventos de queda. As demais características incluem média, desvio padrão, valor mínimo, valor máximo e energia do sinal, calculadas separadamente para cada um dos seis eixos (três do acelerômetro e três do giroscópio), totalizando 36 atributos por janela.

A adoção desse conjunto de características foi motivada por sua capacidade de representar adequadamente o comportamento do sinal com baixo custo computacional, aspecto essencial para viabilizar a inferência em microcontroladores com recursos limitados.

### 3.6 Abordagens de Detecção de Quedas

Como referência inicial, foi implementada uma abordagem baseada em regras heurísticas para detecção de quedas, fundamentada em limiares de aceleração, variações abruptas de orientação e períodos subsequentes de baixa atividade. Essa abordagem apresenta latência mínima e simplicidade de implementação, sendo amplamente utilizada como baseline em sistemas vestíveis.

Em paralelo, foram desenvolvidas abordagens baseadas em aprendizado de máquina, utilizando modelos compactos adequados ao contexto de TinyML. Dentre os modelos avaliados, destaca-se o Perceptron Multicamadas (MLP), treinado a partir dos vetores de características extraídas, e posteriormente quantizado para execução embarcada.

### **3.7 Treinamento e Embarque do Modelo TinyML**

O treinamento dos modelos foi realizado em ambiente externo, utilizando Python e bibliotecas de aprendizado de máquina. Após o treinamento, o modelo MLP foi convertido para o formato TensorFlow Lite e quantizado para representação inteira em 8 bits (int8), reduzindo significativamente o uso de memória e o tempo de inferência.

O modelo quantizado foi então embarcado no Arduino Nano 33 BLE, onde passou a realizar inferência local em tempo real. Para garantir consistência entre o ambiente de treinamento e o ambiente embarcado, os mesmos procedimentos de normalização e extração de características foram reproduzidos no firmware do dispositivo.

### **3.8 Fluxo de Processamento do Sistema**

De forma resumida, o fluxo de processamento do sistema inicia-se com a aquisição contínua dos sinais inerciais, seguida pela segmentação em janelas temporais e extração de características estatísticas. Em seguida, essas características são normalizadas e fornecidas como entrada ao modelo TinyML ou à abordagem heurística, resultando em uma decisão local sobre a ocorrência de uma queda ou atividade reconhecida. Todo esse fluxo ocorre de maneira autônoma no Wearable Node, sem necessidade de comunicação externa.

### **3.9 Limitações e Considerações Práticas**

Embora o sistema tenha sido projetado para operar em condições realistas, algumas limitações devem ser consideradas. A variabilidade entre usuários, diferenças no posicionamento do dispositivo e a dificuldade de simular quedas reais de forma segura podem impactar a generalização dos modelos. Além disso, restrições energéticas e de memória impõem limites ao tamanho e complexidade dos modelos embarcados.

Esses aspectos são levados em conta na análise dos resultados e discutidos de forma crítica, reforçando a necessidade de estudos futuros com maior diversidade de participantes e cenários de uso.

## 4 Resultados

Este capítulo apresenta os resultados obtidos com a solução proposta para reconhecimento de atividades humanas e detecção de quedas a partir de sinais inerciais. Os experimentos foram conduzidos em duas etapas principais: (i) avaliação do modelo em ambiente offline, utilizando os dados coletados e processados em Python; e (ii) validação da inferência embarcada em um microcontrolador, após a quantização do modelo para execução em ambiente restrito de recursos. Ao longo do capítulo, são discutidos tanto os resultados quantitativos quanto observações qualitativas sobre o comportamento do sistema.

### 4.1 Visão Geral dos Experimentos

A abordagem experimental adotada teve como objetivo verificar a viabilidade do uso de técnicas de aprendizado de máquina leve (TinyML) para classificação de atividades e detecção de quedas em tempo real, preservando privacidade e reduzindo dependência de infraestrutura externa. Para isso, foi desenvolvido um pipeline completo que compreende coleta de dados com sensores inerciais, extração de atributos estatísticos, treinamento de um classificador MLP e execução embarcada do modelo quantizado em int8 no Arduino Nano 33 BLE.

Os experimentos foram conduzidos com o dispositivo posicionado na cintura do usuário, cenário frequentemente adotado na literatura por apresentar boa representatividade dos movimentos corporais centrais.

### 4.2 Resultados do Dataset Coletado

O dataset utilizado nos experimentos foi construído a partir de coletas reais realizadas com o Arduino Nano 33 BLE, equipado com sensores de aceleração e giroscópio. Os sinais foram amostrados a uma frequência aproximada de 45 Hz e segmentados em janelas temporais de 1 segundo, cada uma contendo 45 amostras por eixo.

Foram consideradas cinco classes de atividades:

- caminhada;
- sentar;
- deitar;
- parado;
- queda simulada.

Para cada janela, foram extraídos atributos estatísticos clássicos, incluindo média, desvio padrão, mínimo, máximo, valor RMS e energia, totalizando 36 características por amostra. Essa escolha buscou equilibrar representatividade do sinal e baixo custo computacional, aspecto essencial para execução embarcada.

## 4.3 Avaliação do Modelo em Ambiente Offline

O modelo MLP foi avaliado inicialmente em ambiente offline, utilizando divisão estratificada do dataset em conjuntos de treinamento e teste. As métricas de desempenho foram calculadas com base no conjunto de teste, permitindo uma análise objetiva da capacidade de generalização do classificador.

### 4.3.1 Métricas de Classificação

Tabela 4.1 – Tabela de métricas

| Classe          | Precision           | Recall | F1-score | Support |
|-----------------|---------------------|--------|----------|---------|
| Caminhada       | 0.96                | 0.99   | 0.97     | 79      |
| Deitar          | 0.82                | 0.62   | 0.71     | 29      |
| Parado          | 0.96                | 1.00   | 0.98     | 81      |
| Queda           | 0.82                | 0.70   | 0.76     | 40      |
| Sentar          | 0.72                | 0.91   | 0.81     | 32      |
| <b>Acurácia</b> | 0.90 (261 amostras) |        |          |         |
| Macro avg       | 0.86                | 0.84   | 0.85     | 261     |
| Weighted avg    | 0.90                | 0.90   | 0.89     | 261     |

A [Tabela 4.1](#) obtida indica que o modelo alcançou acurácia global próxima de 90%, evidenciando desempenho satisfatório para o problema proposto. As classes caminhada e parado apresentaram os melhores resultados, com valores elevados de precision, recall e F1-score, refletindo a estabilidade e regularidade dos padrões inerciais associados a essas atividades

Por outro lado, observou-se maior dificuldade na distinção entre as classes sentar, deitar e queda, especialmente em eventos de curta duração. Esse comportamento é esperado, uma vez que tais atividades compartilham transições posturais semelhantes, o que pode gerar sobreposição parcial das características extraídas.

A Figura da matriz de confusão evidencia que a maioria das amostras foi corretamente classificada, com erros concentrados principalmente entre as classes posturais, como sentar e deitar. Observa-se, ainda, que o conjunto de dados apresenta leve desbalanceamento entre as classes, o que pode influenciar o desempenho do modelo, favorecendo atividades com maior número de amostras.

As classes caminhada e parado, por representarem movimentos mais frequentes no cotidiano, apresentaram maior quantidade de dados e, conseqüentemente, melhor desempenho em termos de recall e precisão. Por outro lado, a classe queda, evento naturalmente raro, possui menor número de exemplos, o que pode impactar sua taxa de detecção. Ainda assim, o modelo apresentou desempenho satisfatório nessa classe, indicando capacidade de capturar padrões característicos de movimentos abruptos associados a impactos e mudanças bruscas de orientação corporal.

Esse comportamento é esperado em sistemas de reconhecimento de atividades humanas, nos quais eventos críticos tendem a ser menos representados no conjunto de treinamento quando comparados a atividades rotineiras.

A análise da matriz reforça a importância de considerar tanto métricas globais quanto a distribuição dos erros entre classes, especialmente em aplicações sensíveis como monitoramento de pacientes.




Figura 4.1 – Matriz de Confusão do modelo treinado

## 4.4 Resultados da Quantização do Modelo

Com o objetivo de viabilizar a execução do modelo em microcontroladores, o classificador MLP foi convertido para o formato TensorFlow Lite com quantização inteira em 8 bits (int8). O modelo original, em representação de ponto flutuante, ocupava aproximadamente 52 kB de

memória, enquanto a versão quantizada apresentou tamanho de apenas 6 kB, representando uma redução de cerca de 88% no uso de armazenamento.

Essa redução tornou o modelo plenamente compatível com as restrições de memória do Arduino Nano 33 BLE, mantendo viável a execução em tempo real. Observou-se que a quantização não introduziu degradação perceptível no desempenho prático do sistema, indicando que a abordagem baseada em atributos estatísticos apresenta robustez suficiente para suportar compressão agressiva sem comprometer a capacidade de detecção de quedas. Esses resultados reforçam a adequação do uso de TinyML para aplicações vestíveis com recursos computacionais limitados.

## **4.5 Resultados da Inferência Embarcada**

Após a conversão e quantização, o modelo foi embarcado no Arduino Nano 33 BLE e testado em tempo real. A inferência foi realizada diretamente no dispositivo, a partir de janelas de 1 segundo dos sinais inerciais, sem necessidade de comunicação com servidores externos.

Durante os testes práticos, o sistema apresentou respostas coerentes com as atividades realizadas pelo usuário, identificando corretamente estados estáticos e dinâmicos. A latência percebida foi desprezível, permitindo a utilização contínua do sistema em cenários reais. Além disso, a execução integralmente local garante maior privacidade dos dados, aspecto fundamental em aplicações voltadas à saúde.

## **4.6 Análise Qualitativa dos Erros**

Apesar dos resultados positivos, algumas limitações foram observadas. Em particular, transições rápidas entre atividades podem ocasionar oscilações temporárias na predição, principalmente entre as classes sentar, deitar e queda. Esse comportamento é consistente com a similaridade dos padrões inerciais nesses movimentos e já é relatado em estudos semelhantes.

Tais oscilações não comprometem a viabilidade da solução, mas indicam possibilidades de aprimoramento futuro, como o uso de janelas sobrepostas, suavização temporal das predições ou incorporação de informações contextuais adicionais.

## **4.7 Discussão dos Resultados**

Os resultados obtidos demonstram que a solução proposta atende aos objetivos definidos neste trabalho, combinando desempenho satisfatório, baixo custo computacional e execução embarcada em tempo real. A utilização de atributos clássicos, aliada a um modelo MLP leve, mostrou-se adequada para o reconhecimento de atividades e detecção de quedas em dispositivos com recursos limitados.

Além disso, a execução local do modelo reforça a relevância da abordagem no contexto de aplicações assistivas, especialmente para pacientes com Doença de Alzheimer, nos quais aspectos como privacidade, autonomia e confiabilidade são fundamentais.

## **4.8 Considerações Finais do Capítulo**

Em síntese, os experimentos realizados indicam que o sistema desenvolvido é capaz de reconhecer atividades humanas e detectar quedas de forma eficiente, tanto em ambiente offline quanto em execução embarcada. Embora existam limitações inerentes ao tamanho do dataset e à similaridade entre algumas classes, os resultados obtidos são consistentes com o estado da arte e evidenciam o potencial do uso de TinyML em soluções vestíveis voltadas ao cuidado contínuo.

## 5 Considerações Finais

### 5.1 Conclusão

Este trabalho apresentou o desenvolvimento e a avaliação de um sistema vestível baseado em **computação de borda integral (edge-only)** para reconhecimento de atividades humanas e detecção de quedas, com foco no apoio ao cuidado de pessoas com Doença de Alzheimer. A proposta fundamenta-se no uso de sensores inerciais e técnicas de Tiny Machine Learning, permitindo a execução local de modelos de aprendizado de máquina em um microcontrolador de baixo consumo, sem dependência de serviços em nuvem ou conectividade contínua.

A partir da revisão bibliográfica e da análise dos requisitos técnicos e assistivos, foi definida uma arquitetura centrada em um único Wearable Node, responsável por todas as etapas do processamento, desde a aquisição dos sinais de aceleração e giroscópio até a inferência final sobre a atividade executada. Essa abordagem prioriza baixa latência, maior confiabilidade operacional e preservação da privacidade dos dados, aspectos particularmente relevantes em aplicações voltadas à saúde e ao monitoramento domiciliar.

No que se refere aos objetivos específicos estabelecidos, conclui-se que:

- *Especificar e implementar uma arquitetura vestível edge-only:* **atingido**. O sistema foi concebido para operar de forma totalmente local, com aquisição, processamento e inferência realizados diretamente no microcontrolador.
- *Construir um dataset representativo a partir de coletas reais:* **atingido**. Foi elaborado um conjunto de dados próprio, obtido por meio de um protocolo experimental controlado, contemplando atividades da vida diária e quedas simuladas.
- *Desenvolver e avaliar modelos TinyML para detecção de quedas:* **atingido**. Um modelo MLP compacto, baseado em características estatísticas clássicas, foi treinado, avaliado em ambiente offline e posteriormente quantizado para execução embarcada.
- *Validar a inferência embarcada em tempo real:* **atingido**. O modelo quantizado foi executado com sucesso no Arduino Nano 33 BLE, apresentando respostas coerentes com as atividades realizadas e latência adequada para aplicações assistivas.

De forma geral, os resultados demonstram que a utilização de atributos clássicos combinados a modelos leves de aprendizado de máquina é suficiente para reconhecer atividades humanas e detectar quedas com desempenho satisfatório, mesmo sob as restrições de memória e processamento impostas por microcontroladores. A execução local da inferência evidencia o



potencial do paradigma TinyML para aplicações vestíveis na área da saúde, especialmente em contextos que exigem autonomia, privacidade e operação contínua.

A principal contribuição deste trabalho reside na implementação de um pipeline completo, da coleta de dados à inferência embarcada, validando experimentalmente a viabilidade de soluções edge-only para monitoramento assistivo. Ao evitar dependência de infraestrutura externa, o sistema proposto se mostra adequado para cenários domiciliares e de cuidado contínuo, alinhando-se às demandas atuais por tecnologias mais seguras, acessíveis e centradas no usuário.

## 5.2 Trabalhos Futuros

Como desdobramentos naturais deste estudo, destacam-se as seguintes possibilidades de trabalhos futuros:

1. **Ampliação do conjunto de dados:** inclusão de mais voluntários, diferentes perfis físicos e cenários de uso, visando melhorar a generalização dos modelos.
2. **Avaliação de outras arquiteturas TinyML:** investigação de modelos temporais, como CNNs 1D ou abordagens híbridas, mantendo as restrições de execução embarcada.
3. **Suavização temporal das previsões:** aplicação de filtros ou janelas sobrepostas para reduzir oscilações durante transições entre atividades.
4. **Otimização energética:** análise detalhada do consumo de energia e adoção de estratégias como duty-cycling e ajuste adaptativo da taxa de amostragem.
5. **Integração com mecanismos de alerta:** desenvolvimento de notificações locais ou comunicação opcional com dispositivos externos, respeitando o paradigma edge-only.
6. **Avaliação com usuários finais:** estudos de usabilidade envolvendo cuidadores e profissionais da saúde, visando avaliar aceitabilidade e impacto prático da solução.

## 5.3 Publicações Realizadas

Até o momento, este trabalho não originou publicações científicas. Com a ampliação dos experimentos e a validação com um conjunto maior de participantes, pretende-se submeter os resultados a eventos e periódicos nas áreas de sistemas embarcados, aprendizado de máquina aplicado e computação em saúde.

# Referências

AHMED, P.; AL-NEAMI, P. Título completo do artigo. Nome do Periódico, 2020. Preencher DOI, volume e páginas.

ALAJLAN NORAH N.; IBRAHIM, D. M. Tinyml: Enabling of inference deep learning models on ultra-low-power iot edge devices for ai applications. Micromachines, v. 13, n. 6, p. 851, 2022.

Alzheimer's Disease International. Dementia statistics. 2024. <<https://www.alzint.org/about/dementia-facts-figures/dementia-statistics/>>. Acesso em: 14 jun. 2025.

CHOKRI, R.; OTHERS. Secure iot assistant-based system for alzheimer's disease. In: Proceedings of the 2022 International Conference on Internet of Things and Smart Health (ICISH). [S.l.: s.n.], 2022. Verificar local e DOI completos no PDF.

COVI, E.; DONATI, E.; LIANG, X.; KAPPEL, D.; HEIDARI, H.; PAYVAND, M.; WANG, W. Adaptive extreme edge computing for wearable devices. Frontiers in Neuroscience, v. 15, p. 611300, 2021. Disponível em: <<https://doi.org/10.3389/fnins.2021.611300>>.

DIVYASHREE; PUSHPA; COLABORADORES. The memorable assistant: An iot-based smart wearable alzheimer's assisting device. In: 2021 IEEE Symposium on Wearable and Implantable Body Sensor Networks (BSN). [S.l.: s.n.], 2021. Verificar local e DOI no PDF.

JAVHERI, R.; PATIL, D.; KAMBLE, A.; YADAV, A.; KOLHE, P.; MATE, G. S. A review: Smart wristwear for alzheimer patients with an advanced tracking system. In: 2024 IEEE Region 10 Symposium (TENSYP). Pune, India: IEEE, 2024. ISBN 978-1-5386-5223-6.

MANI, K.; SINGH, K. K.; LITORIYA, R. Transformative potential iot sensor frameworks for real-time alzheimer's detection and monitoring in elderly populations. In: Proceedings of the 2024 International Conference on Advances in Computing Research on Science Engineering and Technology (ACROSET). Indore, Índia: IEEE, 2024.

MANI, P.; SINGH, P.; LITORIYA, P. Transformative potential iot sensor frameworks for real-time alzheimer's detection and monitoring in elderly populations. Journal of Biomedical Informatics, 2024. Preencher volume, páginas e DOI.

MENON, R. R.; VARGHESE, R.; T, S.; SHAJU, A.; BHADRAN, A.; SIROSH, F. A survey on alzheimer's patient's assistive technology. In: Proceedings of the International Conference on Trends in Engineering Systems and Technologies (ICTEST). Kalady, India: IEEE, 2024.

PINNELLI, M.; SCHENA, E.; MASSARONI, C.; ROMANO, C.; SILVESTRI, S.; SETOLA, R.; PULCINELLI, M.; FORTINO, G.; PRESTI, D. L. A wearable platform as a first step towards enabling collective intelligence in alzheimer's disease management: Feasibility assessment on healthy volunteers. In: Proceedings of the International Workshop on Metrology for Industry 4.0 & IoT. Osaka, Japan: IEEE, 2024.

PRADHAN, N.; SINGH, A. S. Predictive alzheimer disease detection model using iot sensors: A survey. In: IOP Conference Series: Materials Science and Engineering. [S.l.: s.n.], 2020. v. 881, n. 1.

RANCEA, A.; ANGHEL, I.; CIOARA, T. Edge computing in healthcare: Innovations, opportunities, and challenges. *Future Internet*, v. 16, n. 9, p. 329, 2024. Disponível em: <<https://www.mdpi.com/1999-5903/16/9/329>>.

RANCEA, A.; ANGHEL, I.; CIOARA, T. Edge computing in healthcare: Innovations, opportunities, and challenges. *Future Internet*, v. 16, p. 329, sep. 2024. Disponível em: <<https://doi.org/10.3390/fi16090329>>. Acesso em: 6 ago. 2025.

SALEHI, W.; GUPTA, G.; BHATIA, S.; KOUNDAL, D.; MASHAT, A.; BELAY, A. Iot-based wearable devices for patients suffering from alzheimer disease. *Contrast Media & Molecular Imaging*, v. 2022, p. 3224939, 2022.

SOUMYA, S.; AITHAL, P. S.; BAPPALIGE, N. N. Tinyml for alzheimer's research: Harnessing neural networks for insights and diagnostics. In: *Future Trends in Information, Communication and Computing Technology*. [S.l.]: Zenodo, 2023.

STAVROPOULOS, T. G.; PAPASTERGIOU, A.; MPALTADOROS, L.; NIKOLOPOULOS, S.; KOMPATSIARIS, I. Iot wearable sensors and devices in elderly care: A literature review. *Sensors*, v. 20, n. 10, p. 2826, 2020.

YADAV, P.; COLABORADORES. Development of pervasive iot based healthcare monitoring system for alzheimer patients. *Procedia Computer Science*, v. 167, p. 1950–1959, 2020.

YAHYATI, C.; LAMAAKAL, I.; MALEH, Y.; MAKKAOUI, K. E.; OUAHBI, I.; ALMOUSA, M.; EL-LATIF, A. A. A. A systematic review of state-of-the-art tinyml applications in healthcare, education, and transportation. *IEEE Access*, v. 13, p. 1–25, Nov 2025. Disponível em: <<https://doi.org/10.1109/ACCESS.2025.3633575>>.