

Uma interface computacional configurável para aquisição e segmentação de repetições na reabilitação física e neurofuncional

Maicon Monttozo Batista¹, José Remo B. Ferreira¹, Alexandre Fonseca Brandão²

¹ Universidade Estadual Paulista "Júlio de Mesquita Filho"
Bauru – SP – Brasil

² Pontifícia Universidade Católica de Campinas
Campinas – SP – Brasil

{maicon.monttozo, remo.brega}@unesp.br, alexandre.brandao@puc-campinas.edu.br

Abstract. *This paper describes how the use of Computer Vision can be applied to the acquisition, organization and segmentation of movement repetitions within a patient session, providing an approach designed to value technical judgment and support specialists in Kinesiology in the treatment of patients undergoing physical and neurofunctional rehabilitation. Rather than being limited to the analysis of the session as a whole, the proposed approach enables the monitoring of individual repetitions, supporting a more detailed understanding of the patient's response to the treatment.*

Resumo. *Este artigo descreve como o uso de Visão Computacional pode ser utilizado para a aquisição, organização e segmentação de repetições de movimentos em uma sessão do paciente, proporcionando uma experiência pensada para valorizar o olhar técnico e apoiar os profissionais em Cinesiologia no tratamento de pacientes em reabilitação física e neurofuncional. A proposta não se limita apenas à análise da sessão como um todo, permitindo acompanhar as repetições de forma individualizada e apoiar a compreensão da resposta ao tratamento.*

1. Introdução

Os modelos de reconhecimento e monitoramento de movimento têm aplicações significativas na área da saúde, especialmente no contexto da medição clínica em reabilitação [Lam et al. 2023]. Nesse sentido, utilizar a visão computacional para transformar sessões em dados auxilia os especialistas em Cinesiologia a medir a execução dos movimentos de forma coerente e quantitativa, permitindo acompanhar mudanças no desempenho ao longo do tempo [Stenum et al. 2024].

Na reabilitação física e neurofuncional, a precisão e a individualização desempenham papéis fundamentais. Cada paciente apresenta desafios diferentes e, nesse cenário, torna-se importante analisar não apenas as sessões de forma bruta, mas também os dados cinemáticos extraídos da execução dos movimentos. Dentro de cada sessão, existem repetições de um determinado movimento articular, que podem apresentar variações [Wagh et al. 2025].

Por exemplo, um paciente pode iniciar uma sessão com uma execução próxima do ideal e, com o tempo, apresentar queda na amplitude do movimento ou aumento da compensação. Quando a sessão é analisada apenas como um todo, essas variações internas podem ser suavizadas ou ocultadas, levando o profissional a interpretar uma melhoria geral que não representa necessariamente todas as repetições executadas [Liu et al. 2025].

A partir desse cenário, este trabalho propõe a segmentação da sessão em repetições individuais, permitindo que cada execução seja analisada separadamente. Com essa segmentação, torna-se possível estabelecer um movimento de referência e comparar repetições dentro da mesma sessão ou entre sessões distintas do paciente, favorecendo uma interpretação mais detalhada e rastreável da execução do movimento durante a intervenção proposta [Ullah et al. 2025].

2. Trabalhos relacionados

Existem diversos pesquisadores em nível mundial que contribuem e exploram o uso da Visão Computacional e da estimativa de pose para auxiliar na captura do movimento em reabilitação física e neurofuncional.

O trabalho de Mu et al. [Mu et al. 2021] sintetiza aplicações computacionais na avaliação da reabilitação, abordando técnicas que permitem o acompanhamento da recuperação do paciente e fornecem informações significativas para o profissional. Existem limitações ligadas à escala dos dados e aos atributos, exigindo grandes volumes de dados para modelar o desempenho e produzir alta precisão preditiva.

Já para Tsai e Huang [Tsai and Huang 2022], os pontos do esqueleto corporal devem ser corrigidos antes da análise do movimento, utilizando a simetria do corpo humano e uma estratégia de restrição de posições incorretas dos pontos. Com essa melhoria, há ganho de desempenho na acurácia dos pontos detectados e no reconhecimento dos movimentos.

No cenário nacional, a pesquisa de Gabriel Rissatti Miguel [Miguel 2024] aborda a captura por vídeo para que a aplicação não dependa de sensores vestíveis que podem ser invasivos para o paciente. Em sua pesquisa é possível verificar que os pontos corporais são capturados por meio do MediaPipe [Google AI Edge 2026]. Complementando essa abordagem, este trabalho direciona a atenção para a organização da sessão em repetições, utilizando uma interface configurável para aquisição dos dados, sincronização das informações e apoio à análise funcional do movimento.

3. Método proposto

Esta proposta foi desenvolvida para um contexto real de reabilitação, em que o profissional precisa analisar a execução do movimento com critérios objetivos. O método adota uma arquitetura simplificada, concentrada na captura ou importação de vídeo, análise da sessão, segmentação automática em repetições e visualização das métricas extraídas. A interface foi implementada em Python, utilizando OpenCV para aquisição, leitura e manipulação dos vídeos, MediaPipe para extração dos pontos corporais por estimativa de pose e banco de dados SQLite para persistência das informações da sessão, dos ângulos calculados e das métricas por repetição [OpenCV 2026, Google AI Edge 2026].

3.1. Aquisição e análise da sessão

O pré-processamento ajusta a orientação com base na média dos primeiros quadros, definindo se alguns ângulos começam próximos de zero ou de cento e oitenta graus. Quando necessário, a curva é invertida para manter a leitura dos dados anatômicos.

Os vídeos capturados ou importados pelo sistema não são arquivados, visando preservar a privacidade dos participantes. A partir dos quadros do vídeo, são extraídos os pontos corporais, calculados o ângulo da articulação do movimento e o ângulo de compensação, e armazenados os dados temporais necessários para a consulta posterior e o acompanhamento organizado da sessão.

3.2. Segmentação automática em repetições

Em seguida, realiza-se uma etapa de recorte automático para otimizar o processamento na região do corpo, seguida de um pequeno alisamento para reduzir tremores sem eliminar pontos de pico. A segmentação por histerese separa a parte de interesse do gesto, preservando um pequeno segmento anterior e posterior para contexto.

Como mostrado na Figura 1, a histerese aplica dois limiares para identificar a região ativa. Os segmentos de *preroll* (margem anterior) e *postroll* (margem posterior) são utilizados para manter a escala de tempo.




Figura 1. Exemplo de curva de ângulo com limites de histerese, ilustrando *preroll*, região útil e *postroll*. Fonte: Autor.

3.3. Métricas extraídas por repetição

Uma vez delimitadas as repetições, cada execução passa a ser representada por atributos como amplitude do movimento principal, amplitude compensatória e duração da repetição. Dessa forma, cada repetição é tratada como uma unidade analítica, permitindo comparar execuções dentro da mesma sessão ou em sessões distintas do paciente.

A análise realizada informa o número de repetições reconhecidas em cada sessão, a duração média, a variação entre mínimos e máximos da articulação em foco e uma medida de proximidade com a referência derivada do alinhamento DTW (Dynamic Time Warping), técnica clássica de alinhamento temporal de sequências [Sakoe and Chiba 1978], também utilizada em estudos recentes de análise de movimento baseada em estimativa de pose humana para fisioterapia [Ullah et al. 2025].

4. Resultados e discussão

Como resultado, a sessão deixa de ser observada apenas em nível global e passa a ser descrita por repetições segmentadas, métricas extraídas e visualizações de apoio à análise funcional.




Figura 2. Gráfico da sessão de um paciente com destaque para as repetições segmentadas. Fonte: Autor.

Conforme pode ser visto na Figura 2, o gráfico de uma sessão possui áreas demarcadas na cor verde, que representam uma repetição de um movimento executado pelo paciente. A linha na cor laranja representa o ângulo do movimento principal em relação ao tempo. Já a linha pontilhada em vermelho apresenta o ângulo de compensação do movimento. No gráfico apresentado, é possível ver que o movimento foi realizado dez vezes pelo paciente.

Na Figura 3, é apresentada a interface do sistema, com a aquisição do movimento por webcam à esquerda e a análise da sessão à direita. A tela de análise exibe o gráfico de uma repetição específica, neste caso a repetição sete da sessão apresentada anteriormente. Nele, a linha azul representa o ângulo do movimento principal ao longo do tempo, a linha verde tracejada indica a repetição adotada como referência para o paciente neste tratamento, e a linha laranja tracejada apresenta o ângulo de compensação.




Figura 3. Interface computacional do eMove para aquisição e análise de sessões de movimento. Fonte: Autor.

Na análise de sessão são apresentadas as repetições em que foi dividida a sessão. Cada linha possui informações para o profissional, apresentando o número da repetição, tempo inicial e final, duração em segundos, amplitude do movimento em graus, graus mínimo e máximo do movimento, amplitude da compensação, graus mínimo e máximo da compensação e dados de comparação com a referência. Dessa forma, o profissional pode navegar entre as repetições realizando a análise funcional do paciente.

5. Conclusão

Conforme apresentado, a Visão Computacional pode apoiar profissionais da saúde (especialistas em Cinesioterapia) na análise do movimento em contextos de reabilitação física e neurofuncional. A proposta organiza a aquisição e a análise dos dados, permitindo que a sessão seja segmentada em repetições e interpretada a partir de métricas como amplitude do movimento, compensação, duração e comparação com referência. Dessa forma, a

abordagem contribui para a quantificação padronizada dos dados cinemáticos e para uma leitura mais detalhada da execução do movimento durante a intervenção proposta.

Como etapa futura, serão realizados testes clínicos com profissionais da saúde e pacientes, a fim de validar as métricas extraídas pela interface em contexto real de reabilitação. Essa validação será importante para verificar a aderência dos dados gerados à avaliação da evolução funcional e para apoiar a elaboração de relatórios de acompanhamento aos envolvidos no tratamento.

6. Referências

Referências

- Google AI Edge (2026). Pose landmark detection guide. MediaPipe Solutions. Acesso em: 6 jun. 2026.
- Lam, W. W. T., Tang, Y. M., and Fong, K. N. K. (2023). A systematic review of the applications of markerless motion capture (mmc) technology for clinical measurement in rehabilitation. *Journal of NeuroEngineering and Rehabilitation*, 20(1):57.
- Liu, C., Mitarai, S., Suzuki, K., Ueshima, H., Okahashi, S., Kuroda, T., and Yamamoto, G. (2025). Video-based compensatory movement assessment for supporting upper limb rehabilitation evaluation. In *Studies in Health Technology and Informatics*, volume 329, pages 1044–1048.
- Miguel, G. R. (2024). Uma combinação da visão computacional e inteligência artificial para analisar movimentos em apoio à reabilitação de pacientes pós acidente vascular cerebral.
- Mu, P., Dai, M., and Ma, X. (2021). Application of artificial intelligence in rehabilitation assessment. *Journal of Physics: Conference Series*, 1802(3):032057.
- OpenCV (2026). Opencv documentation. Acesso em: 6 jun. 2026.
- Sakoe, H. and Chiba, S. (1978). Dynamic programming algorithm optimization for spoken word recognition. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 26(1):43–49.
- Stenum, J., Hsu, M. M., Pantelyat, A. Y., and Roemmich, R. T. (2024). Clinical gait analysis using video-based pose estimation: Multiple perspectives, clinical populations, and measuring change. *PLOS Digital Health*, 3(3):e0000467.
- Tsai, M.-F. and Huang, S.-H. (2022). Enhancing accuracy of human action recognition system using skeleton point correction method. *Multimedia Tools and Applications*, 81.
- Ullah, R., Asghar, I., Nawaz, R., Stacey, C., Akbar, S., and Bishop, P. (2025). A real time action scoring system for movement analysis and feedback in physical therapy using human pose estimation. *Scientific Reports*, 15(1):44784.
- Wagh, V., Scott, M. W., Andrushko, J. W., Jones, C. B., Larssen, B. C., Boyd, L. A., and Kraeutner, S. N. (2025). Using mediapipe to track upper-limb reaching movements after stroke: a proof-of-principle study. *Journal of NeuroEngineering and Rehabilitation*, 22:268.