



UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Autorizada pelo Decreto Federal nº 77.496 de 27/04/76
Recredenciamento pelo Decreto nº 17.228 de 25/11/2016



PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
COORDENAÇÃO DE INICIAÇÃO CIENTÍFICA

XXIX SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS **SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2025**

Interface para compartilhamento de dados para estimação da caminhada e de padrões de saúde mediante palmilhas eletrônicas instrumentadas

Wesley Ramos dos Santos¹; Armando Sanca Sanca²

1. Wesley Ramos dos Santos, PIBIC/FAPESB, ENGENHARIA DE COMPUTAÇÃO, e-mail: wesleysrw@gmail.com

2. Armando Sanca Sanca, DEPARTAMENTO DE TECNOLOGIA, e-mail: assanca@uefs.br

PALAVRAS-CHAVE: Palmilhas; IMU; STM32; Raspberry Pi; caminhada; aprendizado de máquina.

INTRODUÇÃO

A marcha é o padrão de movimento dos membros humanos durante a locomoção. Esse movimento envolve a alternância entre as fases de apoio e balanço, delimitadas pelos eventos de contato inicial e desprendimento do pé em relação ao solo, compondo o ciclo da passada (Lin, 2016). A fase de apoio, que representa cerca de 62% do ciclo da marcha (Leal Junior, 2018), é marcada por variações na velocidade, impulsos e nas forças de reação do solo, elementos que afetam diretamente a eficiência do movimento e a necessidade de ajustes posturais.


Diante disso, este trabalho propõe o desenvolvimento de um sistema baseado em palmilhas instrumentadas com 16 sensores piezorresistivos, integrado a um microcontrolador STM32H743, responsável pela aquisição, condicionamento, filtragem e transmissão remota dos dados. A partir desses sinais, busca-se estimar a cinemática da marcha utilizando algoritmos de aprendizado de máquina não paramétricos com o objetivo de explorar uma solução não intrusiva, de baixo custo e com potencial de aplicação em ambientes reais.

METODOLOGIA


O sistema desenvolvido é composto por duas placas com o microcontrolador STM32H743VIT6, responsáveis pela aquisição e pré-processamento dos sinais, duas palmilhas FS-INS-16Z1 com 16 sensores piezoresistivos cada, um sensor inercial BNO055 (9 DOF) e um microcomputador Raspberry Pi para comunicação e gerenciamento remoto. Os sinais das palmilhas passam por filtros anti-aliasing de primeira ordem, são digitalizados pelos conversores analógico-digitais do STM32H743 e enviados via comunicação serial à Raspberry Pi, onde são sincronizados, armazenados e transmitidos junto aos dados das IMUs.

O software embarcado destinado ao envio dos dados foi desenvolvido na plataforma STM32CubeIDE, utilizando a configuração automática de periféricos para acelerar o processo de prototipagem. O módulo de coleta, implementado em C e executado na

Raspberry Pi, adota uma arquitetura baseada em *threads* independentes, assegurando a sincronização entre diferentes taxas de aquisição (100 Hz para as IMUs e 1 kHz para as palmilhas). As informações são registradas em arquivos estruturados, contendo metadados e *timestamps*, enquanto a integração com o simulador Coppeliasim possibilita o controle do processo de aquisição e a mitigação de perdas de dados. A Figura 1 (a) mostra o fluxograma do módulo de coleta e a Figura 1 (b) a visualização dos dados salvos após plotados no octave.



(a)



(b)

Figura 1: (a) Fluxograma do funcionamento do software, e (b) trajetórias da caminhada e dados de pressão obtidas.

Com os sinais devidamente adquiridos e estruturados, foram aplicados algoritmos de regressão para estimar os ângulos articulares, já que se tratam de variáveis contínuas. Entre os modelos utilizados destacam-se: k-NN, que estima a saída a partir da média dos vizinhos mais próximos (Cunningham e Delany, 2007); Árvores de Decisão, que realizam partições recursivas no espaço de atributos (Rokach e Maimon, 2005); Random Forest, que combina múltiplas árvores para reduzir erro de generalização (Breiman, 2001); e o Perceptron Multicamadas (MLP), capaz de aprender representações complexas por meio de camadas ocultas (Haykin, 2001). A

implementação foi feita na biblioteca scikit-learn, com apoio de pandas para manipulação de dados e joblib para serialização dos modelos, em ambiente Google Colab.

RESULTADOS E/OU DISCUSSÃO

Os dados de treinamento foram coletados de um único indivíduo e representavam trajetórias de ciclos de marcha. Esse conjunto reuniu informações das IMUs e das palmilhas instrumentadas, organizadas em um dataframe com a biblioteca pandas. Para o teste, utilizaram-se apenas os dados das palmilhas, removendo-se as colunas referentes às medições articulares das IMUs.

Durante a inferência, os modelos receberam exclusivamente os dados das palmilhas para estimar, de forma independente, as trajetórias angulares de cada articulação. A coleta de um único participante buscou maior precisão para aplicação em uma órtese ativa de joelho, não sendo objetivo a criação de um modelo generalizável, mas sim a análise do desempenho dos algoritmos k-NN, MLP, árvore de decisão e Random Forest na regressão dos ângulos articulares.

A Figura 2 apresenta o resultado do rastreamento das trajetórias estimadas para os ângulos do quadril, joelho e tornozelo, obtido pelo modelo de floresta aleatória que obteve o melhor resultado.




Figura 2: Rastreamento das trajetórias dos ângulos do quadril, joelho e tornozelo estimados pelo algoritmo de floresta aleatória.

A Tabela 1 apresenta os erros quadráticos médios (RMSE) na estimativa dos ângulos articulares. A Floresta Aleatória destacou-se pela robustez, apresentando os menores erros: $0,5977^\circ$ (quadril), $2,1656^\circ$ (joelho) e $1,5966^\circ$ (tornozelo), superando os demais modelos. A Rede Neural Artificial/MLP apresentou bom desempenho para o quadril

(3,8664°), mas inferior para joelho e tornozelo, enquanto o k-NN obteve o maior erro no tornozelo (13,8734°). A Árvore de Decisão apresentou desempenho intermediário, com 6,2380° no joelho e 6,1409° no tornozelo.

Tabela 1. Resultados do RMSE obtidos para cada modelo em graus.

RMSE	k-NN	RNA	Árvore de decisão	Floresta aleatória
Hip	4,0011°	3,8664°	4,4402°	0,5977°
Knee	10,7709°	9,7343°	6,2380°	2,1656°
Ankle	13,8734°	8,2947°	6,1409°	1,5966°

CONSIDERAÇÕES FINAIS

Neste estudo, investigou-se o uso de palmilhas instrumentadas para análise da marcha humana, por meio de quatro modelos de aprendizado de máquina. Com sinais de IMUs e sensores piezoresistivos, foi possível estimar as trajetórias angulares dos membros inferiores sem sensores adicionais. A Floresta Aleatória apresentou o melhor desempenho, embora ruídos nas predições tenham sido observados, possivelmente devido a limitações dos algoritmos, escolha de hiperparâmetros e número reduzido de amostras.

Futuramente, podem ser aplicadas técnicas de filtragem que preservem características individuais dos sinais e ampliada a base de dados para melhorar a acurácia. As trajetórias geradas servirão como referência para o controle de uma órtese ativa de joelho em desenvolvimento no Laboratório de Processamento de Sinais do DTEC/UEFS. O estudo evidencia o potencial de modelos de regressão não paramétricos em aplicações como controle de órteses inteligentes, tecnologias vestíveis e integração com sistemas de Internet das Coisas Médicas (IoHT).

REFERÊNCIAS

- LIN, F. et al. 2016. Smart insole: A wearable sensor device for unobtrusive gait monitoring in daily life. *IEEE Trans. Ind. Informat.*, 12(6):2281–2291.
- CUNNINGHAM, P.; DELANY, S. 2007. k-nearest neighbour classifiers. *Mult Classif Syst*, 54.
- LEAL-JUNIOR, A.G. et al. 2018. Polymer optical fiber for in-shoe monitoring of ground reaction forces during the gait. *IEEE Sens. J.*, 18(6):2362–2368.
- DUONG, T.T.H. et al. 2022. Ecological validation of machine learning models for spatiotemporal gait analysis in free-living environments using instrumented insoles. *IEEE Robot. Autom. Lett.*, 7(4):10834–10841.
- HAYKIN, S. 2001. Redes Neurais: Princípios e Prática. Bookman Editora.
- BREIMAN, L. 2001. Random Forest. 45:5–32.
- ROKACH, L.; MAIMON, O. 2005. Decision Trees. 6:165–192.