

03 A 06  
DE NOVEMBRO

## Estudo e implementação de técnicas de visualização de dados aplicadas a dados de movimentos do corpo humano

Henrique Zanette de Souza (PIBIT/CNPq/Unioeste), Wu Feng Chung (Orientador),  
Alexandre Peiter Ferraz, Weber Shoity Resende Takaki, Huei Diana Lee,  
e-mail: Henrique.souza14@unioeste.br

Universidade Estadual do Oeste do Paraná/Laboratório de Bioinformática/Centro de Engenharias e Ciências Exatas/Foz do Iguaçu, PR.

**Área/subárea:** Ciências Exatas e da Terra/Ciência da Computação.

**Palavras-chave:** biomecânica, sensor inercial, série temporal.

### Resumo

A análise de movimentos corpóreos em espaço tridimensional é fundamental para prevenção, diagnóstico e reabilitação em saúde. Aparatos como sensores inerciais são capazes de coletar estes dados, todavia, a visualização e a interpretação das informações são complexas. O objetivo desse trabalho foi estudar e implementar técnicas de visualização de dados de movimentos do corpo e associar ao Sistema de monitoramento de movimentos e análise remota em telemedicina (SMMAR-T). Três técnicas foram selecionadas, sendo MV1 baseada na representação tridimensional dos movimentos, MV2 na representação tridimensional com um eixo fixo em zero e MV3 na comparação de curvas de movimento com saturação de cor proporcional à diferença de amplitude. Para isso, foi necessário, primeiramente, implementar um processo de segmentação automática de ciclos de movimentos baseado em suavização gaussiana ( $\sigma=2, 3, 5$ ). Os resultados mostraram que a segmentação automática, implementada no SMMAR-T, não mostrou diferença estatística nos valores de  $\sigma$ , tanto na comparação entre ângulos obtidos por especialistas e de modo automático ( $p=0,6221$ ), quanto no erro da amplitude ( $p=0,0671$ ). Com isso, a seleção automática de pontos se mostrou efetiva para segmentar ciclos de movimentos otimizando a demarcação manual no processamento de dados capturados pelo acelerômetro. Este módulo é capaz de agilizar o processo de análise de dados volumosos e contribuir para a continuidade da implementação de técnicas de visualização MV1, MV2 e MV3.

### Introdução

A avaliação biomecânica tridimensional (3D) de movimentos humanos é essencial para diagnóstico e prevenção de lesões (World Health Organization, 2001) e o sensor inercial acelerômetro é alternativa promissora para mensurar os múltiplos

**03 A 06  
DE NOVEMBRO**

eixos de movimentos complexos do corpo (Yang & Hsu, 2010). Nesse escopo, o método para monitorar e analisar movimentos de articulações e de partes do corpo (Wu *et al.*, 2019) fundamentou o desenvolvimento do SMMAR-T (Lee *et al.*, 2020). Este sistema *web* faz a leitura de dados biomecânicos captados por sensores inerciais de *smartphones*, gera e compara curvas de movimentos entre indivíduos saudáveis e doentes. Contudo, estas curvas são séries temporais multidimensionais e volumosas, situação que dificulta a visualização e a interpretação de profissionais da saúde. Assim, o objetivo deste trabalho foi estudar e implementar técnicas mais eficazes para agilizar, visualizar e contribuir para as análises de movimentos do corpo humano.

## Material e Métodos

Os materiais usados foram: notebook/Dell/Inspiron/i15-i1100-A58PF, Linguagem de programação Python e biblioteca de visualização de dados Matplotlib 3.10.1 e SMMAR-T. A revisão da literatura foi em bases PubMed, SciELO, Scopus e IEEE Xplore com a expressão: ("visualiz\*" OR "visual analy\*") AND ("data" OR "recorded information") AND ("movement\*" OR "motion\*" OR "body activit\*" OR "body dynamics" OR "biomechanic\*") AND ("human" OR "physical\*") AND ("temporal data" OR "time series") AND ("inertial sensor\*" OR "IMU" OR "accelerometer\*" or "gyroscope\*"). Depois, a técnica de visualização (TV) desenvolvida foi MV1, baseada na representação 3D da trajetória dos movimentos do corpo coletados por acelerômetros e com variáveis eixos X, Y e Z e tempo. Alguns movimentos das articulações ocorrem predominantemente em um plano, sendo o valor da amplitude máxima ínfimo em relação aos outros eixos. Com isso, abordou-se a MV2 que fixa um dos eixos do gráfico em posição zero e MV3 que determina a diferença entre amplitudes máximas de duas coletas utilizando gráficos de linha colorido. Os dados de aceleração foi então convertido para ângulo de inclinação, automaticamente, pelo SMMAR-T através das Equações 1, 2 e 3 e subtraiu-se, ponto a ponto, da primeira coleta com a segunda. O resultado foi normalizado entre 1 (ponto com maior diferença) e 0 (ponto com menor diferença). Ao delinear os gráficos de linha ângulo vs. tempo, os valores normalizados foram utilizados para definir a saturação de cada trecho do gráfico.

$$(1) \quad \theta_x = \arctan\left(\frac{A_x}{\sqrt{A_x^2 + A_z^2}}\right) \quad (2) \quad \theta_y = \arctan\left(\frac{A_y}{\sqrt{A_x^2 + A_z^2}}\right) \quad (3) \quad \theta_z = \arctan\left(\frac{\sqrt{A_x^2 + A_y^2}}{A_z}\right)$$

onde  $A_x$ ,  $A_y$ ,  $A_z$  e  $\theta_x$ ,  $\theta_y$ ,  $\theta_z$  representam, respectivamente, a aceleração nos eixos X, Y e Z, e os ângulos de inclinação nos eixos X, Y e Z.

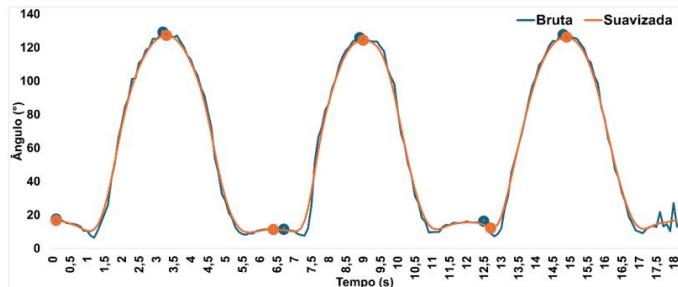
Para desenvolver as técnicas TVs, foi necessário, primeiramente, implementar um processo de segmentação automática de ciclos (SAC) de movimento baseado em suavização gaussiana ( $\sigma=2,3,5$ ) e utilizou-se da derivada da curva para definir os pontos máximos e mínimos e as regiões de interesse. Com isso, as segmentações

**03 A 06  
DE NOVEMBRO**

realizadas por dois especialistas foram comparadas com as da SAC e aplicou-se estatística com intervalo de confiança de 95%. Os dados das curvas foram adquiridos de um sujeito hígido pelo acelerômetro em *smartphone* (Samsung/GalaxyA10s) com SMMAR-T instalado (CEP: 35290820000000107) (Rodrigues *et al.*, 2024). Os movimentos analisados foram flexão e hiperextensão do tronco sentado e ortostático e cada atividade foi repetida por três vezes, totalizando 12 ciclos.

## Resultados e Discussão

A revisão bibliográfica resultou em 23 artigos: um do PubMed, um do SciELO, cinco do Scopus e 16 do IEEE Xplore e dois foram de maior relevância (Rahman *et al.*, 2016, John & Soangra, 2022). Rahman *et al.* (2016) apresentaram um sistema que integrou pulseira de captura de dados com painel de jogo para melhor visualização do desempenho e John & Soangra (2022) usaram sensores com técnica de visualização para distinguir atividades físicas entre adultos saudáveis e com acidente vascular cerebral, com adequado desempenho. Neste trabalho, a seleção da MV1, MV2 e MV3 foram decorrentes ao comportamento das curvas de movimentos realizados neste trabalho, e foi necessário a implementação da SAC no SMMAR-T para resolver o problema de pareamento das curvas comparadas (Wu *et al.*, 2019). Com isso, a SAC dos pontos iniciais e finais de cada ciclo garantiu a comparação de regiões definidas, e este módulo é capaz de agilizar o processo de análise de dados volumosos e contribuir para a continuidade da implementação das técnicas selecionadas. Na Figura 1, está delineado o gráfico com dados de ângulo vs. tempo, brutos e suavizados ( $\sigma = 2$ ), e pontos marcados em flexão ortostática. Na Tabela 1 estão as médias e desvios padrão (DP) da diferença de ângulo e o erro da amplitude definidos por especialistas e pela SAC, com respectivos p-valor para  $\sigma=2, 3$  e  $5$ .



**Figura 1** – Flexão ortostática com demarcações automáticas, em laranja, e dos especialistas, em azul.

O teste de Friedman não mostrou diferença estatística significativa nos  $\sigma$ , tanto na comparação entre ângulos obtidos automaticamente ou por especialistas ( $p=0,6221$ ), quanto no erro da amplitude ( $p=0,0671$ ), indicando que o processo se manteve estável em diferentes níveis de filtragem e reforça a viabilidade em análises que utilizam dados de acelerômetros (Rodrigues *et al.*, 2024).

Tabela 1: Médias, desvios-padrão e p-valor da diferença de ângulo (graus) e erro da amplitude de pontos selecionados (%).

$\sigma$	Diferença Ângulo	Erro da Amplitude em %
2	0,98 (1,46)	1,62 (1,55)
3	0,81 (0,69)	1,44 (1,07)
5	0,77 (0,62)	2,16 (1,64)
p-valor	0,6221	0,0671

O erro médio para  $\sigma=2$  foi de 1,62%, valor considerado reduzido quando tecidos biológicos são biomeanicamente avaliados (Wu *et al.*, 2019). O DP elevado ocorreu, principalmente, devido ao movimento flexão ortostática, pois este apresenta maior variação angular em comparação com outros deslocamentos. Contudo, o uso da SAC reduz esforço manual em demarcações de conjuntos de dados volumosos, benefícios estes encontrados também por Yang & Hsu (2010) com métodos similares. Com inserção do SAC ao SMMAR-T, foi possível iniciar a MV1 que revelou como as acelerações se relacionam e propiciou a visualização e a interpretação do movimento de modo mais próximo à realidade 3D (Neumann, 2017). Alguns movimentos que ocorrem no espaço 3D, se fazem principalmente em um plano e, com isso, ampliou-se os estudos para MV2, focando análises no plano mais relevante do deslocamento. Rodrigues *et al.*, 2024, demonstraram em movimentos da coluna vertebral que a análise de eixos predominantes representa, adequadamente, os deslocamentos desta região, características compartilhadas por Kapandji (2018). A implementação da MV3 utilizou, no gráfico, TV por meio de cores em tons de vermelho para destacar, visualmente, trechos de maior diferença entre as inclinações. Vale destacar que implementações de MV1, MV2 e MV3 e representadas, graficamente, na Figura 2, estão em fase inicial, e serão aperfeiçoados com a continuidade do projeto.

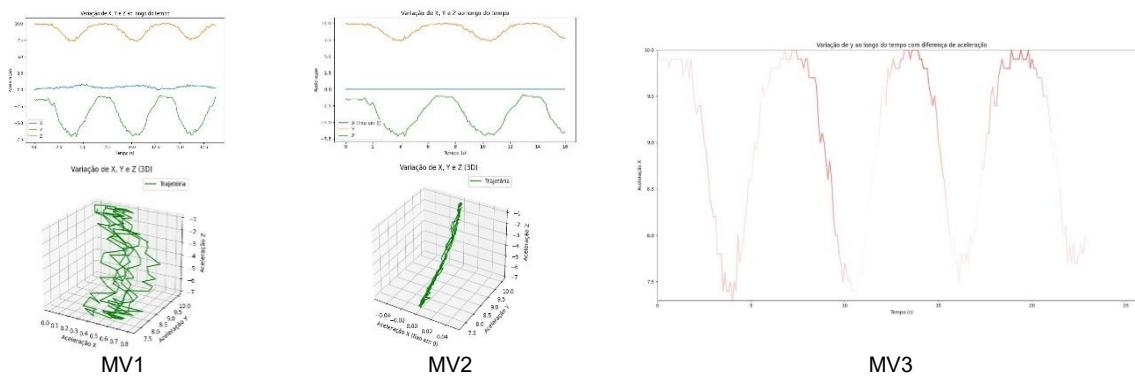


Figura 2 – Técnicas MV1, MV2 e MV3 aplicadas a dados de hiperextensão ortostática do tronco.

03 A 06  
DE NOVEMBRO

## Conclusões

A seleção automática de pontos se mostrou efetiva para segmentar ciclos de movimentos otimizando a marcação manual no processamento de dados capturados pelo acelerômetro e contribui para a continuidade da implementação de técnicas de visualização MV1, MV2 e MV3.

## Agradecimentos

Ao CNPq pela bolsa PIBITI (Edital 03/2024 – PRPPG/Unioeste, Processo 156559/2024).

## Referências

Kapandji, I.A. (2018). Fisiologia Articular: Esquemas Comentados de Mecânica Humana. Vol. 1 e 2. 7. ed. Rio de Janeiro: Guanabara Koogan.

Lee, H. D., Wu, F. C., Spolaôr, N., Ensina, L. A., Takaki, W., Coy, C. S. R. and Rodrigues, M. A. (2020). BR INPI (Registro de software) 51 2020 000583 7. SMMAR-T – Sistema de Monitoramento de Movimentos e Análise Remota em Telemedicina.

John, J. & Soangra, R. (2022). Visualization-Driven Time-Series Extraction from Wearable Systems Can Facilitate Differentiation of Passive ADL Characteristics among Stroke and Healthy Older Adults. *Sensors (Basel)*, **22**(2), 598.

Rahman, M., Kankanhalli, A., Wadhwa, B., Hua, Y. C., Kei, C. K., Hoon, L. J., Jayakkumar, S., Lin, C., et al. (2016). GEAR: A Mobile Game-Assisted Rehabilitation System. In 2016 IEEE International Conference on Healthcare Informatics (ICHI), Chicago, Illinois, Estados Unidos.

Rodrigues, M.A., Ferraz, A.P., Lee, H.D., Spolaôr, N., Takaki, W.S.R., Coy, C.S.R. & Wu, F.C. (2024). Computational analysis of the biomechanics of vertebral column's movements. *Journal of Health Informatics*, **16** (1), 1307.

World Health Organization. (2001). International Classification of Functioning. <https://apps.who.int/iris/handle/10665/42407>. Acesso em 25 set. 2025.

Wu, F.C., Coy, C.S.R., Lee, H.D., Maciejewski, N.R., Ensina, L.A., Takaki, W.S.R. et al. (2019). BR INPI (Patente) 10 2019 015290 7. Método para Monitorar e Analisar Movimentos de Articulações e de Partes do Corpo.

Yang, C.C. & Hsu, Y.L. (2010). A review of accelerometry-based wearable motion detectors for physical activity monitoring. *Sensors*, **10** (8), 7772–7788.