

Proposta de Desenvolvimento de Dispositivo Vestível Baseado em Edge AI para Avaliação Objetiva em Sessões de Fisioterapia

Tobias Moraes de Souza
Centro Universitário Estácio de Belém
Belém, Pará, Brasil

Clara de Aquino Rodrigues
Centro Universitário Estácio de Belém
Belém, Pará, Brasil

Eucila Gisele Silva de Freitas
Centro Universitário Estácio de Belém
Belém, Pará, Brasil

Ramon Costa de Lima
Centro Universitário Estácio de Belém
Fisioterapia
Belém, Pará, Brasil

Marcos César da Rocha Seruffo
Universidade Federal do Pará (UFPA)
Belém, Pará, Brasil

Diego Lisboa Cardoso
Universidade Federal do Pará (UFPA)
Belém, Pará, Brasil

Frederico Guilherme Santana
da Silva Filho
Centro Universitário Estácio de Belém
Belém, Pará, Brasil

Abstract

The convergence between the Internet of Medical Things (IoMT) and physical rehabilitation demands objective monitoring solutions to effectively assess patient progress during therapy sessions. Current approaches often rely heavily on subjective clinical assessments or cloud-based processing architectures, which introduce undesirable latency and significant privacy concerns regarding patient data. This work proposes the development of a low-cost wearable hardware architecture combined with Artificial Intelligence algorithms running directly at the edge, a paradigm known as Edge AI. The system is designed for the acquisition of kinematic data and real-time inference of motor patterns specifically during physiotherapy exercises. Based on a comprehensive systematic review of the literature, the proposed device integrates a modern RP2040 microcontroller with precision BMI160 inertial sensors. This specific architecture aims to overcome the limitations of traditional monitoring systems by offering a non-invasive and energetically efficient solution for evaluating movement quality during sessions, processing data locally to ensure patient privacy and rapid therapeutic response.

Keywords

Inteligência Artificial; Wearables; Fisioterapia; Edge AI; Microcontroladores; IoMT

1 Introdução e Contextualização

A medicina contemporânea vivencia uma transição paradigmática fundamental, migrando progressivamente para uma abordagem baseada em evidências quantitativas. Nesse cenário de transformação digital, a convergência entre a computação ubíqua e a assistência à saúde permitiu o surgimento da Internet das Coisas Médicas [7]. Esta nova classe de dispositivos caracteriza-se por permitir a coleta precisa de dados biomecânicos durante a execução de tarefas específicas, integrando-se à rotina de reabilitação sem causar desconforto físico ou restringir a amplitude de movimento do paciente.

A aplicação prática dessas tecnologias é crucial na reabilitação motora e na fisioterapia, áreas onde a avaliação da qualidade do movimento durante as sessões é um desafio constante. A avaliação clínica tradicional baseia-se frequentemente na observação visual subjetiva do terapeuta, o que pode falhar em quantificar com precisão a evolução de ângulos articulares, a fluidez do movimento ou a presença de tremores sutis durante os exercícios [5]. A capacidade de monitorar o paciente objetivamente durante a sessão permite ajustes imediatos no protocolo de tratamento, baseados em métricas concretas e não apenas em percepções qualitativas.

Entretanto, a onipresença de sensores inerciais gerou um volume de dados que requer análise especializada. A literatura recente aponta que a simples coleta de dados brutos de acelerometria durante os exercícios é insuficiente sem um processamento inteligente capaz de transformar esses sinais em biomarcadores acionáveis de performance [15]. Além disso, a dependência exclusiva de arquiteturas baseadas em nuvem introduz latência, prejudicando o feedback em tempo real necessário durante a execução do movimento.

Diante deste cenário, este trabalho propõe o desenvolvimento de uma arquitetura de hardware vestível de baixo custo, aliada a algoritmos de Inteligência Artificial, capaz de realizar a aquisição de dados cinemáticos e a inferência da qualidade do movimento diretamente no dispositivo durante as sessões de fisioterapia. O foco principal reside na precisão da avaliação e na segurança dos dados, visando fornecer uma ferramenta de suporte à decisão clínica.

2 Fundamentação Teórica

Para embasar as escolhas arquiteturais deste projeto, foi conduzida uma revisão sistemática prévia que analisou 39 estudos de alto impacto publicados entre 2016 e 2025 distribuídos conforme a Figura 1 abaixo.

2.1 Deep Learning na Análise de Movimento

A literatura demonstra que arquiteturas de Aprendizado Profundo, especificamente as Redes Neurais Convolucionais (CNNs), são ideais

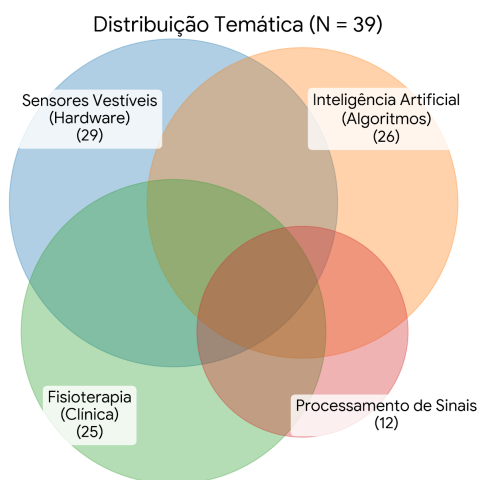


Figura 1: Diagrama de distribuição temática dos estudos considerados

para analisar a execução de exercícios terapêuticos [13]. Diferentemente de métodos estatísticos simples, as CNNs conseguem aprender padrões complexos de movimento a partir dos dados brutos dos sensores, permitindo classificar se um exercício está sendo realizado corretamente ou identificar compensações motoras indesejadas.

Estudos indicam que mecanismos de atenção permitem que o modelo foque nos momentos críticos do ciclo do movimento, ignorando períodos de repouso entre repetições, o que é essencial para gerar relatórios fidedignos sobre o desempenho do paciente durante a sessão [8, 11].

2.2 Edge AI para Feedback Imediato

Em sessões de fisioterapia, o feedback imediato é vital para a correção motora. A latência introduzida pelo envio de dados para a nuvem pode desincronizar o feedback visual ou háptico. Pesquisas de Tam et al. [10] validam o uso de *Edge AI*, onde a análise ocorre no próprio microcontrolador. Isso garante que a avaliação da execução do exercício seja instantânea, além de aumentar a privacidade, pois apenas os resultados da avaliação (e não os dados brutos do paciente) precisam ser armazenados ou transmitidos [1].

3 Metodologia e Arquitetura do Dispositivo

A proposta técnica consiste no desenvolvimento de um nó de sensor sem fio compacto, projetado para ser acoplado ao membro do paciente apenas durante a realização dos exercícios [9]. A arquitetura, ilustrada na Figura 2 é otimizada para alto desempenho durante curtos períodos de uso ativo.

3.1 Unidade de Processamento e Controle

O núcleo de processamento é o microcontrolador RP2040 (placa RP2040-Zero). Sua arquitetura *dual-core* ARM Cortex-M0+ é explorada para garantir a precisão temporal: um núcleo dedica-se exclusivamente à amostragem dos sensores em alta frequência,

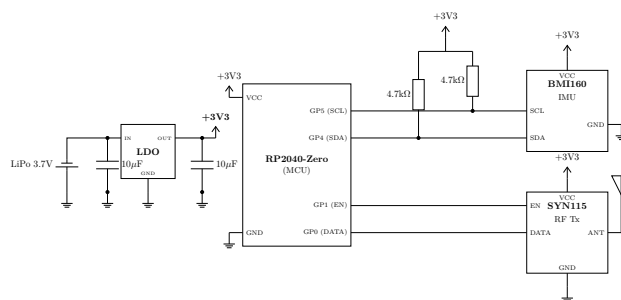


Figura 2: Diagrama esquemático do sistema vestível: MCU RP2040-Zero, IMU BMI160, RF SYN115 e Alimentação.

essencial para capturar movimentos rápidos, enquanto o outro executa os algoritmos de IA para classificar a execução do exercício em tempo real. Essa divisão impede que o processamento da inferência cause perda de dados durante o movimento [3].

3.2 Sensoriamento Inercial de Precisão

A captura dos dados cinemáticos utiliza o sensor BMI160, uma IMU de 6 eixos. A fusão de dados de acelerômetro e giroscópio permite reconstruir a trajetória do movimento no espaço, fornecendo dados sobre amplitude, velocidade e suavidade, métricas fundamentais para a avaliação fisioterapêutica [2].

3.3 Comunicação sem Fio

Para a transmissão dos resultados da avaliação para o computador ou tablet do terapeuta, utiliza-se o módulo RF SYN115 (Sub-GHz). Esta escolha garante uma conexão robusta dentro do ambiente clínico ou doméstico, sem a complexidade de pareamento do Bluetooth, facilitando o uso rápido entre diferentes pacientes [12].

3.4 Gerenciamento de Energia

Embora o uso seja limitado às sessões, a eficiência energética permanece importante para garantir que o dispositivo esteja sempre pronto para uso. O sistema é alimentado por uma bateria LiPo de 3.7V com regulador LDO, garantindo estabilidade durante os picos de processamento da rede neural [6].

4 Resultados Esperados e Discussão

A implementação visa fornecer uma ferramenta objetiva para o ambiente terapêutico.

4.1 Avaliação Objetiva da Sessão

O dispositivo fornecerá métricas quantitativas sobre cada repetição realizada, superando a contagem manual e a avaliação visual. Dados sobre a fadiga muscular (inferida por alterações no padrão de movimento) e a consistência da execução permitem ao terapeuta ajustar a carga e a dificuldade dos exercícios com base em evidências [14].

4.2 Segurança e Praticidade

A arquitetura *Edge* elimina a necessidade de infraestrutura de rede complexa na clínica. Como os dados são processados localmente,

reduz-se o risco de exposição de dados sensíveis. O uso de componentes de baixo custo (COTS) viabiliza a adoção de múltiplos dispositivos para monitorar diferentes segmentos corporais simultaneamente.

4.3 Limitações do Estágio Atual

Conforme a natureza desta pesquisa, a proposta encontra-se atualmente em um estágio de concepção arquitetural. Embora o modelo desenhado esteja rigorosamente alinhado ao estado da arte e às restrições clínicas, a ausência provisória de testes quantitativos com usuários finais (pacientes e profissionais de fisioterapia) e de uma implementação física em larga escala validada compõem as limitações deste estágio primário, balizando os próximos passos de desenvolvimento.

5 Conclusão e Trabalhos Futuros

Este trabalho apresentou a arquitetura de um dispositivo vestível focado na avaliação objetiva durante sessões de reabilitação. A proposta atende à demanda por ferramentas que quantifiquem o progresso terapêutico, preenchendo a lacuna de subjetividade na avaliação clínica. Ao priorizar o processamento na borda, o sistema garante feedback em tempo real, essencial para o aprendizado motor. A combinação do RP2040 com sensores MEMS oferece o desempenho necessário para analisar a qualidade do movimento in loco, constituindo um passo significativo para a modernização das práticas fisioterapêuticas [4].

Considerando que o estudo se encontra em um estágio inicial de formulação conceitual da arquitetura, os próximos passos da pesquisa concentram-se na implementação e validação empírica. Os trabalhos futuros englobam a prototipagem física do dispositivo, a coleta e rotulagem de um dataset primário com movimentos terapêuticos, além do treinamento e embarque de modelos preditivos otimizados para microcontroladores (através da abordagem

TinyML). Por fim, testes quantitativos com usuários em ambiente clínico serão conduzidos para validar a acurácia do sistema e consolidar sua maturidade científica.

References

- [1] L. Black, R. Red, and G. Green. 2021. Secure Data Transmission in WBAN. *IEEE Internet of Things Journal* 8, 12 (2021). doi:10.1109/JIOT.2021.3054321
- [2] H. Chen, Y. Zhang, and X. Wang. 2022. Fusion of Vision and Inertial Sensors for Upper Limb Analysis. *IEEE Transactions on Human-Machine Systems* 52, 2 (2022). doi:10.1109/THMS.2021.3134567
- [3] X. Chen, L. Gong, L. Wei, S. Yeh, L. Da Xu, L. Zheng, and Z. Zou. 2021. A Wearable Hand Rehabilitation System With Soft Gloves. *IEEE Transactions on Industrial Informatics* 17, 2 (2021). doi:10.1109/TII.2020.3010369
- [4] M. Gomez et al. 2025. Design of an AI-driven home-based pulmonary telerehabilitation system to enhance patient engagement. *PubMed Central* (2025).
- [5] J. Li et al. 2025. Wearable Sensors and Artificial Intelligence for the Diagnosis of Parkinson's Disease. *PubMed Central* (2025).
- [6] Q. Li, Y. Wu, and S. Liu. 2024. Smart Textile Sensors for Continuous Health Monitoring. *IEEE Sensors Journal* 24, 1 (2024). doi:10.1109/JSEN.2023.3334567
- [7] Edna Ramos de Medeiros. 2016. Revisão Sistemática sobre os Dispositivos Vestíveis na Área da Saúde.
- [8] M. O'Brien et al. 2024. Early Prediction of Poststroke Rehabilitation Outcomes Using Wearable Sensors. *Archives of Physical Medicine and Rehabilitation* (2024).
- [9] Y. Su, X. Li, and H. Liu. 2022. Soft Pneumatic Glove with Integrated Sensing for Hand Rehabilitation. *IEEE Transactions on Biomedical Engineering* 69, 5 (2022). doi:10.1109/TBME.2021.3126457
- [10] S. Tam, M. Boukadoum, A. Campeau-Lecours, and B. Gosselin. 2020. A Fully Embedded EMG-Based Gesture Classifier Using Propagation-Based Spiking Neural Networks. *IEEE Transactions on Biomedical Circuits and Systems* 14, 6 (2020). doi:10.1109/TBCAS.2020.3031744
- [11] D. Thakur, S. Biswas, E. S. L. Ho, and S. Chattopadhyay. 2022. Attention-Based Sensor Fusion for Human Activity Recognition. *IEEE Sensors Journal* 22, 16 (2022). doi:10.1109/JSEN.2022.3189745
- [12] T. White, M. Green, and S. Blue. 2020. Energy Harvesting for Wearable Medical Devices. *IEEE Transactions on Power Electronics* 35, 10 (2020). doi:10.1109/TPEL.2020.2976543
- [13] J. Wu, H. Sun, and Q. Zhang. 2021. Wearable ECG Monitoring System using CNN. *IEEE Transactions on Biomedical Circuits and Systems* 15, 3 (2021). doi:10.1109/TBCAS.2021.3087654
- [14] Y. Ye et al. 2025. Improving Parkinson's disease management through wearable technology: A cost-benefit perspective. *PubMed* (2025).
- [15] K. Zhang, J. Wang, and Z. Li. 2023. Deep Learning for IMU-Based Human Activity Recognition in Rehabilitation. *IEEE Journal of Biomedical and Health Informatics* 27, 3 (2023). doi:10.1109/JBHI.2022.3221456