

Interface para Monitoramento da Marcha Antropomórfica a Tempo Real por Palmilhas Piezorresistivas Instrumentadas

Wesley Ramos dos Santos¹, Armando S. Sanca (*Orientador*)¹

¹ Departamento de Tecnologia
Curso de Engenharia de Computação
Universidade Estadual de Feira de Santana (UEFS)
44036-900 - Feira de Santana, BA - Brasil

wesleysrw@gmail.com, armando@ecomp.uefs.br

Abstract. *This work presents an interface for monitoring anthropomorphic gait, with estimation and analysis of movement kinematics based on data collected by sixteen prefabricated piezoresistive sensors arranged in insoles. The instrumented system also includes six inertial measurement units attached to the articular segments of the lower limbs, enabling the tracking of joint trajectories. For the estimation of these trajectories, four non-parametric machine learning computational models were evaluated: k-NN, ANN, decision tree, and random forest. The results demonstrate the feasibility of applying pattern classification-based models to estimate joint angles, with potential applications in driving active orthosis joints or rehabilitation devices.*

Resumo. *Neste trabalho, apresenta-se uma interface para o monitoramento da marcha antropomórfica, com estimação e análise da cinemática do movimento a partir de dados coletados por dezesseis sensores piezorresistivos pré-fabricados, dispostos em palmilhas. O sistema instrumentado também inclui seis unidades de medida inercial fixadas aos segmentos articulares dos membros inferiores, permitindo o rastreamento das trajetórias das articulações. Para a estimação dessas trajetórias, foram determinados quatro modelos computacionais de aprendizado de máquinas não paramétricas: k-NN, RNA, árvore de decisão e floresta aleatória. Os resultados demonstram a viabilidade da aplicação de modelos baseados em classificação de padrões, que podem ser utilizados no acionamento de juntas de órteses ativas ou em dispositivos de reabilitação.*

1. Introdução

A marcha humana, ou locomoção bípede, é um processo cíclico e complexo que possibilita o deslocamento do corpo, mediado pela interação entre os sistemas neuromuscular e esquelético. Esse movimento é caracterizado pela alternância entre as fases de apoio e balanço em cada membro inferior, delimitadas pelos eventos de contato inicial (calcanhar) e desprendimento (dedos) do pé com o solo (ciclo de passada) [Lin et al. 2016]. Durante o intervalo de apoio (aproximadamente 62% do ciclo da marcha) [Leal-Junior et al. 2018], observam-se variações na velocidade, impulsos e forças de reação do solo, as quais refletem exigências de manobra e eficiência energética. A distribuição da pressão plantar e a cinemática da marcha são diretamente influenciadas pela dinâmica articular - posição,

velocidade e aceleração dos segmentos dos membros inferiores. Além disso, alterações nos padrões de marcha constituem indicadores precoces de comorbidades crônicas, como acidente vascular cerebral (AVC), demência, doença de Parkinson, câncer, cardiopatias e diabetes [Hao et al. 2020]. Tais alterações decorrem de compensações neuromusculares ou degenerações estruturais, que modificam a dinâmica articular e, conseqüentemente, os padrões de pressão plantar.

O monitoramento e a análise da marcha possuem aplicações multidisciplinares, abrangendo áreas como medicina, esportes, geriatria, reabilitação e diagnóstico. Tradicionalmente, a precisão dessas análises depende de medições realizadas em laboratórios especializados, equipados com sistemas de câmeras de alta resolução, sensores corporais, esteiras instrumentadas e unidades de processamento integradas - recursos que, embora ofereçam alta acurácia, envolvem custos elevados [Antoniou et al. 2023]. No entanto, essas metodologias apresentam limitações críticas: 1. Restrições espaciais e temporais, os dados coletados em ambientes controlados nem sempre refletem a marcha natural do paciente em seu cotidiano, comprometendo a validade clínica dos diagnósticos. 2. Complexidade operacional, sistemas baseados em múltiplas câmeras exigem processos de pós-análise demorados, enquanto esteiras instrumentadas não reproduzem contextos reais de caminhada ou fornecem alertas preventivos para quedas. 3. Barreiras de acesso, o alto custo e a necessidade de infraestrutura especializada tornam esses métodos inviáveis para idosos com mobilidade reduzida, especialmente em regiões com poucos centros de referência - como muitas cidades do interior da Bahia. Diante desses desafios, torna-se urgente o uso de soluções acessíveis que permitam o monitoramento remoto da marcha, combinando praticidade, confiabilidade e inclusão. Tal abordagem seria particularmente relevante para a população idosa, garantindo acompanhamento contínuo sem a necessidade de deslocamentos dispendiosos.

O avanço de sensores vestíveis e da Internet das Coisas para a Saúde (*Internet of Health Things* - IoHT), tem democratizado a análise da marcha, possibilitando monitoramento em ambientes naturais e confortáveis, superando as limitações do ambiente laboratorial. Estudos recentes ilustram esse progresso, por exemplo, em [Chen et al. 2020] propuseram um sistema de palmilha instrumentada que extrai vinte seis parâmetros clínicos da marcha, aplicando o conceito de “marcha baseada em termos de atividades da vida diária” para maior relevância clínica. No entanto, em [Nguyen et al. 2018], utilizaram dados de pressão plantar e algoritmos k-NN para classificar cinco atividades ambulatoriais - caminhada em terreno plano, descida de rampa, subida de rampa, descida de escada e subida de escada. O tempo da passada, comprimento e a velocidade da marcha, validando a aplicação em ecossistemas reais, foram propostos usando um modelo SVM em [Duong et al. 2022]. Já os parâmetros cinemáticos, cinéticos e trajetórias do centro de pressão a partir da distribuição plantar foram estimados em [Zhang et al. 2017], com o sistema denominado SportSole. Em [Ansah et al. 2023] combinaram palmilhas instrumentadas com IMUs para detecção contínua de passos arrastados, auxiliando no diagnóstico precoce de doença de Parkinson.

Este trabalho propõe uma solução de interface para compartilhamento de dados destinada à estimação da marcha empregando palmilhas pré-fabricadas e instrumentadas. O sistema foi projetado para ser não intrusivo e de fácil adoção no cotidiano, permitindo sua inserção em calçados convencionais como uma palmilha comum. As informações

dinâmicas durante todas as fases da marcha são capturados a tempo real a partir de dezesseis sensores piezorresistivos, condicionadas, filtradas, convertidas e pré-processadas por um microcontrolador STM32H743, para posteriormente serem compartilhados via interface remota para análise em um computador. A cinemática da marcha antropomórfica é estimada utilizando quatro algoritmos de aprendizado de máquina não paramétricos: *k*-vizinhos mais próximos, (*k* *Nearest Neighbors* - *k*-NN), Rede Neural Artificial (RNA), árvore de decisão e floresta aleatória. O desenvolvimento do sistema será detalhado nas seguintes seções: Metodologia, descrição dos materiais, configuração experimental e técnicas de processamento de dados; Resultados e Discussões, análise comparativa do desempenho dos algoritmos e validação dos modelos, e Conclusão, implicações práticas, limitações e direcionamentos futuros.

2. Metodologia

A Figura 1 ilustra a arquitetura do sistema de aquisição desenvolvido para: supervisão remota da marcha antropomórfica, treinamento de modelos de aprendizado de máquina, regressão e análise qualitativa dos modelos para estimação da marcha.

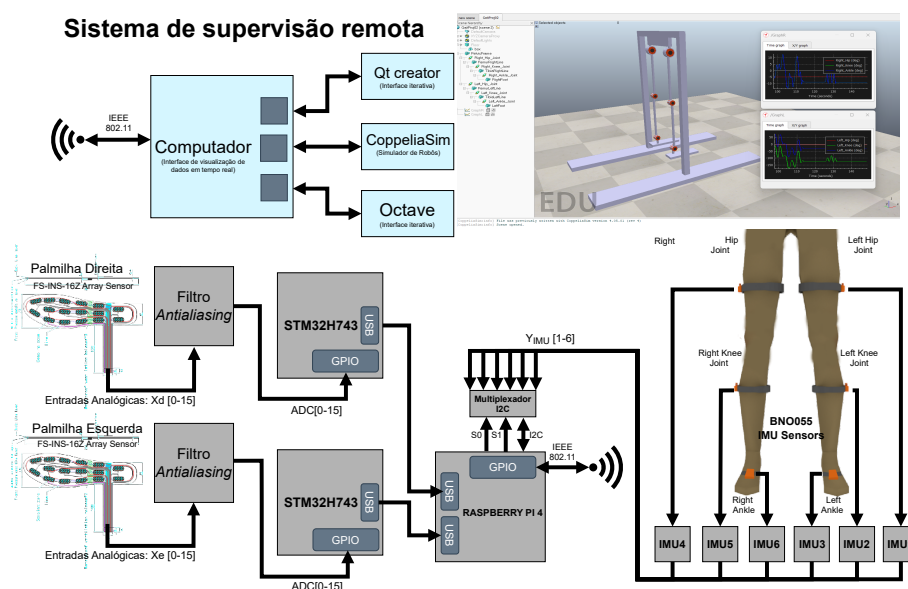


Figura 1. Diagrama em blocos do sistema de hardware implementado.

2.1. Módulo de hardware desenvolvido

Palmilhas modelo FS-INS-16Z¹ foram instrumentadas para capturar sinais provenientes de dezesseis pontos de pressão piezorresistivos, os quais foram condicionados e limitados em banda por filtros *antialiasing* de primeira ordem, como etapa inicial da montagem do protótipo. Em seguida, os sinais analógicos foram digitalizados pelos dezesseis Conversores Analógico-Digital (CAD) do microcontrolador STM32H743² para posterior compartilhamento com o sistema embarcado Raspberry PI4. Conforme ilustrado na Figura 1, também foi implementada a aquisição de dados de seis Unidades de Medida Inerciais (*Inertial Measurement Units* - IMUs), cujos sinais foram compartilhados

¹Legact@<https://film-sensor.com/product/pressure-mapping-fs-ins-16z>

²STMicroelectronics@<https://www.st.com>

via barramento I²C multiplexado. Os microcontroladores foram programados utilizando a plataforma STM32CubeIDE, desenvolvida pela STMicroelectronics®, fabricante dos microcontroladores STM. O microcontrolador STM32H743 incorpora uma CPU Arm Cortex®-M7 de 480MHz com FPU e três CADs SAR (ADC1, ADC2 e ADC3, com até 20 canais analógicos cada), oferecendo resoluções de até 16 bits e taxas de amostragem entre 3,6MSps até 7,1MSps. Para este projeto, foram utilizados 16 canais analógicos dos conversores ADC1 e ADC3, configurados com DMA (*Direct Memory Access*) de resoluções de 14 bits. Para garantir o tempo de conversão adequado, um temporizador interno (TIM3) foi utilizado para gerenciar a sinalização de fim de conversão dos 16 CADs, com uma taxa de 387,5 ciclos do clock do processador de 240MHz.

Contudo, no contexto desta pesquisa, que se centra na análise da marcha humana, conforme referido em [Aggarwal et al. 2018], a maioria dos movimentos corporais ocorre numa faixa de frequência até 15Hz por ciclo de marcha. Assim, optou-se por uma taxa de aquisição síncrona e estável de até 1kHz para os dados capturados pelas palmilhas instrumentadas.

Visando obter os ângulos das articulações dos membros inferiores (conforme Figura 1), estimados com base nos dados adquiridos pelas palmilhas instrumentadas, este projeto também utilizou seis sensores IMU BNO055³, configurados modo de fusão de dados com saída em ângulos de Euler, os quais geram uma taxa de atualização de 100Hz. Os dados são recebidos via barramento I²C multiplexado, gerenciado pela Raspberry Pi4. Apesar da baixa frequência dos IMUs, a coleta desses dados foram retidos e sincronizados para garantir uma taxa de amostragem de 1kHz, escolhida como padrão para o processamento do volume de dados. Posteriormente, os dados organizados na Raspberry PI4 são disponibilizados via API remota para serviços com interfaces desenvolvidas no simulador de robôs CoppeliaSim®⁴, no Qt Creator⁵ e no Octave®⁶.

2.2. Módulo de software desenvolvido

Na Figura 2, apresenta-se um fluxograma que descreve a arquitetura do código desenvolvido. A aquisição dos dados ocorre em **threads independentes**, com as informações de cada sensor sendo armazenadas em variáveis globais auxiliares. Dessa forma, mesmo quando uma das threads não tiver recebido uma nova amostra, o processo principal continua utilizando o último valor disponível, evitando assim bloqueios e problemas de sincronização decorrentes das diferentes taxas de aquisição entre os IMUs (100Hz) e as palmilhas (1kHz).

A operação do sistema está condicionada à conexão com o ambiente de simulação CoppeliaSim, mantendo-se ativa enquanto o simulador estiver em funcionamento. Essa abordagem permite o encerramento controlado da coleta de dados diretamente através da interface do simulador, prevenindo interrupções abruptas no terminal supervisor quanto a possíveis perdas de dados. Embora os dados sejam recebidos de forma independente no código, todos são posteriormente concatenados e armazenados em um único arquivo estruturado, contendo metadados com o número total de amostras e os respectivos timestamps em segundos. Devido à taxa de amostragem limitada dos sensores BNO055

³Bosch Sensortec GmbH <https://www.bosch-sensortec.com>

⁴Coppelia Robotics AG <https://www.coppeliarobotics.com>

⁵The Qt Company <https://www.qt.io>

⁶GNU Octave <https://www.octave.org>

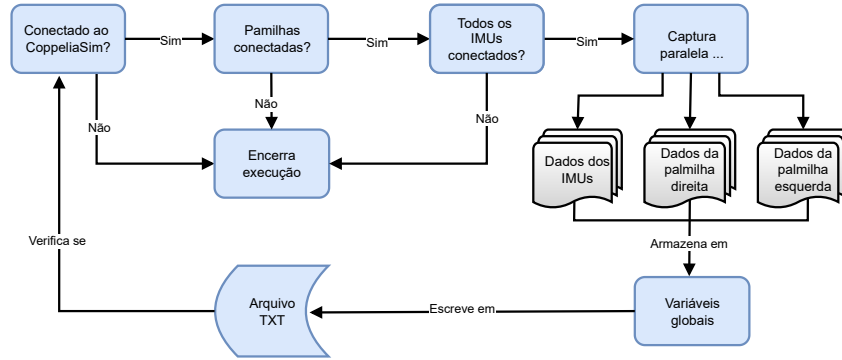


Figura 2. Fluxograma da recepção de dados.

(100Hz), foi necessária a implementação de threads dedicadas para a aquisição dos dados das palmilhas, garantindo assim a taxa de atualização global desejada de 1kHz. Dessa forma, a coleta dos dados ocorre de maneira assíncrona e paralela, com um buffer de até 10 amostras dos IMUs, para manter a sincronização sem comprometer o desempenho dos CADs.

2.3. Algoritmos utilizados para estimação das trajetórias angulares

Classificação e regressão constituem abordagens fundamentais para tarefas preditivas em mineração de dados. Enquanto técnicas de classificação são empregadas para categorizar sinais em rótulos discretos, os métodos de regressão são mais adequados para prever trajetórias contínuas ou sequências numéricas. Neste trabalho, as trajetórias angulares das articulações, capturadas pelas IMUs, juntamente com os dados das palmilhas instrumentadas, foram utilizadas para desenvolver modelos não determinísticos por meio dos seguintes algoritmos: k-NN, RNA, árvore de decisão e floresta aleatória. O principal objetivo consiste em estimar padrões de marcha antropomórfica (cinemática do movimento) utilizando exclusivamente dados provenientes das palmilhas instrumentadas. Para isso, sejam os sinais $x_{ei} \in \mathbb{R}$ e $x_{di} \in \mathbb{R}$, com $i = 0, \dots, 15$, oriundos das palmilhas esquerda e direita, respectivamente, e sejam os sinais $y_{IMU_i} \in \mathbb{R}$, com $i = 1, \dots, 6$, correspondentes aos ângulos de Euler obtidos das seis IMUs, no plano sagital. O algoritmo k-NN é um dos métodos de classificação de padrões não paramétricos mais conhecidos e amplamente usados. Considerando os sinais $\mathbf{x} = [x_{e0}, x_{e1}, \dots, x_{e15}, x_{d0}, x_{d1}, \dots, x_{d15}]' \in \mathbb{R}^{32}$ e $\mathbf{y} = [y_{IMU1}, y_{IMU2}, \dots, y_{IMU6}]' \in \mathbb{R}^6$ (onde $'$ denota o operador transposto), a ideia central de regressão via k-NN inicia-se com a escolha do hiperparâmetro k , que representa a quantidade de vizinhos mais próximos a serem identificados nos dados de entrada/saída. Esses vizinhos são então usados para determinar a classe da consulta com base em métricas de similaridade (distância) [Cunningham and Delany 2007].

O algoritmo de árvore de decisão é um classificador expresso como uma partição recursiva do espaço de instâncias, começando pela raiz e formando uma estrutura hierárquica composta por nós internos e folhas [Rokach and Maimon 2005]. Já o algoritmo de floresta aleatória [Breiman 2001] combina múltiplos preditores baseados em árvores de decisão, em que cada árvore depende de um vetor aleatório amostrado independentemente - com a mesma distribuição para todas as árvores da floresta. O erro de generalização da floresta converge à medida que o número de árvores aumenta, e seu de-

sempenho depende da robustez das árvores individuais e da correlação entre elas. Por fim, a RNA Perceptron Multicamadas (*Multilayer Perceptron* - MLP), inspirada no sistema nervoso biológico, consiste em um arranjo de unidades sensoriais distribuídas em camadas de entrada, ocultas e de saída. Devido à sua capacidade de resolver problemas numericamente complexos por meio de aprendizado supervisionado, tornou-se uma ferramenta popular em aplicações avançadas [Haykin 2001].

Para determinar os modelos, recorreremos à biblioteca de aprendizado de máquina `scikit-learn`, de código aberto, para a linguagem de programação Python - amplamente adotada em análises de dados e modelagem preditiva. Essa biblioteca oferece um extenso conjunto de ferramentas para tarefas como classificação, regressão e agrupamento, além de integração com outras bibliotecas científicas, como `NumPy`, `SciPy` e `matplotlib`, o que a torna eficiente e de fácil utilização. Entre as principais funcionalidades da biblioteca `scikit-learn`, destacam-se as implementações de algoritmos de aprendizado supervisionado e não supervisionado, incluindo regressão linear, máquinas de vetor de suporte (*Support Vector Machines* - SVM), árvores de decisão e `k-means`; ferramentas para pré-processamento de dados, como normalização, padronização e transformação de características; além de recursos para avaliação e validação de modelos, incluindo validação cruzada, métricas de erro e matrizes de confusão.

O treinamento dos modelos foi realizado na plataforma Google Colab, um ambiente gratuito baseado em nuvem que permite escrever e executar código Python diretamente no navegador por notebooks Jupyter. Além da biblioteca `scikit-learn`, foram empregadas as seguintes ferramentas: `pandas`, para criação e manipulação dos *dataframes* utilizados no processo de treinamento; e `joblib`, para serialização e armazenamento dos modelos, possibilitando a reutilização de modelos pré-treinados para realização de inferências.

3. Resultados e Discussões

Os dados utilizados para treinamento consistiram em dois conjuntos de amostras coletados de um único indivíduo, representando trajetórias de ciclos de marcha (Figura 3). O conjunto de treinamento foi composto exclusivamente por dados dos sensores inerciais (IMUs) e das palmilhas, previamente organizados em um *dataframe* utilizando a biblioteca `pandas` (entre três e dez ciclos de marcha). Já no conjunto de teste, as colunas correspondentes às medições articulares dos IMUs foram removidas, mantendo-se apenas os dados das palmilhas. A Figura 3 ilustra dados das palmilhas para inferência com apenas três ciclos de marcha para comparação.

Na etapa de inferência, utilizou-se um terceiro conjunto de amostras do mesmo indivíduo, no qual os modelos receberam como entrada apenas os dados das palmilhas. Com base nessas informações, foram estimadas separadamente as trajetórias de cada junta articular.

A coleta de dados foi restrita a um único indivíduo, visando obter o modelo mais preciso, capaz de estimar trajetórias angulares. Essas trajetórias seriam utilizadas no acionamento de uma órtese ativa de joelho para membros inferiores. O estudo não teve como finalidade desenvolver um modelo geral, mas sim analisar o desempenho dos algoritmos `k-NN`, RNA, árvore de decisão e floresta aleatória.

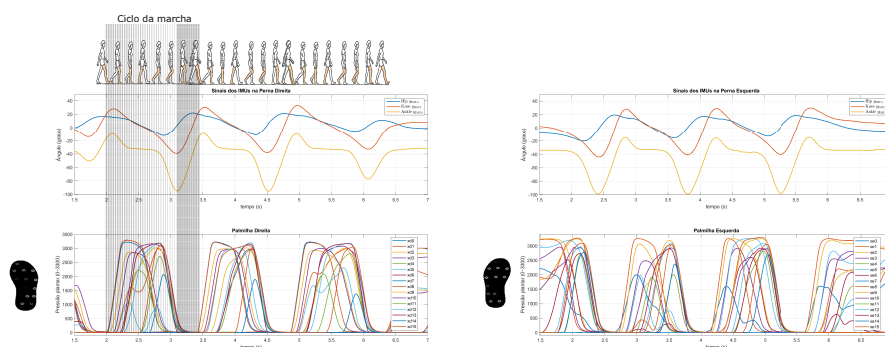


Figura 3. Trajetórias de caminhada obtidas pelas palmilhas direita/esquerda e IMUs.

As Figuras 4, 5, 6 e 7 ilustram os resultados de rastreamento das trajetórias estimadas para os ângulos do quadril, joelho e tornozelo pelos algoritmos k-NN, RNA, árvore de decisão e floresta aleatória, respectivamente.




Figura 4. Rastreamento de trajetórias dos ângulos do quadril, joelho e tornozelo estimados pelo algoritmo k-NN.

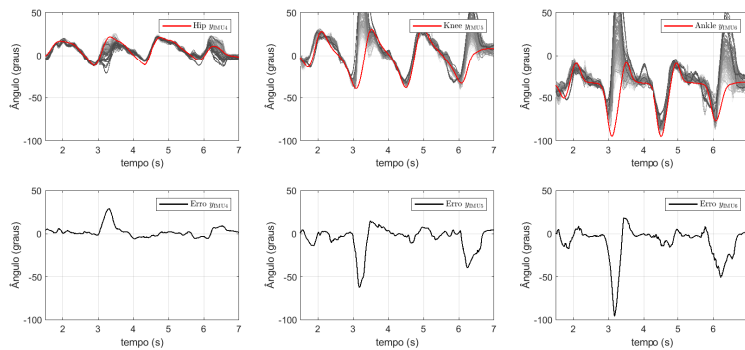


Figura 5. Rastreamento de trajetórias dos ângulos do quadril, joelho e tornozelo estimados pelo algoritmo RNA.




Figura 6. Rastreamento de trajetórias dos ângulos do quadril, joelho e tornozelo estimados pelo algoritmo de árvore de decisão.




Figura 7. Rastreamento de trajetórias dos ângulos do quadril, joelho e tornozelo estimados pelo algoritmo de floresta aleatória.

Tabela 1. Valores de RMSE (em graus) para cada modelo na estimativa dos ângulos articulares.

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°

A Tabela 1 mostra que o modelo de floresta aleatória obteve os menores erros (RMSE) na estimação dos ângulos articulares: 0,5977° (quadril), 2,1656° (joelho) e 1,5966° (tornozelo), destacando-se como o mais adequado para a tarefa.

A RNA teve bom desempenho no quadril (3,8664°), superando levemente o k-NN (4,0011°) e a árvore de decisão (4,4402°). No entanto, tanto a RNA quanto o k-NN apresentaram erros maiores no joelho e tornozelo, com o k-NN atingindo 13,8734° no tornozelo.

A árvore de decisão teve desempenho intermediário no joelho (6,2380°) e tornozelo (6,1409°), superando a RNA e o k-NN nessas articulações, mas ainda abaixo do algoritmo de floresta aleatória.

Os resultados confirmam o melhor desempenho do algoritmo de floresta aleatória

e reforçam a viabilidade de métodos de aprendizado de máquina não paramétricos na análise biomecânica, mesmo diante de desafios como poucas amostras e ruídos nos dados.

Os melhores hiperparâmetros indicam que a floresta aleatória obteve os melhores resultados ao usar `criterion=friedman_mse`, `min_samples_leaf=1`, `min_impurity_decrease=0` para *hip* e *knee*, e 0,5 para *ankle*, com `ccp_alpha=0` e `random_state` fixos. A árvore de decisão adotou `criterion=squared_error`, `splitter` variando entre `best` e `random`, `min_samples_leaf` de 1 ou 5, e `min_impurity_decrease=0,25`. O k-NN obteve melhor desempenho com `n_neighbors` 10 para *hip* e 20 para *knee* e *ankle*, `weights` `distance` ou `uniform`, e métrica `manhattan`. A RNA usou entre 25 e 100 neurônios, ativação `logistic` ou `tanh`, otimizador `sgd` e `alpha` entre 0,0001 e 0,001.

Esses ajustes específicos mostram que o algoritmo de floresta aleatória é mais robusta e precisa na estimação dos ângulos articulares, enquanto a árvore de decisão, k-NN e RNA apresentam maior sensibilidade e erros, principalmente no *ankle*.

Durante o desenvolvimento deste trabalho, foram alcançados resultados significativos, demonstrando que é possível estimar a cinemática do movimento dos membros inferiores durante a marcha utilizando apenas os dados gerados pela palmilha instrumentada.

Observou-se que um modelo devidamente treinado, com o auxílio dos dados provenientes da palmilha e de três IMUs posicionados em cada perna, consegue acompanhar os movimentos de um determinado indivíduo. Com base nos pontos de pressão detectados pela palmilha, é possível inferir o processo da marcha, ainda que, no momento, a estimativa esteja limitada aos ângulos articulares.

4. Conclusão

Neste trabalho, explorou-se a utilização de palmilhas instrumentadas para análise da marcha humana por meio do treinamento de quatro modelos distintos de aprendizado de máquina. Com base em sinais provenientes de IMUs e sensores piezorresistivos embutidos nas palmilhas, demonstrou-se a viabilidade de estimar as trajetórias angulares dos membros inferiores durante a marcha, sem a necessidade de sensores adicionais.

Os resultados revelaram que o modelo de floresta aleatória obteve o melhor desempenho, apresentando erros significativamente menores comparados aos demais modelos avaliados. Entretanto, observou-se a presença de ruídos nas predições, possivelmente decorrentes: (i) do desempenho intrínseco dos algoritmos, (ii) da seleção de hiperparâmetros, e (iii) do possível número limitado de amostras de trajetórias.

Como perspectivas futuras, recomenda-se: a aplicação de técnicas de filtragem que preservem as características individuais dos dados, e a ampliação do conjunto de amostras para otimizar o erro de rastreamento. Além disso, as trajetórias estimadas serão usadas como sinais de referência para o acionamento e controle de uma órtese ativa de joelho projetada no Laboratório de Processamento de Sinais do DTEC/UEFS.

Este estudo confirma avanços significativos na aplicação de modelos de regressão não paramétricos para estimativa cinemática da marcha, demonstrando potencial para: controle inteligente de órteses ativas, otimização de dispositivos vestíveis e integração com sistemas de IoHT.

Referências

- Aggarwal, A., Gupta, R., and Agarwal, R. (2018). Design and development of integrated insole system for gait analysis. In *Proceedings of the 2018 Eleventh International Conference on Contemporary Computing (IC3)*, pages 2–4, Noida, India. IEEE. © 2018 IEEE.
- Ansah, S., Olugbon, F., Arthanat, S., LaRoche, D., and Chen, D. (2023). Smart insole based shuffling detection system for improved gait analysis in parkinson’s disease. In *2023 IEEE 19th International Conference on Body Sensor Networks (BSN)*, pages 1–6, Durham, USA. IEEE.
- Antoniou, N., Hadjiantonis, A., Kyriacou, C., and Konstantinidis, A. (2023). A cost effective smart insole system for real time gait analysis. In *2023 IEEE SENSORS*, pages 979–8.
- Breiman, L. (2001). *Random Forest.*, volume 45, pages 5–32.
- Chen, D., Cai, Y., Qian, X., Ansari, R., Xu, W., Chu, K.-C., and Huang, M.-C. (2020). Bring gait lab to everyday life: Gait analysis in terms of activities of daily living. *IEEE Internet of Things Journal*, 7(2):1298–1307.
- Cunningham, P. and Delany, S. (2007). k-nearest neighbour classifiers. *Mult Classif Syst*, 54.
- Duong, T. T. H., Uher, D., Montes, J., and Zanotto, D. (2022). Ecological validation of machine learning models for spatiotemporal gait analysis in free-living environments using instrumented insoles. *IEEE Robotics and Automation Letters*, 7(4):10834–10841.
- Hao, Z., Cook, K., Canning, J., Chen, H.-T., and Martelli, C. (2020). 3-d printed smart orthotic insoles: Monitoring a person’s gait step by step. *Sensor Integration*, 4(1).
- Haykin, S. (2001). *Redes Neurais: Princípios e Prática*. Bookman Editora.
- Leal-Junior, A. G., Frizera, A., Avellar, L. M., Marques, C., and Pontes, M. J. (2018). Polymer optical fiber for in-shoe monitoring of ground reaction forces during the gait. *IEEE Sensors Journal*, 18(6):2362–2368.
- Lin, F., Wang, A., Zhuang, Y., Tomita, M. R., and Xu, W. (2016). Smart insole: A wearable sensor device for unobtrusive gait monitoring in daily life. *IEEE Transactions on Industrial Informatics*, 12(6):2281–2291.
- Nguyen, N. D., Bui, D. T., Truong, P. H., and Jeong, G.-M. (2018). Classification of five ambulatory activities regarding stair and incline walking using smart shoes. *IEEE Sensors Journal*, 18(13):5422–5428.
- Rokach, L. and Maimon, O. (2005). *Decision Trees*, volume 6, pages 165–192.
- Zhang, H., Zanotto, D., and Agrawal, S. K. (2017). Estimating cop trajectories and kinematic gait parameters in walking and running using instrumented insoles. *IEEE Robotics and Automation Letters*, 2(4):2159–2166.