



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
FACULDADE DE ENGENHARIAS ELÉTRICA E BIOMÉDICA

PEDRO ANDERSON FERREIRA CASTRO

**DESENVOLVIMENTO DE SISTEMA DE BAIXO CUSTO PARA ANÁLISE DO
MOVIMENTO HUMANO UTILIZANDO O OPENPOSE: UM ESTUDO DE CASO**

BELÉM-PA

2023



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
FACULDADE DE ENGENHARIAS ELÉTRICA E BIOMÉDICA

PEDRO ANDERSON FERREIRA CASTRO

**DESENVOLVIMENTO DE SISTEMA DE BAIXO CUSTO PARA ANÁLISE DO
MOVIMENTO HUMANO UTILIZANDO O OPENPOSE: UM ESTUDO DE CASO**

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia Elétrica e Biomédica da Universidade Federal do Pará, como requisito para a obtenção do Grau de Bacharel em Engenharia Biomédica.

Orientador: Prof Dr. Ronaldo de Freitas Zampolo

Coorientador: Prof^a Dr^a. Ana Carolina Quintão Siravenha Muller

BELÉM-PA

2023


Pedro Anderson Ferreira Castro

Desenvolvimento de sistema de baixo custo para análise do movimento humano utilizando o OpenPose: um estudo de caso


Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharias Elétrica e Biomédica da Universidade Federal do Pará, sendo julgada adequada para a obtenção do Grau de Bacharel em Engenharia Biomédica.

Data da Defesa: 21 de Dezembro de 2023

BANCA EXAMINADORA

Documento assinado digitalmente
 RONALDO DE FREITAS ZAMPOLO
Data: 02/01/2024 21:07:44-0300
Verifique em <https://validar.iti.gov.br>


Prof Dr. Ronaldo de Freitas Zampolo
(Orientador - FCT/ITEC/UFPA)

Documento assinado digitalmente
 ANA CAROLINA QUINTAO SIRAVENHA MULLER
Data: 02/01/2024 21:47:24-0300
Verifique em <https://validar.iti.gov.br>

Prof^ª Dra. *Ana Carolina Quintao Siravenha Muller*
(Coorientadora – FEEB/ITEC/UFPA)

Bianca Callegari
Prof^ª Dra. Bianca Callegari

(Membro externo - FFTO/ICS/UFPA)

Documento assinado digitalmente
 ALAN SOVANO GOMES
Data: 03/01/2024 13:49:25-0300
Verifique em <https://validar.iti.gov.br>

Prof. Me. Alan Sovano Gomes
(Membro externo - FEEB/ITEC/UFPA)

Prof^ª. Dra. Carminda Célia Moura de Moura Carvalho
(Diretora da FEEB/ITEC/UFPA)

Este trabalho é dedicado às pessoas que contribuíram para meu desenvolvimento acadêmico e pessoal, a todos que auxiliaram a chegar onde cheguei e à comunidade científica em geral.

AGRADECIMENTOS

Primeiramente, a Deus por me auxiliar ao longo dessa caminhada.

À minha amada família, em especial, meus pais, Anderson da Silva Castro e Alexandra Braga Ferreira, pelo amor incondicional, apoio e compreensão em todos os momentos. Obrigado por serem meu porto seguro.

À minha querida namorada, Rebecca Almeida Aben-Athar, por estar ao meu lado em todos os momentos, compartilhando sonhos, alegrias e desafios. Sua presença é meu conforto e felicidade.

Aos meus amigos incríveis, dentro e fora da UFPA, pelos risos, apoio mútuo e momentos inesquecíveis. Vocês são parte fundamental da minha jornada. Agradeço em especial às minhas amigas Sofia Pinheiro Klautau, Samya Layse Lopes Pinheiro e Natália Soares Mendonça por terem contribuído para o meu amadurecimento.

Ao meu companheiro de laboratório, Lucas Nícolas Azevedo Cruz, por me auxiliar na obtenção dos resultados nos últimos dias para que eu pudesse terminar tudo em tempo hábil.

Aos meus orientadores, o Prof. Dr. Ronaldo de Freitas Zampolo e a Prof^a. Dra. Ana Carolina Quintão Siravenha Müller por disporem do seu tempo para fazer esse trabalho acontecer, apesar das dificuldades.

À Prof^a. Dra. Bianca Callegari e suas bolsistas de projeto por cederem o espaço de seu laboratório e nos auxiliarem na coleta de dados.

Ao Prof. Dr. Aldebaro Barreto da Rocha Klautau Junior e ao Núcleo de P&D em Telecomunicações, Automação e Eletrônica (LASSE), por me fazerem crescer profissionalmente e despertarem meu interesse pela pesquisa.

Muito obrigado a todos!

*"The only thing standing between you and your goal is the story you keep telling yourself as to why you can't achieve it."
(Jordan B. Peterson)*

RESUMO

Os sistemas de análise de movimento humano têm, na conjuntura atual, grande importância em áreas da indústria, como animação, filmes e treinamento esportivo, bem como nas áreas de pesquisa envolvendo motricidade humana, tendo grande impacto na reabilitação, biomecânica e diagnósticos. Entretanto, tais sistemas frequentemente possuem alto custo de aquisição, seja por software ou por equipamentos, bem como problemas logísticos de transporte e implementação em ambientes fora do laboratório, por exemplo, no geral vinculados às especificidades dos aparelhos empregados, dificultando seu acesso por um público maior. Tendo isso em vista, esse trabalho conduz um estudo de caso visando propor uma alternativa de baixo custo, utilizando ferramentas de visão computacional, mais precisamente, o software OpenPose. Além disso, são usadas técnicas de processamento digital de sinais para criar um sistema de análise que atinja níveis satisfatórios, reduzindo drasticamente o número de equipamentos utilizados e o custo deles como um todo, cujo desempenho seja comparável a um sistema de alto padrão disponível no laboratório dedicado a esses estudos, o Laboratório de Estudos da Motricidade Humana (LEMOH), vinculado à FFTO-ICS/UFPA. Os resultados desse trabalho mostraram-se promissores em ambientes com condições controladas (iluminação, contraste de cores, sem ocorrência de oclusão de membros e estruturas para estabilização dos equipamentos de captura), atingindo coeficientes de correlação acima de 85%, bem como uma razão sinal-ruído (SNR) acima de 8 dB (decibéis) em comparações realizadas entre os sinais obtidos por ambos sistemas em relação ao deslocamento dos pontos anatômicos. Para comparações dos sinais de velocidade e aceleração, obteve-se coeficiente de correlação acima de 80%, ambos apresentando valor de SNR acima de 4 dB. As estimativas de variação angular articular para o movimento testado mostraram valores médios de SNR acima de 7 dB.

Palavras-chaves: sistemas de baixo custo; análise de movimento humano; visão computacional; OpenPose; processamento digital de sinais.

ABSTRACT

The human motion analysis systems have significant importance in today's scenario across various industrial domains such as animation, movies, and sports training, as well as in research areas involving human motor skills, greatly impacting rehabilitation, biomechanics, and diagnostics. However, such systems often come with a high acquisition cost, either due to software or equipment, as well as logistical issues regarding transportation and implementation outside laboratory facilities, typically associated with the specificities of the devices used, hindering access to a larger audience. Bearing this in mind, this work conducts a case study aiming to propose a low-cost alternative using computer vision tools, more precisely, the OpenPose software. Additionally, digital signal processing techniques are employed to create an analysis system that achieves satisfactory levels, drastically reducing the number of equipment used and their overall cost, while maintaining performance comparable to a high-standard system available in the laboratory dedicated to these studies, the Laboratory of Human Motor Studies (LEMOH), linked to FFTO-ICS/UFGA. The results of this work have shown promising outcomes in controlled environments (lighting, color contrast, no occurrence of limb occlusion, and structures for equipment stabilization), achieving correlation coefficients above 85%, as well as a signal-to-noise ratio (SNR) above 8 dB (decibels) in comparisons made between signals obtained by both systems concerning the displacement of anatomical points. For comparisons of velocity and acceleration signals, a correlation coefficient above 80% was obtained, both presenting an SNR value above 4 dB. The estimates of angular joint variation for the tested movement showed average SNR values above 7 dB.

Keywords: low-cost systems; human motion analysis; computer vision; OpenPose; digital signal processing.

LISTA DE FIGURAS

Figura 1	– Exemplo de <i>pose</i> estimada pela ferramenta OpenPose. Fonte: autor.	18
Figura 2	– Exemplo genérico da arquitetura de uma CNN. Fonte: autor.	19
Figura 3	– Passo a passo do funcionamento da detecção dos pontos anatômicos do OpenPose. Fonte: Cao et al.[Cao et al. 2017].	21
Figura 4	– Modelos para saída da rede do OpenPose. Fonte: Cao et al.[Cao et al. 2017].	21
Figura 5	– Exemplo de <i>scatter plot</i> gerado no trabalho. Os eixos compõem a estimativa de cada sistema. O ponto em análise é o ponto esquerdo do quadril, conforme o modelo <i>BODY_25</i> . Fonte: autor.	30
Figura 6	– Movimento padronizado (abdução lateral do braço esquerdo) para o registro de dados de comparação. Fonte: autor.	32
Figura 7	– <i>Pipeline</i> de aquisição de dados. Fonte: autor.	33
Figura 8	– <i>Pipeline</i> de comparação de dados de deslocamento dos pontos anatômicos. Cada caixa representa uma etapa de processamento realizado pelo <i>script</i> . Fonte: autor.	34
Figura 9	– <i>Pipeline</i> de comparação dos dados de velocidade e aceleração do deslocamento. Fonte: autor.	35
Figura 10	– <i>Pipeline</i> de análise de ângulo da articulação. Conta com a porção de comparação de dados de variação angular e também de velocidade e aceleração (angulares). A seta vermelha indica exatamente que ambos, variação angular e dados de velocidade e aceleração, passam por uma avaliação em comparação com os dados do LEMOH. Fonte: autor.	36
Figura 11	– <i>Pipeline</i> de avaliação dos dados gerados pelos sistemas. É dividido em duas etapas, sendo uma qualitativa e a outra quantitativa. Fonte: autor.	37
Figura 12	– Frame do vídeo para teste de hiperparâmetros do OpenPose. Fonte: autor. . .	39
Figura 13	– Típica resposta em frequência para o modelo de filtro passa-baixas Chebyshev I de 7ª ordem. Fonte: autor.	40
Figura 14	– Teste de oclusão de membros para o OpenPose. Fonte: autor.	43
Figura 15	– Teste de iluminação para o Openpose. Imagens em RGB. Fonte: autor. . . .	44
Figura 16	– Teste de iluminação para o Openpose. Imagens em escala de cinza. Fonte: autor.	45
Figura 17	– Gráficos das variâncias janeladas dos pontos estimados para a vértebra lombar número 5 (L5). A variância é dada pelo deslocamento em píxels dos pontos. Fonte: autor.	45
Figura 18	– Gráficos dos desvios padrões janelados dos pontos estimados para a vértebra lombar número 5 (L5). Tais valores são obtidos pelo deslocamento em píxels dos pontos. Fonte: autor.	46
Figura 19	– Gráficos de análise de erro para o teste de erro mínimo inerente ao OpenPose. Fonte: autor	46

Figura 20 – Gráficos de análise de erro para o deslocamento dos pontos anatômicos com maior amplitude de movimento durante a abdução lateral do braço. Fonte: autor.	48
Figura 21 – Gráficos de nuvem de pontos para o deslocamento dos pontos anatômicos com maior amplitude de movimento durante a abdução lateral do braço. Fonte: autor.	49
Figura 22 – Gráficos de correlação cruzada para o deslocamento dos pontos anatômicos com maior amplitude de movimento durante a abdução lateral do braço. Fonte: autor.	50
Figura 23 – Gráficos no domínio da frequência para o deslocamento dos pontos anatômicos com maior amplitude de movimento durante a abdução lateral do braço. Fonte: autor.	51
Figura 24 – Gráficos de avaliação qualitativa para a velocidade do deslocamento (rápido) do olécrano esquerdo no eixo X durante a abdução lateral do braço. Fonte: autor.	52
Figura 25 – Gráficos de avaliação qualitativa para a aceleração do deslocamento (rápido) do pulso esquerdo no eixo Y durante a abdução lateral do braço. Fonte: autor.	53
Figura 26 – Gráficos de avaliação qualitativa para o deslocamento (lento) do acrômio esquerdo no eixo Y durante a abdução lateral do braço. Fonte: autor.	54
Figura 27 – Gráficos de avaliação qualitativa para a velocidade do deslocamento (rápido) do acrômio esquerdo no eixo X durante a abdução lateral do braço. Fonte: autor.	55
Figura 28 – Gráficos de avaliação qualitativa para a aceleração do deslocamento (rápido) do acrômio esquerdo no eixo X durante a abdução lateral do braço. Fonte: autor.	56
Figura 29 – Gráficos de avaliação qualitativa para a variação angular no deslocamento (lento) do ângulo da articulação do ombro esquerdo durante a abdução lateral do braço. Fonte: autor.	57
Figura 30 – Gráficos de avaliação qualitativa para a velocidade angular no deslocamento (lento) do ângulo da articulação do ombro esquerdo durante a abdução lateral do braço. Fonte: autor.	58
Figura 31 – Gráficos de avaliação qualitativa para a aceleração angular no deslocamento (lento) do ângulo da articulação do ombro esquerdo durante a abdução lateral do braço. Fonte: autor.	59

LISTA DE TABELAS

Tabela 1	– Taxa de SNR para conjuntos de valores do hiperparâmetro “net_resolution” do OpenPose, para o ponto (x,y) direito do quadril. As linhas contendo “NaN” se referem à perda do sinal quando utilizado o referido valor do hiperparâmetro.	40
Tabela 2	– Taxa de SNR para conjuntos de valores do hiperparâmetro “net_resolution” do OpenPose, para o ponto (x,y) do joelho direito. As linhas contendo “NaN” se referem à perda do sinal quando utilizado o referido valor do hiperparâmetro.	41
Tabela 3	– Taxa de SNR para conjuntos de valores do hiperparâmetro “net_resolution” do OpenPose, para o ponto (x,y) do joelho direito, porém com ajuste de deslocamento convertido de pixel para metro. As linhas contendo “NaN” se referem à perda do sinal quando utilizado o referido valor do hiperparâmetro.	42
Tabela 4	– Taxa de SNR para diferentes modelos de filtros IIR passa-baixas de 7ª ordem, utilizando o ponto (x,y) do joelho direito do output do OpenPose.	42
Tabela 5	– Valores máximos absolutos do erro de deslocamento para o teste estático do OpenPose.	47
Tabela 6	– Resultados das métricas para o deslocamento lento realizado pelos sujeitos.	66
Tabela 7	– Resultados das métricas para o deslocamento rápido realizado pelos sujeitos.	67
Tabela 8	– Resultados das métricas para a velocidade do deslocamento lento realizado pelos sujeitos.	69
Tabela 9	– Resultados das métricas para a velocidade do deslocamento rápido realizado pelos sujeitos.	70
Tabela 10	– Resultados das métricas para a aceleração do deslocamento lento realizado pelos sujeitos.	72
Tabela 11	– Resultados das métricas para a aceleração do deslocamento rápido realizado pelos sujeitos.	73
Tabela 12	– Resultados das métricas para a variação angular do deslocamento lento e rápido realizados pelos sujeitos.	75
Tabela 13	– Resultados das métricas para a velocidade angular do deslocamento lento e rápido realizados pelos sujeitos.	76
Tabela 14	– Resultados das métricas para a aceleração angular do deslocamento lento e rápido realizados pelos sujeitos.	77

LISTA DE SÍMBOLOS

θ – Ângulo entre vetores

$X(\omega)$ – Função da transformada de Fourier contínua

$X[k]$ – Função da transformada discreta de Fourier

$X(\Omega)$ – Função da transformada de Fourier de sinais discretos

$e[n]$ – Sinal de erro

SNR – Relação sinal-ruído

r_{xy} – Coeficiente de correlação de Pearson entre x e y

$R_{xy}(\tau)$ – Função de correlação cruzada com deslocamento temporal entre x e y

$R_{xy}[k]$ – Função de correlação cruzada com deslocamento em amostras entre x e y

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Motivação	15
1.2	Justificativa	15
1.3	Proposta	16
1.4	Objetivos	16
1.4.1	Objetivos específicos	16
1.5	Estrutura do trabalho	16
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	OpenPose	18
2.1.1	Redes neurais convolucionais	19
2.2	Interpolação de sinais	21
2.3	Filtros digitais	22
2.4	Estimativa de ângulo entre dois vetores	24
2.5	Transformada de Fourier	25
2.5.1	Transformada de Fourier discreta	26
2.5.2	Transformada de Fourier de sinais discretos	26
2.6	Métricas para avaliação	26
2.6.1	Sinal de erro	26
2.6.2	Razão sinal-ruído	27
2.6.3	Correlação de Pearson	28
2.6.4	Correlação cruzada	28
2.6.5	Gráfico de nuvem de pontos	29
2.7	Sistema de alto padrão do LEMOH	30
3	METODOLOGIA	31
3.1	Materiais e métodos	31
3.2	Movimento estudado	32
3.3	Aquisição e pré-processamento	33
3.4	Pós-processamento	34
3.4.1	Análise de deslocamento	34
3.4.2	Análise de velocidade e aceleração do deslocamento	35
3.4.3	Análise de ângulo	36
3.5	Avaliação	37
4	RESULTADOS	38
4.1	Testes exploratórios do OpenPose	38

4.1.1	<i>Trade-off</i> entre precisão e performance através do valor do hiperparâmetro “net_resolution”	38
4.1.2	Escolha de modelo para filtro passa-baixas	39
4.1.3	Teste de oclusão da “visão” do OpenPose	39
4.1.4	Iluminação e escala de cinza para imagens processadas	41
4.1.5	Teste de variação de pontos do OpenPose	41
4.1.6	Teste de erro mínimo	44
4.1.7	Resultados finais	44
5	CONCLUSÃO	60
5.0.1	Trabalhos futuros	60
	REFERÊNCIAS	62
6	APÊNDICES	65
6.1	Apêndice A - Dados do deslocamento	65
6.2	Apêndice B - Dados da velocidade do deslocamento	68
6.3	Apêndice C - Dados da aceleração do deslocamento	71
6.4	Apêndice D - Dados das medidas angulares	74

1 INTRODUÇÃO

Os sistemas de análise de movimento humano constituem ferramentas e técnicas utilizadas para capturar, processar e interpretar o movimento do corpo humano. Esses sistemas têm aplicações em diversas áreas, incluindo medicina, pesquisa esportiva, animação, reabilitação, entre outras. Eles são fundamentais para obter informações precisas sobre o movimento, permitindo compreender melhor a biomecânica do corpo e auxiliar em diagnósticos, avaliações e melhorias do desempenho humano. Existem diferentes aplicações de sistemas de análise de movimento humano, cada um com suas características e métodos de funcionamento:

- **Sistemas de captura de movimento:** esses sistemas são projetados para rastrear e capturar a posição e orientação das articulações e partes do corpo em tempo real. Eles podem ser baseados em câmeras de captura de movimento, sensores inerciais, marcadores refletivos ou até mesmo sensores vestíveis. A combinação de várias tecnologias permite registrar os movimentos tridimensionais de forma precisa [Zhu e Li 2016].
- **Análise de marcha:** os sistemas de análise de marcha são usados para estudar e avaliar o padrão de movimento durante a caminhada ou corrida. Eles podem ser aplicados em reabilitação para pacientes com lesões ou deficiências, em atletas para melhorar a eficiência da corrida ou em estudos biomecânicos para compreender melhor o funcionamento do sistema locomotor humano [Herran, Garcia-Zapirain e Mendez-Zorrilla 2014].
- **Animação e filmes:** os sistemas de análise de movimento são amplamente utilizados na indústria de animação e produção de filmes. Eles permitem capturar o movimento de atores ou animais para criar personagens virtuais ou efeitos especiais realistas em filmes, jogos e outras mídias.
- **Saúde e medicina:** na área médica, esses sistemas são utilizados para auxiliar em diagnósticos e tratamentos. Podem ser empregados em análises ortopédicas para avaliar pacientes com problemas musculoesqueléticos, ou para estudar os padrões de movimento em casos de distúrbios neuromotores [E. et al. 2021].
- **Treinamento esportivo:** os sistemas de análise de movimento são usados em treinamento esportivo para monitorar e melhorar o desempenho de atletas. Eles permitem analisar a técnica de movimentos específicos em esportes como golfe, tênis, futebol, entre outros, e fornecem *feedback* valioso para otimizar o desempenho [Gouwanda e Senanayake 2008].
- **Reabilitação e terapia física:** esses sistemas são úteis na reabilitação após lesões ou cirurgias, auxiliando os fisioterapeutas a acompanhar a evolução do paciente e ajustar o tratamento conforme necessário [Wong, Wong e Lo 2007].

Os sistemas de análise de movimento humano têm evoluído significativamente com o avanço da tecnologia, tornando-se mais acessíveis e precisos [Wang, Hu e Tan 2003]. Eles desempenham um papel crucial em diversas áreas, fornecendo informações detalhadas sobre o movimento humano, ajudando a aprimorar o desempenho, prevenir lesões e melhorar a qualidade de vida.

Dando enfoque nos sistemas de captura de movimento humano, nos últimos anos, a área em si está recebendo cada vez mais atenção por parte de pesquisadores em visão computacional. Esse interesse é motivado por aplicações em uma ampla variedade de tópicos. Por exemplo, segmentar as partes do corpo humano em uma imagem, rastrear o movimento das articulações ao longo de uma sequência de imagens e recuperar a estrutura tridimensional do corpo são especialmente úteis para a análise do desempenho atlético, bem como para diagnósticos médicos.

A capacidade de monitorar automaticamente atividades humanas usando computadores em áreas sensíveis à segurança, como aeroportos, fronteiras e saguões de prédios, é de grande interesse para a polícia e o exército, como apontado no artigo de revisão de Aggarwal e Cai [Aggarwal e Cai 1999]. Trabalhos como o de Colyer et al. [Colyer et al. 2018] mostram a evolução dos métodos para extrair informações cinemáticas de imagens, observando como a tecnologia progrediu desde abordagens manuais trabalhosas até sistemas baseados em marcadores optoeletrônicos. Esse trabalho elucidou, de maneira introdutória, os principais avanços no estado da arte da pesquisa de captura de movimento sem marcadores pela visão computacional, que provavelmente terão um impacto futuro na biomecânica, levando em consideração os desafios relacionados à precisão e robustez que ainda precisam ser abordados.

Ainda sobre o auxílio do avanço das pesquisas e uso de tecnologias para o desenvolvimento de sistemas de análise de movimento humano, trabalhos como os de Rodrigues et al. [Rodrigues et al. 2022] e Carse et al. [Carse et al. 2013] enfatizam também a contribuição na redução de custos e facilidade de implementação desses sistemas em larga escala e em consultórios, onde muitas vezes existe a dificuldade de instalação por questões como espaço necessário, custos de treinamento para operação do equipamento, manutenção, etc. Além disso, destaca-se o principal obstáculo: o custo de aquisição de tecnologias desse tipo. O trabalho de Rodrigues et al. [Rodrigues et al. 2022], visa avaliar a validade concorrente de um *smartphone* e um dispositivo portátil para a avaliação do controle de equilíbrio estático, utilizando um mesmo grupo de participantes (vinte e seis indivíduos saudáveis e jovens) em comparação com a posturografia, o método padrão de avaliação do equilíbrio. Para validação dos resultados obtidos, a avaliação do controle de equilíbrio estático dos acelerômetros embutidos dentro do *smartphone* portátil e dos dispositivos vestíveis foi testada considerando as gravações da plataforma de força como padrão-ouro para comparações. O estudo apresentou resultados com correlação linear (r) acima de 0,5 entre as variáveis quantitativas obtidas pelos sensores inerciais dos *smartphones* e a plataforma de força para 11 de 12 variáveis, em condições de olhos abertos, olhos fechados e unipedais, enquanto os dispositivos vestíveis apresentaram 8 de 12 variáveis com correlação moderada para

muito alta (com r acima de 0,5 com as variáveis da plataforma de força sob as mesmas condições de tarefa). Já o trabalho de Carse et al.[Carse et al. 2013] , por sua vez, objetiva determinar a precisão de rastreamento de marcadores de um novo sistema óptico de análise de movimento 3D de baixo custo, conduzindo um estudo comparativo entre sistemas, incluindo o proposto pelos autores nesse segundo trabalho. Utilizando um conjunto rígido de quatro marcadores refletivos para comparar um sistema de análise de movimento 3D de baixo custo, chamado de *Optitrack* (que faz uso de 8 câmeras), com dois sistemas mais caros: Vicon 612, contando com 12 câmeras e o Vicon MX, que conta com 8 câmeras também. Os resultados apresentaram discordância máxima entre as magnitudes médias de vetores de 2,2% para Optitrack e Vicon MX e 2,1% entre Vicon 612 e Vicon MX.

1.1 Motivação

A busca por serviços de reabilitação acessíveis e de baixo custo, especialmente ressaltada pela recente pandemia do SARS-CoV-2 (Coronavírus), impulsionou a exploração de novos caminhos para implementar tratamentos de forma eficaz. Nesse contexto, surgem alternativas, como por exemplo, a Telereabilitação, que tem um enfoque promissor baseado em tecnologias de Visão Computacional (*Computer Vision* - CV) [Hellsten et al. 2021]. Essa busca por abordagens inovadoras é ampliada pela evolução histórica da análise de movimento, que remonta ao século XIX com os trabalhos pioneiros de Muybridge[Muybridge 1887]. Ao longo do tempo, essa análise evoluiu significativamente em conjunto com avanços tecnológicos, sendo aplicada em áreas tão diversas quanto a avaliação clínica de marcha e a animação de jogos. Em aplicações de biomecânica esportiva e reabilitação, a análise quantitativa da cinemática do corpo humano tem se mostrado uma ferramenta poderosa para entender aspectos determinantes de técnicas, identificar fatores de risco de lesões e auxiliar na recuperação pós-trauma.

1.2 Justificativa

No contexto atual, a análise de movimento humano é predominantemente realizada por sistemas de alto padrão, como os empregados no Laboratório de Estudos da Motricidade Humana (LEMOH), localizado dentro do Instituto de Ciências Médicas (ICM), fazendo parte do Instituto de Ciências da Saúde (ICS) da Universidade Federal do Pará (UFPA) [FFTO]. Apesar de sua precisão, tais sistemas apresentam barreiras financeiras e logísticas como, por exemplo, os custos associados a equipamentos especializados, sensores e software, restringindo assim sua acessibilidade e escalabilidade da pesquisa e tratamentos ou seu uso em ambientes fora de laboratórios de pesquisa especializada [Carse et al. 2013]. Surge, portanto, a indagação central: é factível desenvolver um sistema de análise de movimento de baixo custo que mantenha níveis aceitáveis de precisão e detalhamento, tornando a análise acessível em diversos cenários? Enquanto isso, a adoção dos sistemas convencionais é limitada devido às circunstâncias comentadas

acima, destacando assim a necessidade de alternativas como o **OpenPose**, um software de visão computacional que rastreia e identifica pontos-chave no corpo humano. A aplicação do OpenPose como solução de baixo custo pode democratizar a análise de movimento, ampliando seu alcance e aplicabilidade em várias áreas. Este estudo visa, portanto, explorar tal alternativa para tornar a análise de movimento mais acessível e abrangente.

1.3 Proposta

Este estudo visa avaliar a viabilidade e acurácia do OpenPose como alternativa de baixo custo para o desenvolvimento de um sistema de análise de movimento humano, baseado em visão computacional e processamento digital de sinais.

1.4 Objetivos

O objetivo geral deste trabalho é conduzir um estudo de caso para avaliar a viabilidade e o desempenho da ferramenta OpenPose como uma alternativa para a elaboração de um sistema de análise de movimento em comparação com o sistema de alto padrão que faz uso do software Simi motion [Pascal and Philipp Russ 2023].

1.4.1 Objetivos específicos

De modo a atingir o objetivo central do trabalho, contamos ainda com as seguintes metas:

- Investigar as capacidades do OpenPose em termos de precisão e detalhamento na análise de movimento humano em comparação com o sistema de referência adotado;
- Avaliar a praticidade e a usabilidade do OpenPose em relação à configuração, calibração e operação do sistema de baixo custo utilizando essa ferramenta;
- Realizar estudos de caso para analisar e identificar as limitações e vantagens do sistema proposto;
- Desenvolver *pipeline* de pré- e pós-processamento para estudos e análise de movimento;
- Propor recomendações para a integração eficaz do OpenPose como alternativa de baixo custo no LEMOH e em outras instituições similares.

1.5 Estrutura do trabalho

CAPÍTULO 1 - INTRODUÇÃO: apresenta uma breve contextualização da área do problema abordado, bem como apresenta uma breve revisão bibliográfica, salientando a relevância e

os avanços na área do tema, destacando após isso os objetivos da pesquisa, por meio da exposição de sua proposta, justificativa e metas estabelecendo o contexto para o restante do trabalho.

CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA: Apresenta as bases teóricas para a compreensão das técnicas e algoritmos utilizados no trabalho, além de apresentar o estado da arte na problemática a ser abordada.

CAPÍTULO 3 - METODOLOGIA: descreve os recursos usados para a coleta dos dados (materiais e métodos), descreve sobre os processamentos aplicados aos dados coletados, os passos para preparar os dados (pipeline de pré e pós processamento) e as métricas usadas para avaliar os resultados da ferramenta.

CAPÍTULO 4 - RESULTADOS: apresentação das métricas utilizadas, dos testes realizados e discussão dos resultados obtidos.

CAPÍTULO 5 - CONCLUSÃO: são feitas as considerações finais do trabalho. Também são mencionadas ponderações quanto às limitações do trabalho e aponta recomendações para pesquisas futuras.

CAPÍTULO 6 - APÊNDICES: são apresentadas as tabelas contendo as informações das métricas de avaliação para os dados coletados no LEMOH.


2 FUNDAMENTAÇÃO TEÓRICA

Nesse capítulo serão apresentadas as bases teóricas, ou seja, a fundamentação necessária para a compreensão das ferramentas e algoritmos utilizados na elaboração deste trabalho.

2.1 OpenPose

O OpenPose é uma ferramenta de código aberto desenvolvida pela *Carnegie Mellon University* (CMU) que permite a detecção de múltiplos pontos-chave (em inglês, *keypoints*) do corpo humano em imagens e vídeos [Cao et al. 2019]. A principal funcionalidade do OpenPose é a estimativa da *pose* humana em tempo real, definida por [Colyer et al. 2018] como “a posição e orientação de um objeto em sequências de imagens”, rastreando as posições das articulações do corpo, como mãos, cotovelos, joelhos e pés, como pode ser visto na Figura 1. Mais recentemente, foram adicionadas à ferramenta opções de detecção de pontos do rosto e também das mãos [Simon et al. 2017].

Figura 1 – Exemplo de *pose* estimada pela ferramenta OpenPose. Fonte: autor.




Essa ferramenta utiliza redes neurais convolucionais para realizar a detecção dos pontos-chave e, assim, conseguir identificar a pose humana em diferentes cenas e ambientes [Wei et al. 2016]. O OpenPose é capaz de lidar com múltiplas pessoas simultaneamente,

sendo uma das suas principais vantagens em relação a outras ferramentas de análise de pose [Cao et al. 2017].

2.1.1 Redes neurais convolucionais

Redes neurais convolucionais (CNNs, do inglês, *Convolutional Neural Networks*) são uma classe de redes neurais profundas [LeCun, Bengio e Hinton 2015] que têm se mostrado altamente eficazes na área de visão computacional, incluindo a análise de movimento [Kale e Patil 2016]. As CNNs são projetadas para extrair automaticamente características relevantes de imagens e dados visuais complexos, permitindo uma análise mais precisa e eficiente. Na Figura 2 pode-se contemplar um exemplo estrutural desse tipo de rede. Grande parte da rede é constituída por unidade chamadas de filtros ou *kernels* que realizam a operação de convolução sobre as imagens de entrada. As dimensões das imagens são então alteradas (resolução e número de canais) conforme a configuração de cada camada, podendo aumentar ou diminuir, até ser enviado às camadas densas de uma rede convencional.

Figura 2 – Exemplo genérico da arquitetura de uma CNN. Fonte: autor.



No contexto de uso das CNNs para análise de movimento, pesquisas relativamente recentes vêm sendo conduzidas, como o trabalho de Moro et al. [Moro et al. 2020], que relata os resultados de um estudo piloto realizado em um caso de análise clínica da marcha, onde eles comparam parâmetros 2D calculados com uma técnica baseada em marcadores de referência com aqueles obtidos com um *pipeline* sem marcadores. Outro trabalho importante da área é o de Hellsten et al. [Hellsten et al. 2021], que traz uma visão geral crítica dos recentes estudos baseados em sistemas de visão computacional de estimativa de pose humana sem marcadores e sua aplicabilidade para o campo de estudos envolvendo a reabilitação. O artigo de Liu [Liu 2021] faz o uso das CNNs para reconhecimento de movimentos humanos para análise esportiva, um campo que vem adotando cada vez mais o uso de tecnologias relacionadas ao aprendizado de máquina para avaliação de desempenho de atletas. A pesquisa de Nieto-Hidalgo et al. [Nieto-Hidalgo et al. 2018] apresenta uma abordagem de análise da marcha baseada em

visão computacional, realizada em um *smartphone* com assistência de computação em nuvem podendo atingir uma precisão de 95%.

Esses trabalhos são apenas alguns exemplos das muitas pesquisas que utilizam CNNs para a análise de movimento. A aplicação de CNNs nessa área tem contribuído para avanços significativos no reconhecimento de ações humanas, na estimativa da pose, na detecção de movimentos anormais e em outras tarefas relacionadas. As CNNs têm demonstrado excelentes resultados na extração e aprendizado de características discriminativas dos movimentos, permitindo a análise e o reconhecimento de padrões complexos. Essas características têm impulsionado avanços em diversas áreas por possibilitar reduções de custos em relação a sistemas clínicos consolidados e fornecendo praticidade e simplicidade para determinadas tarefas, como por exemplo, a de diagnósticos preventivos.

O processo de detecção de movimento do OpenPose começa com a extração de características dos dados de entrada (imagens isoladas ou *frames* de um vídeos) onde a imagem é passada para a CNN de referência (a arquitetura da VGG-19 de Simonyan e Zisserman [Simonyan e Zisserman 2014]) para extração dos chamados mapas de características (em inglês, *feature maps*), que são representações visuais de ativações de neurônios em diferentes camadas da rede após a aplicação das operações de convolução. O processamento é seguido de um *pipeline* de vários estágios, gerando os Mapas de Confiança de Partes, que são uma representação 2D da confiança de que uma determinada parte do corpo pode ser localizada em um dado pixel, e também os Campos de Afinidade de Partes, ou PAFs (do inglês *Part Affinity Fields*), que são um conjunto de campos vetoriais 2D que codifica a localização e a orientação dos membros de diferentes pessoas na imagem, codificando os dados na forma de conexões emparelhadas entre as partes do corpo. A partir daí, o OpenPose estima as conexões entre esses pontos para formar a estrutura da *pose* do corpo humano através de um algoritmo para emparelhamento bipartido ganancioso, montando o esqueleto representativo seguindo um modelo preestabelecido. Esse processo pode ser visualizado na Figura 3, onde é destacado esse passo a passo. Atualmente, dois modelos de saída para o OpenPose são disponibilizados para seleção, o *COCO*, contando com 18 pontos e o *BODY_25*, contando com 26 pontos, como exemplificado pela Figura 4 [Cao et al. 2017]. O primeiro modelo não possui pontos para compor o tronco e os pés do indivíduo, ao contrário do segundo, que dispõe de 3 pontos para formar o tronco e quadril, e 3 pontos para a formação de cada pé do sujeito, sendo assim um modelo mais completo.

O OpenPose tem diversas aplicações práticas em várias áreas. Por exemplo, na saúde, pode ser utilizado para a análise da marcha, fisioterapia e reabilitação. Em esportes, é útil para a análise do desempenho de atletas e movimentos em atividades físicas. Também é aplicado em entretenimento, em animações, realidade virtual e jogos interativos.

Além disso, o OpenPose possui uma comunidade de desenvolvedores ativa, que contribui para o seu aprimoramento contínuo e o desenvolvimento de recursos adicionais. A ferramenta está disponível publicamente no GitHub, permitindo que pesquisadores e desenvolvedores

Figura 3 – Passo a passo do funcionamento da detecção dos pontos anatômicos do OpenPose. Fonte: Cao et al.[Cao et al. 2017].



Figura 4 – Modelos para saída da rede do OpenPose. Fonte: Cao et al.[Cao et al. 2017].



utilizem e adaptem o código conforme suas necessidades específicas.

Vale ressaltar que o OpenPose tem algumas limitações, como a dependência de uma boa iluminação e oclusões parciais, que podem afetar a precisão da detecção dos pontos-chave em algumas situações. Mesmo assim, o OpenPose tem se mostrado uma ferramenta poderosa e acessível para análise de pose humana em tempo real, abrindo caminho para uma série de aplicações e avanços nas áreas de visão computacional e aprendizado de máquina.

2.2 Interpolação de sinais

A interpolação de sinais é um conceito amplamente utilizado em processamento de sinais e tem como objetivo estimar os valores de um sinal em pontos intermediários com base em seus valores conhecidos em pontos discretos adjacentes. De acordo com Proakis e

Manolakis[Proakis e Manolakis 2006], a interpolação pode ser considerada como um processo de reconstrução de um sinal contínuo ou discreto a partir de amostras discretas. O termo “reconstrução” é usado porque, em muitos casos, o sinal original é previamente amostrado e convertido em um sinal discreto antes de ser processado.

Para realizar a interpolação, o sinal amostrado é aproximado por uma função contínua que passa pelos pontos discretos disponíveis. Essa função contínua é geralmente um polinômio, e o processo é conhecido como interpolação polinomial. O polinômio é ajustado de forma que ele passe exatamente pelos pontos discretos conhecidos e, assim, os valores desconhecidos entre esses pontos podem ser estimados.

Existe uma importância na escolha do método de interpolação dependendo do tipo de sinal e dos objetivos do processamento Proakis e Manolakis[Proakis e Manolakis 2006]. Diferentes métodos de interpolação podem ser utilizados, como interpolação linear, interpolação polinomial de ordem superior, interpolação cúbica e assim por diante. Cada método tem suas vantagens e limitações, e a escolha adequada deve levar em conta fatores como a complexidade computacional, a precisão necessária e o grau de suavidade desejado no sinal interpolado. É importante ressaltar que a interpolação pode introduzir erros, especialmente quando os pontos discretos disponíveis não representam adequadamente o comportamento do sinal original. Portanto, a interpolação deve ser realizada com cautela e, em alguns casos, técnicas adicionais podem ser utilizadas para melhorar a qualidade do sinal interpolado, como filtragem e técnicas de correção de distorções.

A interpolação de sinais é amplamente utilizada em diversas áreas, como processamento de imagens, processamento de áudio, processamento de sinais biomédicos e telecomunicações. Em imagens, a interpolação é utilizada para redimensionar imagens, melhorar a qualidade visual e realizar zoom ou rotação. No processamento de áudio, é aplicada para a ressíntese de áudio, melhoria de qualidade sonora e correção de distorções. Na área biomédica, é utilizada para a reconstrução de imagens médicas e o processamento de sinais fisiológicos.

2.3 Filtros digitais

Os filtros digitais são sistemas que realizam o processamento de sinais digitais, alterando suas características espectrais, como amplitude, fase e frequência, como mencionado no livro de Oppenheim, Schafer e Buck[Oppenheim, Schafer e Buck 1999]. Eles são amplamente utilizados em diversas áreas, incluindo processamento de áudio e de imagens, telecomunicações, controle de sistemas, entre outros.

Conforme o livro de Lathi[Lathi 2007], existem dois tipos principais de filtros digitais: Filtros FIR (Resposta Finita ao Impulso) e Filtros IIR (Resposta Infinita ao Impulso). Os filtros FIR têm uma resposta ao impulso finita, o que significa que sua resposta se extingue no tempo. Eles são caracterizados por não possuírem realimentação em seus estágios, além de serem

geralmente mais estáveis por essa mesma característica e são linearmente invariantes no tempo. Isso torna os filtros FIR ideais para aplicações que exigem resposta de fase linear, como em sistemas de áudio. Já os filtros IIR têm uma resposta ao impulso infinita, o que implica que a resposta pode continuar indefinidamente no tempo. Eles possuem realimentação dos valores de saída para os estágios do filtro e geralmente exigem menos coeficientes para alcançar a mesma especificação que um filtro FIR, em outras palavras, alcançam características de filtragem complexas com ordens menores do que os FIR. Como já mencionado, os filtros IIR usam realimentação dos estágios do filtro, o que pode causar instabilidade se não forem projetados corretamente.

Uma importante propriedade dos filtros digitais é a resposta em frequência, que descreve como o filtro atenua ou amplifica as diferentes frequências do sinal de entrada. A resposta em frequência é geralmente representada em gráficos de magnitude e fase, permitindo uma análise completa das características do filtro. A magnitude representa a relação de ganho ou atenuação do sinal em função da frequência, enquanto a fase representa o atraso introduzido pelo filtro em diferentes frequências.

Existe ainda uma classificação dos filtros com base nas características de seleção feita para as frequências em que eles permitem a passagem (comumente chamadas de bandas de passagem). Há quatro tipos diferentes de filtros segundo essas características: o filtro passa-baixas, permitindo a passagem de frequências até um limiar, chamado de frequência de corte, atenuando todas as frequências acima deste limiar; o passa-altas, que realiza a função inversa; o passa-faixas e o rejeita faixas, ambos sendo a junção de um passa-baixas e um passa-altas, realizando a função de atenuar tudo que não esteja entre esses dois limites e a rejeição das frequências dentro desse limiar, respectivamente, sendo diferenciados apenas pelas frequências de corte dos filtros que os compõem.

Dentre os vários modelos de filtros amplamente disseminados, para o trabalho em questão destacam-se três sistemas digitais utilizados para o tratamento dos dados coletados: o filtro de Chebyshev I, o filtro de Savitzky–Golay e a técnica de redução de ruído utilizando a decomposição *Wavelet*.

- **Chebyshev I:** é um tipo de filtro digital projetado para atender a requisitos específicos em termos de resposta em frequência, ganho e atenuação de determinadas frequências. A principal característica do filtro Chebyshev Tipo I é sua capacidade de proporcionar uma taxa de corte (largura da banda de transição) mais íngreme em comparação com outros tipos de filtros, como o filtro *Butterworth*, se fixado o mesmo número de ordem. Ele é particularmente adequado para aplicações em que é necessário atenuar rapidamente certas frequências fora da banda de interesse.
- **Savitzky-Golay:** é um tipo de filtro utilizado para suavizar e remover ruído de dados de séries temporais. Ele difere de outros filtros, como os filtros de média móvel, por sua

abordagem de ajuste de polinômios locais a janelas deslizantes de pontos de dados. Esse filtro é particularmente útil quando se lida com dados experimentais que podem conter ruído de alta frequência, variações locais ou picos. Possui a diferença de, ao invés de aplicar uma média simples ou ponderada aos dados, o filtro de Savitzky-Golay ajusta polinômios locais aos dados em uma janela deslizante, permitindo que ele modele as variações locais nos dados. Ele ainda permite que o usuário escolha a ordem do polinômio a ser ajustado aos dados e o tamanho da janela deslizante. A ordem do polinômio controla como ele melhor se ajustará aos dados locais, ao passo que o tamanho da janela determina quantos pontos da vizinhança estão incluídos no ajuste local.

- **Wavelet:** a filtragem digital wavelet, juntamente com a análise wavelet, são técnicas poderosas e versáteis usadas em processamento de sinais e análise de dados. Elas são usadas para implementar transformadas wavelet em sinais digitais, sendo essa uma técnica de análise espectral que permite representar sinais no domínio do tempo e no domínio da frequência simultaneamente, fornecendo informações sobre como diferentes frequências estão distribuídas ao longo do tempo. Ela é particularmente útil para analisar sinais não estacionários, nos quais as características do sinal podem mudar ao longo do tempo.

A análise wavelet envolve o desdobramento de um sinal em componentes de diferentes frequências e escalas, permitindo a detecção de recursos e características em diferentes níveis de detalhe.

Os filtros wavelet são projetados para dividir o sinal em componentes de alta e baixa frequência, correspondentes a detalhes e aproximações, respectivamente. Tal processo é guiado pela escolha da chamada wavelet "mãe" (também chamada de wavelet mãe prototípica), que é a função base usada para a análise de um sinal. A wavelet mãe é uma função que é dilatada e transladada para analisar diferentes escalas e posições no sinal. A escolha da wavelet mãe pode afetar significativamente a qualidade e a sensibilidade da análise wavelet.

Na pesquisa desenvolvida, optou-se pelo uso da família de funções Daubechies, mais precisamente, utilizando a função de 13 coeficientes na wavelet mãe. Esse conjunto de funções ortogonais têm características específicas e úteis para a análise de sinais. De modo mais aprofundado, a família Daubechies, é conhecida por suas propriedades de regularidade e suavidade, tornando-a adequada para a análise de detalhes em sinais. Ela é frequentemente usada em aplicações como compressão de imagem, *denoising* (remoção de ruído) de sinais de áudio e análise de características em séries temporais.

2.4 Estimativa de ângulo entre dois vetores

O ângulo entre dois vetores é um conceito fundamental nas áreas da matemática e das ciências, incluindo álgebra linear, geometria, física, engenharia e computação, usado

para medir a direção relativa desses vetores em relação ao ponto de origem Anton e Busby[Anton e Busby 2003]. Esse conceito é também amplamente usado em computação gráfica.

O ângulo entre dois vetores é definido, segundo o livro de Anton e Busby[Anton e Busby 2003], como o menor ângulo que deve ser girado em um plano para que os vetores fiquem alinhados. A equação para o cálculo do ângulo pode ser vista abaixo:

$$\theta = \arccos \left(\frac{\vec{u} \cdot \vec{v}}{\|\vec{u}\| \|\vec{v}\|} \right), \quad (2.1)$$

onde θ é o valor do ângulo, \vec{u} e \vec{v} são os vetores que geram o ângulo, e $\|\vec{u}\|$ e $\|\vec{v}\|$ são suas respectivas normas.

O ângulo é medido graus ou radianos, podendo variar entre 0° e 180° (ou 0 e π radianos), dependendo de sua direção relativa. Quando os vetores são paralelos (ou opostos), o ângulo é 0° (ou 180°) e, quando são perpendiculares, o ângulo é 90° . No contexto do trabalho em questão, os vetores \vec{u} e \vec{v} correspondem ao segmento de reta entre dois pontos anatômicos, e o ângulo gerado corresponde ao ângulo interno da articulação durante a realização daquele movimento.

2.5 Transformada de Fourier

A transformada de Fourier é um conceito essencial no campo das engenharias. A transformada de Fourier é uma técnica matemática que permite decompor um sinal em suas componentes de frequência. Ela é particularmente útil para analisar sinais, tanto periódicos quanto não periódicos, e é amplamente aplicada em áreas como processamento de sinais, análise de sistemas lineares, comunicações, processamento de imagens, entre outras. A transformada de Fourier é definida matematicamente por meio de uma integral complexa que relaciona a função de tempo contínuo $f(t)$ com sua representação no domínio da frequência $F(\omega)$, conforme os livros de Oppenheim, Schaffer e Buck[Oppenheim, Schaffer e Buck 1999] e Lathi[Lathi 2007]. Essa transformação é uma forma de representar a função $f(t)$ como uma combinação de senos e cossenos de diferentes frequências.

Em termos mais técnicos, a transformada de Fourier para sinais contínuos é dada por:

$$X(\omega) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j\omega t} dt, \quad (2.2)$$

onde $X(\omega)$ é a transformada de Fourier do sinal $x(t)$ em frequência ω , $x(t)$ é o sinal contínuo no domínio do tempo, j é a unidade imaginária $j = \sqrt{-1}$ e ω é a frequência angular contínua.

Já na área do processamento digital de sinais, existem duas ferramentas para trabalhar com os sinais discretizados (digitais): a transformada de Fourier Discreta (DFT) e a transformada de Fourier de sinais discretos (DTFT).

2.5.1 Transformada de Fourier discreta

A DFT é uma versão discreta da transformada de Fourier e é utilizada para converter um sinal discreto do domínio do tempo para o domínio da frequência. A DFT é definida como uma soma finita de exponenciais complexas ponderadas pelos valores do sinal discreto. Para um sinal discreto $x[n]$ de comprimento N , a DFT $X[k]$ é dada por

$$X[k] = \sum_{n=0}^{N-1} x[n] \cdot e^{-j\frac{2\pi kn}{N}}, \quad (2.3)$$

onde $X[k]$ é a DFT do sinal discreto $x[n]$ e representa as componentes espectrais do sinal em diferentes frequências discretas k , $x[n]$ é o sinal discreto no domínio do tempo, j é a unidade imaginária $j = \sqrt{-1}$, N é o comprimento do sinal discreto $x[n]$.

2.5.2 Transformada de Fourier de sinais discretos

A transformada de Fourier de sinais discretos (DTFT) é apresentada por [Oppenheim, Schafer e Buck 1999] como uma generalização da DFT para sinais de comprimento infinito. Ela é definida para sinais de tempo discreto, sendo uma transformada com domínios contínuos em frequência. A DTFT é dada por:

$$X(\Omega) = \sum_{n=-\infty}^{\infty} x[n] \cdot e^{-j\Omega n}, \quad (2.4)$$

onde $X(\Omega)$ é a DTFT do sinal discreto $x[n]$ e representa as componentes espectrais do sinal em todas as frequências discretas Ω , $x[n]$ é o sinal discreto no domínio do tempo, j é a unidade imaginária $j = \sqrt{-1}$, Ω é a variável frequencial.

2.6 Métricas para avaliação

As métricas estatísticas desempenham um papel fundamental na avaliação de métodos e algoritmos em diversas áreas, incluindo ciência de dados, aprendizado de máquina, processamento de sinais, visão computacional, entre outras. Elas são usadas para medir o desempenho, a precisão e a eficácia de um método em relação aos dados de entrada e às tarefas específicas. No contexto do trabalho em questão, um conjunto de métricas quantitativas e qualitativas são utilizadas para a avaliação da ferramenta, em outras palavras, o desempenho do OpenPose no contexto do potencial nos estudos envolvendo motricidade humana.

2.6.1 Sinal de erro

No contexto de processamento de sinais, o sinal de erro, também conhecido como resíduo ou diferença, é uma medida da discrepância entre um sinal original e uma estimativa ou previsão

desse sinal. Ele é amplamente utilizado em várias aplicações, como filtragem de sinais, estimação de parâmetros, controle, reconhecimento de padrões, entre outros. Suponha que tenhamos um sinal original $x[n]$ e uma estimativa ou predição desse sinal, chamada de $\hat{x}[n]$. O sinal de erro é definido como a diferença entre esses dois sinais, conforme o livro de Oppenheim, Schafer e Buck [Oppenheim, Schafer e Buck 1999]:

$$e[n] = x[n] - \hat{x}[n] \quad (2.5)$$

O sinal de erro $e[n]$ representa a parte do sinal original $x[n]$ que não foi capturada ou prevista corretamente pela estimativa. Em outras palavras, ele representa o "erro" na predição do sinal original. O processamento do sinal de erro é uma técnica comum para melhorar a qualidade de um sinal ou para ajustar modelos e algoritmos que realizam a estimativa. Ao analisar o sinal de erro, é possível identificar padrões não capturados pelo modelo ou evidências de ruído ou distorções presentes no sinal original.

2.6.2 Razão sinal-ruído

A relação sinal-ruído (SNR, do inglês, Signal-to-Noise Ratio) é uma medida importante no processamento de sinais que descreve a proporção entre a potência ou amplitude do sinal útil e a potência ou amplitude do ruído presente no sinal. Essa relação é frequentemente utilizada para avaliar a qualidade e a fidelidade de um sinal em meio à presença de ruído indesejado. Matematicamente, Haykin e Moher [Haykin e Moher] define a SNR como:

$$\text{SNR} = \frac{\text{Potência do Sinal Útil}}{\text{Potência do Ruído}} \quad (2.6)$$

A SNR é expressa em forma de decibéis (dB) e é uma medida adimensional, uma vez que compara grandezas de mesma dimensão (potência ou amplitude).

Uma alta relação sinal-ruído indica que o sinal útil é dominante em relação ao ruído, apontando um sinal de alta qualidade e baixa interferência do ruído. Por outro lado, uma baixa relação sinal-ruído significa que o sinal útil está sendo prejudicado pela presença de ruído, tornando a interpretação e o processamento do sinal mais desafiadores. A relação sinal-ruído é amplamente utilizada em diversas aplicações, tais como comunicações, imagens e vídeos, áudio e música, sensoriamento remoto, etc.

A avaliação e melhoria da relação sinal-ruído são essenciais para garantir a eficiência e a precisão de algoritmos e sistemas de processamento de sinais. Métodos de filtragem, equalização, supressão de ruído e técnicas de processamento adaptativo são frequentemente utilizados para melhorar a SNR e aumentar a qualidade do sinal útil em diversas aplicações práticas. Nesse trabalho, para o cálculo do SNR utilizou-se como amplitude do sinal útil a varância do sinal de

referência (nesse caso, o sinal do sistema do LEMOH) e como amplitude do ruído, a variância do sinal de erro (a diferença entre os sinais do LEMOH e do OpenPose).

2.6.3 Correlação de Pearson

A correlação de Pearson, também conhecida como coeficiente de correlação de Pearson, é uma medida estatística utilizada para quantificar o grau de associação linear entre duas variáveis. No contexto do processamento de sinais, a correlação de Pearson é amplamente utilizada para avaliar a relação linear entre dois sinais, indicando o quão fortemente eles variam juntos em uma direção positiva (correlação positiva) ou em uma direção negativa (correlação negativa).

A correlação de Pearson é definida, em concordância com o livro de Shumway e Stoffer [Shumway e Stoffer 2017] como a covariância entre os dois sinais dividida pelo produto dos desvios padrão de cada sinal. Matematicamente, a fórmula é dada por:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.7)$$

Onde n é o número de amostras nos sinais x e y ; x_i e y_i são os valores das amostras nos sinais x e y , respectivamente; \bar{x} e \bar{y} são as médias dos valores dos sinais x e y , respectivamente.

A correlação de Pearson r_{xy} é um valor entre -1 e 1, cuja interpretação é dada da seguinte forma:

- $r_{xy} = 1$: indica uma correlação positiva perfeita, ou seja, os sinais x e y variam na mesma direção linearmente.
- $r_{xy} = -1$: indica uma correlação negativa perfeita, ou seja, os sinais x e y variam em direções opostas linearmente.
- $r_{xy} = 0$: indica que não há correlação linear entre os sinais x e y .

A correlação de Pearson é amplamente utilizada em aplicações como processamento de áudio, processamento de imagem, análise de dados, reconhecimento de padrões e em outras áreas do processamento de sinais. É uma ferramenta útil para entender a relação entre sinais e para auxiliar na tomada de decisões em diversas aplicações práticas.

2.6.4 Correlação cruzada

A correlação cruzada é uma técnica importante no processamento de sinais que mede a similaridade ou relação entre dois sinais em função do deslocamento (atraso ou adiantamento) de um em relação ao outro. É uma ferramenta útil para identificar atrasos temporais e determinar o grau de sincronização ou correspondência entre os sinais.

No contexto de processamento de sinais discretos, a correlação cruzada normalizada (utilizada no trabalho em questão) entre dois sinais $x[t]$ e $y[t]$ é definida por Brockwell e Davis [Brockwell e Davis 2016] como:

$$R_{xy}[k] = \frac{1}{N} \sum_{t=0}^{N-1} x[t] \cdot y[t+k] \quad (2.8)$$

Onde $R_{xy}[k]$ é a correlação cruzada entre os sinais amostrados $x[t]$ e $y[t]$, de tamanho N , com um atraso de k amostras. Quando k é zero, a correlação cruzada mede a similaridade entre os sinais em sincronia. Se houver um atraso temporal entre os sinais, o máximo da correlação cruzada indica o valor do atraso, ou seja, o deslocamento em que os sinais são mais semelhantes.

A correlação cruzada é uma poderosa ferramenta no processamento de sinais para análise, estimação e sincronização de sinais, proporcionando *insights* valiosos sobre a relação temporal entre diferentes fontes de informação em diversas aplicações práticas.

2.6.5 Gráfico de nuvem de pontos

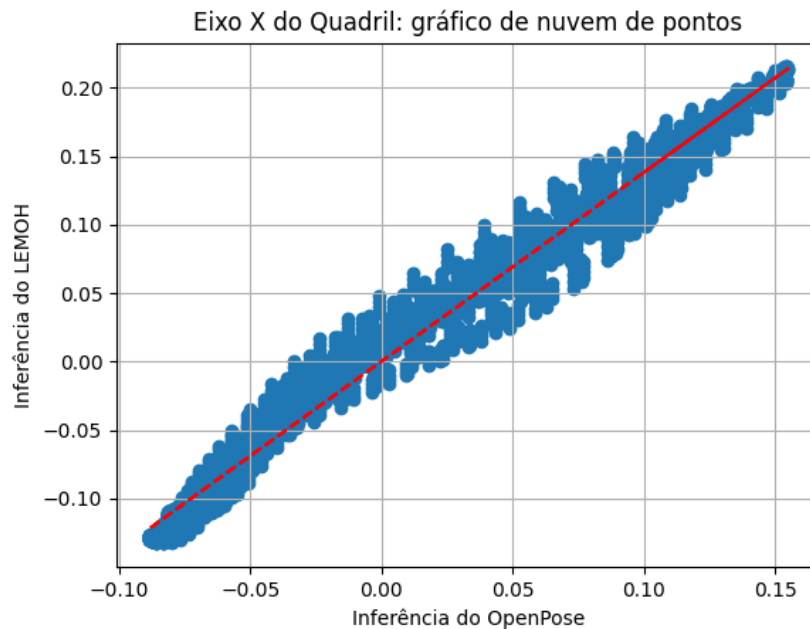
Os gráficos de nuvens de pontos, também conhecidos como *scatter plots*, em inglês, são uma técnica visual comumente usada no contexto de processamento de sinais para analisar e representar relações entre dois conjuntos de dados. Essa técnica é particularmente útil quando se deseja examinar a relação entre duas variáveis contínuas, como em séries temporais ou sinais amostrados.

No gráfico de nuvem de pontos, cada ponto no gráfico representa uma combinação específica de valores das duas variáveis em estudo. O eixo horizontal geralmente representa a primeira variável e o eixo vertical representa a segunda variável. Cada ponto é posicionado de acordo com os valores correspondentes das duas variáveis, criando uma "nuvem" de pontos no espaço bidimensional.

Esses gráficos são úteis para visualizar padrões, tendências ou agrupamentos nos dados. A distribuição dos pontos no gráfico pode revelar informações importantes sobre a relação entre as variáveis. Alguns padrões comuns que podem ser observados em um *scatter plot* incluem correlação linear, agrupamento, distribuição e *outliers* que são pontos isolados e distantes dos outros podem indicar valores atípicos ou espúrios nos dados.

Os gráficos de nuvens de pontos são uma ferramenta visual poderosa para o processamento de sinais, permitindo uma rápida identificação de padrões e relações entre variáveis.

Figura 5 – Exemplo de *scatter plot* gerado no trabalho. Os eixos compõem a estimativa de cada sistema. O ponto em análise é o ponto esquerdo do quadril, conforme o modelo *BODY_25*.
Fonte: autor.



2.7 Sistema de alto padrão do LEMOH

O Laboratório de Estudos da Motricidade Humana, vinculado à FFTO-ICS/UFPA, é um importante centro de pesquisa coordenado pela professora Bianca Callegari. Este laboratório é equipado com tecnologias de alto padrão que desempenham um papel fundamental na realização de avaliações quantitativas dos movimentos humanos, tais como equilíbrio, postura e marcha. Uma das aquisições mais recentes do LEMOH é o sistema de cinemetria da empresa Simi, o software *Simi motion*, composto por quatro câmeras, das quais 3 estão operantes. Ele permite a captura detalhada e precisa dos movimentos humanos, tornando possível uma análise minuciosa das trajetórias e dos ângulos das articulações durante a marcha e outras atividades [Duarte et al. 2022].

3 METODOLOGIA

Neste capítulo será apresentada a abordagem utilizada para conduzir este trabalho de conclusão de curso, incluindo materiais empregados, etapas de processamento de sinais e as métricas de avaliação. Detalhes são fornecidos para garantir a compreensão e reprodutibilidade, assegurando a validade e transparência dos resultados.

3.1 Materiais e métodos


Para a aquisição dos sinais de referência, fora utilizada, para o sistema de alto desempenho instalado no LEMOH, um conjunto de câmeras com velocidade de captura de 120 FPS e sensores infravermelho, bem como tripés para estabilização das câmeras e um *software* proprietário, o *Simi motion* [Pascal and Philipp Russ 2023], com a função de rastrear e realizar o processamento para os dados coletados, contando ainda com marcadores anatômicos reflexivos para os sensores infravermelhos presentes nas câmeras. Já para o sistema de baixo custo proposto nesse trabalho, fez-se uso apenas de uma câmera de *smartphone* com taxa de captura de 30 FPS em uma resolução Full HD e um tripé para estabilização ótica do aparelho. Fez-se necessário também a presença de um objeto de dimensões conhecidas durante as filmagens (utilizou-se uma régua ou um objeto medido dentro da cena), para a conversão das unidades de deslocamento dos sinais adquiridos. Já para a utilização da ferramenta de visão computacional de código aberto e também a cadeia de pré e pós processamento dos dados, fez-se uso de um computador com as especificações:

- Sistema operacional - Ubuntu 18.04.06 LTS
- Processador (CPU) - Intel i7-8700K
- Placa de vídeo (GPU) - Nvidia Geforce GTX 1060 de 6 GBytes de memória
- Memória RAM - 16 GBytes em *dual channel* (2×8 GBytes)
- OpenPose - Versão 1.6
- CUDA - Versão 10.1
- cuDNN - Versão 7.5.1

3.2 Movimento estudado

Após testes realizados descritos no próximo capítulo, o movimento escolhido para avaliação dos dois sistemas fora o de abdução lateral do braço esquerdo, sendo esse um movimento dentro do eixo látero-lateral (em outras palavras, um deslocamento contido apenas no plano frontal). As aquisições foram efetuadas em duas velocidades definidas pelo sujeito, uma mais lenta e outra mais rápida, espaçadas por um intervalo de repouso de aproximadamente 5 segundos. Os indivíduos participantes da coleta de dados realizavam o movimento sentado em um banco, conforme ilustrado na Figura 6, para facilitar a captura pelo software do sistema de alto padrão, conforme ajuste efetuado pela equipe responsável do LEMOH, além de auxiliar na redução de influências de outras regiões do corpo. Optou-se também pelo uso de roupas que se destacavam em relação à parede ao fundo do cenário para facilitar a detecção realizada pelo OpenPose. Uma vez que o *Simi Motion* realiza a captura com base em marcadores reflexivos, a remoção de objetos com propriedades reflexivas do espaço de registro de dados foi empregada.

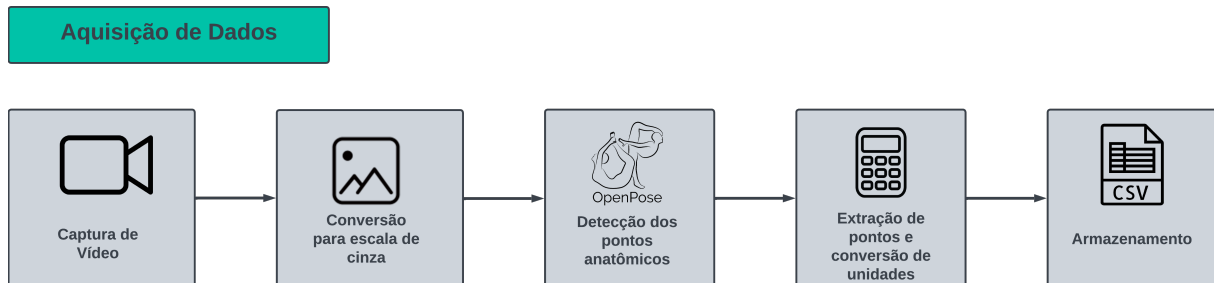
Figura 6 – Movimento padronizado (abdução lateral do braço esquerdo) para o registro de dados de comparação. Fonte: autor.



3.3 Aquisição e pré-processamento

Durante a etapa de aquisição, foram seguidos os passos mostrados na Figura 7.

Figura 7 – Pipeline de aquisição de dados. Fonte: autor.



- **Captura de vídeo:** durante esse passo, é realizada a captura do movimento a ser estudado, seguindo uma sequência de 10 tentativas, *trials*, espaçadas por um intervalo de tempo pré-estabelecido, utilizando das câmeras presentes em ambos sistemas. Os dados capturados pelo sistema do LEMOH são então processados *on-the-fly* pelo software presente na máquina que recebe os dados da câmera.
- **Conversão para escala de cinza:** após a captura dos vídeos, é feita a conversão dos vídeos para escala de cinza, de modo a auxiliar o algoritmo do OpenPose na detecção.
- **Detecção do OpenPose:** os vídeos são então passados as redes do OpenPose com uma série de parâmetros estipulados através de *flags* de modo a melhorar a performance do algoritmo.
- **Extração de pontos e conversão de unidades:** as estimativas dos pontos anatômicos são armazenadas em arquivos no formato JSON (*JavaScript Object Notation*), onde cada frame do vídeo corresponde a um arquivo. Todos os arquivos referentes a um único vídeo são então carregados e armazenados em vetores correspondentes aos *keypoints* do modelo de detecção do OpenPose. As unidades de dimensionamento dos pontos são então convertidas de pixel para metros (m). Nessa etapa, também é feita a extração da variação angular entre o braço e o tronco (conforme explicado na seção 2.4), referentes ao movimento realizado pela articulação do membro que é objeto de estudo na análise a ser performada. Essa obtenção de dados angulares é realizada para ambos os sistemas, uma vez que essa informação não é gerada de forma “orgânica” também pela estrutura presente no LEMOH.
- **Armazenamento:** esses sinais são armazenados em arquivos de texto no formato CSV (*Comma-separated values*), onde cada arquivo corresponde a um vídeo, possuindo colunas de identificação para cada ponto estimado, bem como suas componentes (X e Y) ao longo dos *frames*. Para os estudos da variação angular, apenas o valor do ângulo entre o braço e o tronco em cada instante de tempo é armazenado.

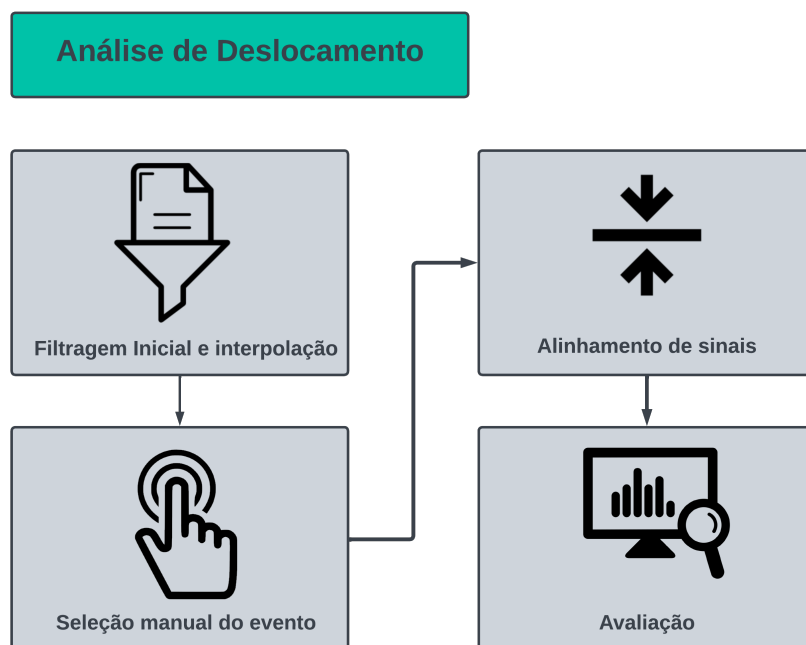
3.4 Pós-processamento

Após o pré-processamento e armazenamento dos dados gerados pelo OpenPose, entra em ação a etapa de pós-processamento, constituída por 3 estágios de análise: a análise de deslocamento, a análise de velocidade e aceleração (do deslocamento) e a análise de ângulo. Cada estágio conta ainda com uma etapa de avaliação, onde são retiradas as métricas.

3.4.1 Análise de deslocamento

Ilustrada na Figura 8, essa análise consiste na comparação dos dados, eixo a eixo, dos pontos anatômicos, selecionados, para o estudo do movimento em questão.

Figura 8 – Pipeline de comparação de dados de deslocamento dos pontos anatômicos. Cada caixa representa uma etapa de processamento realizado pelo *script*. Fonte: autor.



- **Filtragem inicial e interpolação:** para retirar o ruído intrínseco à estimativa das redes do OpenPose e suavizar os dados de aferição, é performada uma filtragem inicial somente no sinal do sistema de baixo custo, utilizando um filtro passa-baixas de 7ª ordem do tipo **Chebyshev I**. Entretanto, devido à diferença entre as taxas de captura entre as câmeras presentes nos dois sistemas, o de alto padrão contando com uma taxa de 120 FPS e o de baixo custo com 30 FPS, é imprescindível realizar uma interpolação entre os sinais adquiridos de modo que os dados gerados pelo OpenPose apresentem o mesmo número de amostras que o sistema do LEMOH. Sendo assim, esse passo é realizado para fazer essa compensação.
- **Seleção manual do evento:** com auxílio de uma janela interativa gerada pelo *script* de pós-processamento, é realizada a seleção do início e fim do evento a ser estudado em

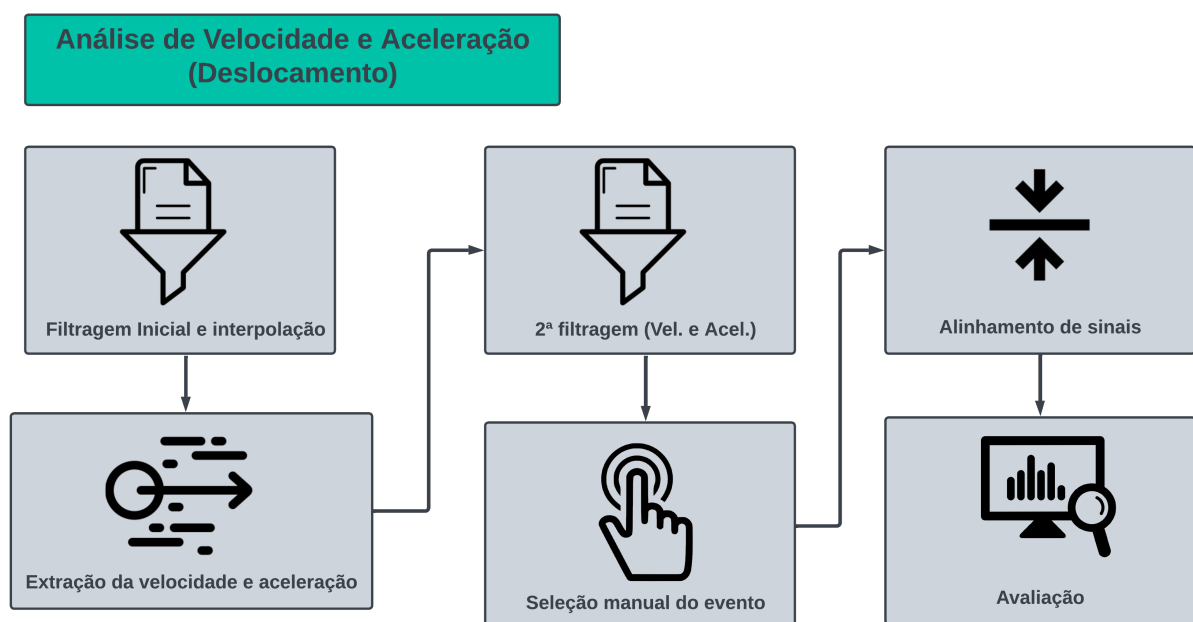
ambos os sinais, de modo a retirar partes dos sinais que não serão de grande valia para a avaliação.

- **Alinhamento de sinais:** com os dados filtrados e o evento de interesse selecionado, os sinais são alinhados com auxílio do algoritmo de correlação cruzada normalizada, com o objetivo de obter uma dupla de sinais comparáveis para as métricas.
- **Avaliação:** por fim, os sinais são comparados e uma avaliação qualitativa e quantitativa é realizada, extraindo os valores das métricas utilizadas para tal. Os detalhes dessa etapa de processamento serão explicados mais adiante no texto.

3.4.2 Análise de velocidade e aceleração do deslocamento

Seguindo o estágio de processamento dos dados de deslocamento, o próximo passo é a comparação das medidas de velocidade e aceleração desses registros. O processamento inicial, como é mostrado na Figura 9, é parecido com o realizado na etapa anterior, diferenciando-se pela extração dos dados de velocidade e aceleração e a filtragem realizada sobre eles.

Figura 9 – Pipeline de comparação dos dados de velocidade e aceleração do deslocamento. Fonte: autor.



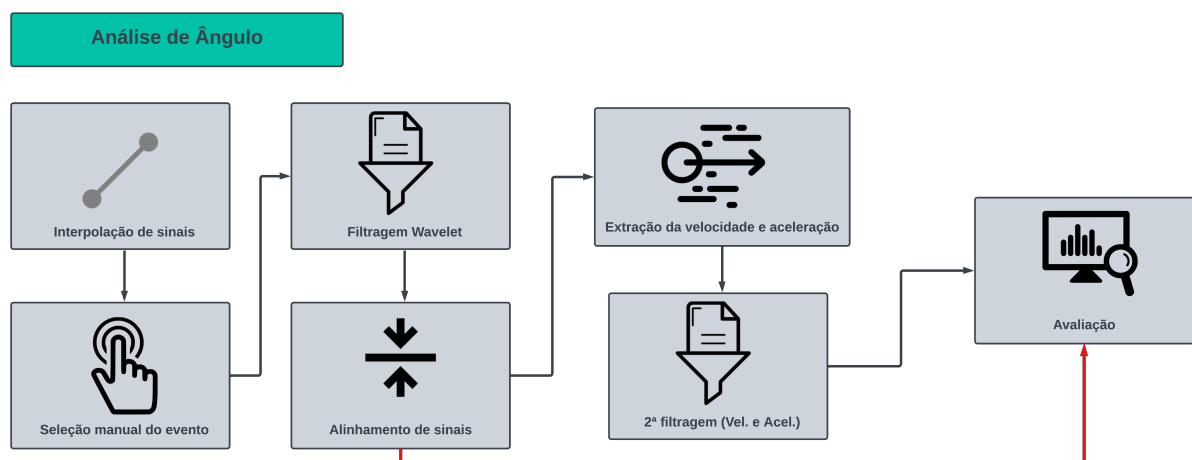
- **Extração de velocidade e aceleração:** realizando a diferenciação dos sinais obtidos pelo OpenPose referentes ao deslocamento, conseguimos extrair informações de velocidade e aceleração dos pontos de interesse, de modo a compararmos com os registros dessas medidas que também são feitas pelo *Simi Motion*.
- **2ª filtragem (velocidade e aceleração):** com os sinais extraídos, uma filtragem em duas etapas é realizada sobre os sinais do sistema de baixo custo e do LEMOH, para redução

de ruídos presentes nos dois sistemas. Na primeira filtragem, é feito o uso de um filtro Savitzky-Golay, conhecido por suas propriedades de redução de ruído ou de suavização de sinais, com janelas de 30 amostras e um polinômio de 7ª ordem. Após isso, é utilizado um filtro passa-baixas semelhante ao da filtragem inicial, para maior atenuação de ruídos restantes. Após isso, o processamento dos dados é o mesmo aplicado ao estágio anterior, seguido também pela avaliação.

3.4.3 Análise de ângulo

No último *script* de análise, teremos o processamento dos dados angulares referentes à articulação do membro avaliado (se for o caso do estudo). Como a Figura 10 explicita, essa etapa conta com algumas diferenças em relação as duas primeiras, principalmente por conta da filtragem inicial realizada e por já contar com o processamento de velocidade e aceleração dos dados junto da análise de deslocamento, que nesse caso, é dada pela variação angular no tempo.

Figura 10 – Pipeline de análise de ângulo da articulação. Conta com a porção de comparação de dados de variação angular e também de velocidade e aceleração (angulares). A seta vermelha indica exatamente que ambos, variação angular e dados de velocidade e aceleração, passam por uma avaliação em comparação com os dados do LEMOH. Fonte: autor.



- **Interpolação:** dessa vez, é realizada apenas a interpolação dos dados angulares, sem a filtragem inicial. Os sinais então passam para a seleção da região de interesse.
- **Filtragem Wavelet:** com o evento já selecionado, os dados de variação angular extraídos do OpenPose são filtrados utilizando a transformada Wavelet, mais especificamente, com a família Daubechies com 13 coeficientes, que conforme mencionado anteriormente, é conhecida por ter propriedades que auxiliam na redução de ruídos de sinais digitais. Essa decomposição de sinal é realizada em vários níveis, com base no comprimento dos dados e do filtro escolhido, onde um cálculo é feito para determinar o nível máximo útil de decomposição. Após isso o sinal é filtrado reduzindo os coeficientes abaixo de um limiar, suavizando assim o sinal que será então reconstruído a partir desses coeficientes

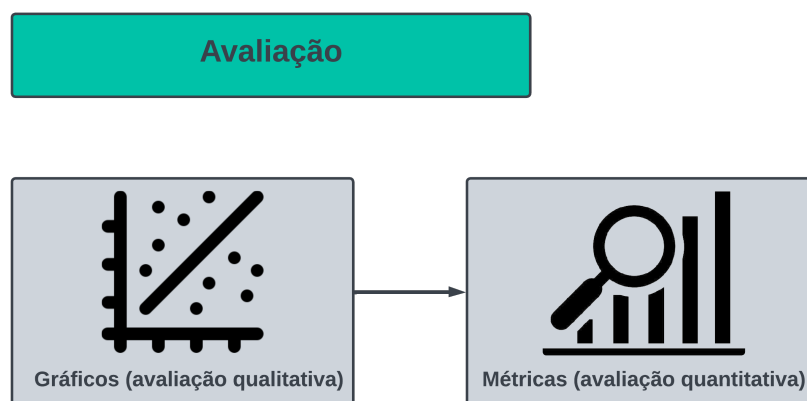
modificados, tratando o sinal como periódico. Após isso os sinais são alinhados conforme descrito anteriormente, onde segue para avaliação.

- **Extração de velocidade e aceleração:** os sinais de variação angular são convertidos de graus por segundo ($^{\circ}/s$) para radianos por segundo (rad/s) para só então serem obtidos os valores de velocidade e aceleração angulares, de modo semelhante ao realizado para o deslocamento. Esses dados então são filtrados utilizando, para a velocidade, somente um filtro de Savitzky-Golay, e, para aceleração, o mesmo filtro porém com a adição de outra filtragem passa-baixas com o filtro de Chebyshev I.

3.5 Avaliação

Por fim, a última etapa na metodologia pela qual passam todos os *scripts* de processamento é a de avaliação, conforme mostrado na Figura 11, onde são retiradas as métricas para validar a qualidade das aferições feitas pelo OpenPose em comparação com o sistema de alto padrão presente no LEMOH. Esse passo conta com uma análise qualitativa e quantitativa.

Figura 11 – Pipeline de avaliação dos dados gerados pelos sistemas. É dividido em duas etapas, sendo uma qualitativa e a outra quantitativa. Fonte: autor.



- **Avaliação qualitativa:** aqui são gerados os gráficos de comparação entre os sinais estudados, de acordo com a análise efetuada. Estão incluídos nessa etapa os gráficos de análise de erro, de nuvem de pontos, de correlação cruzada normalizada e no domínio da frequência, obtidos através da transformada de Fourier discreta (DFT).
- **Avaliação quantitativa:** conforme os gráficos são gerados, métricas são retiradas para analisar a qualidade da aferição do OpenPose em comparação com a feita pelo sistema do LEMOH. As medidas retiradas são o SNR (calculado como fora explicado anteriormente, na seção 2.6.2), o valor máximo absoluto de erro, o valor de correlação de Pearson, o de correlação cruzada normalizada e os valores de frequência de pico entre os dois sinais, obtidos através da DFT.

4 RESULTADOS

Este capítulo sintetizará os resultados dos testes executados de modo a encontrar o melhor conjunto de parâmetros para a realização dos objetivos propostos, bem como os resultados finais de acordo com a metodologia adotada, presente no capítulo anterior.

4.1 Testes exploratórios do OpenPose

Com o intuito de entender melhor como o OpenPose poderia se comportar em diversos cenários e condições, uma série de experimentos foram conduzidos para averiguar a saída gerada e assim definir um procedimento base para a operação do mesmo.


4.1.1 *Trade-off* entre precisão e performance através do valor do hiperparâmetro “net_resolution“

O OpenPose possui uma série de parâmetros que podem ser passados através de *flags* ao utilizarmos a ferramenta para executar a estimativa dos pontos anatômicos, como por exemplo, ativação da visualização da saída durante o processamento do vídeo. Dentre esses parâmetros, destaca-se um, com o nome de “net_resolution“. O par de números setado nesse hiperparâmetro afeta diretamente o controle de precisão do algoritmo, o que afeta indiretamente a velocidade de performance da ferramenta. Os valores possíveis variam entre múltiplos de 16, com a recomendação do autor da faixa de utilização entre 160 e 368 [Cao et al. 2017]. Além disso, os autores recomendam a utilização de uma das dimensões setada para -1 , que significa deixar que o OpenPose decida a proporção ideal dependendo do valor de entrada do usuário (da imagem/vídeo). Para obter o máximo equilíbrio entre velocidade e precisão, deve-se manter a proporção mais próxima possível das imagens ou vídeos a serem processados [Cao et al. 2019].

Nas tabelas 1 e 2, são visualizados os dados referentes as componentes X e Y do ponto direito do quadril e do ponto joelho direito, respectivamente, sendo a Tabela 3 correspondente também ao ponto do joelho direito, porém com um ajuste da conversão do deslocamento de pixels para metro.

A escolha se deu com base no valor de SNR (que com base em reuniões iniciais da pesquisa com o laboratório parceiro, o LEMOH, teve seu valor aceitável como sendo acima de 6 dB) presente nas 3 tabelas que mantivesse a menor diferença entre as condições de mudança de pontos e eixos, além do ajuste de unidade de deslocamento, escolhendo assim o valor “-1x336” para gerar os resultados finais. Isso pode ser confirmado ao analisar os valores obtidos nas tabelas citadas, uma vez que tal valor foi o que apresentou a menor variação entre eixos, mesmo com a mudança de unidade. O vídeo processado em questão é referente ao ensaio com o movimento de sentar e levantar do indivíduo em uma cadeira, que pode ser visto na Imagem 12.

Figura 12 – Frame do vídeo para teste de hiperparâmetros do OpenPose. Fonte: autor.



4.1.2 Escolha de modelo para filtro passa-baixas

Devido a presença de ruídos que a estimativa do OpenPose pode apresentar, gerados pelo ambiente, equipamento de captura, etc, se faz necessário a realização de uma etapa de filtragem inicial (descrita no capítulo anterior, na sessão 3.4). Esses ruídos representam componentes de alta frequência presentes no sinal, dando um aspecto “tremido” ou “serrilhado” ao conjunto de dados bruto. Para eliminar esse ruído apresentado pela ferramenta utilizada, foi utilizado um filtro passa-baixas de resposta ao impulso de duração infinita (IIR) de 7ª ordem, sendo o seu modelo definido pelo teste utilizando o mesmo vídeo para a seleção do conjunto de valores para o hiperparâmetro de controle de acurácia e performance. A frequência de corte desse filtro foi definida a partir da análise na frequência dos sinais para o movimento de estudo em questão, sendo o corte efetuado em 1,5 Hz. A visualização da Tabela 4 permite a análise dos diferentes modelos de filtros testados, dando base para a escolha do filtro de Chebyshev I, devido manter a menor variação entre os valores de SNR ao ser utilizando em dois eixos diferentes. A Imagem 13 exemplifica a resposta em frequência do modelo selecionado.

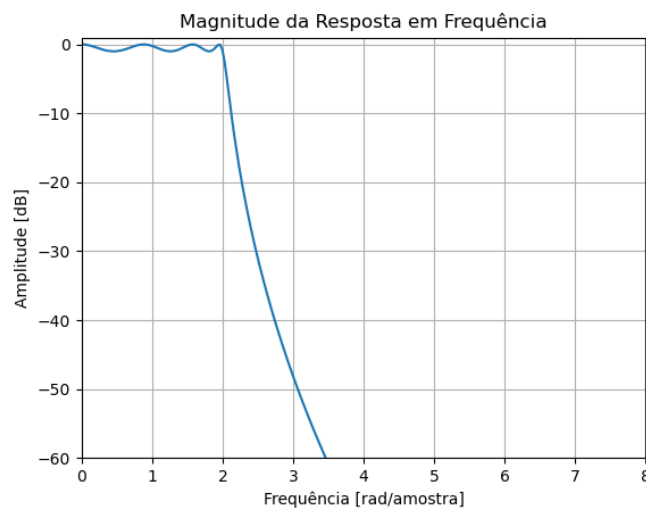
4.1.3 Teste de oclusão da “visão” do OpenPose

Focando em entender o comportamento do algoritmo de detecção da ferramenta em cenários onde não se teriam a visão de todo o corpo do indivíduo a ser performado o *tracking* dos pontos anatômicos, foram conduzido dois testes, onde um consistia em começar a aquisição em um ponto em que fosse possível ver o corpo inteiro, seguido do caminhar da pessoa em direção à

Tabela 1 – Taxa de SNR para conjuntos de valores do hiperparâmetro “net_resolution” do OpenPose, para o ponto (x,y) direito do quadril. As linhas contendo “NaN” se referem à perda do sinal quando utilizado o referido valor do hiperparâmetro.

net_resolution	SNR quadril x (dB)	SNR quadril y (dB)
-1x160	15.5970	14.1491
-1x176	15.1095	14.6524
-1x192	16.6502	15.7754
-1x208	15.7996	14.3809
-1x224	15.5146	13.9679
-1x240	15.7914	16.5784
-1x256	16.1237	13.4508
-1x272	16.6071	15.4716
-1x288	NaN	NaN
-1x304	16.5030	16.8553
-1x320	NaN	NaN
-1x336	17.0687	15.6492
-1x352	17.0020	15.7804
-1x368	16.9079	16.0195

Figura 13 – Típica resposta em frequência para o modelo de filtro passa-baixas Chebyshev I de 7ª ordem. Fonte: autor.



câmera de registro, de modo a ocluir a parte superior do corpo (o que pode ser visto na Imagem 14a, da Figura 14), bem como um teste com a altura da câmera ajustada de modo que, ao sujeito se aproximar do dispositivo, seus membros inferiores fosse “cortados” do campo de visão do OpenPose, como ilustrado na Imagem 14b. Os testes foram conduzidos para avaliação qualitativa da variação do esqueleto plotado pela ferramenta.

Tabela 2 – Taxa de SNR para conjuntos de valores do hiperparâmetro “net_resolution” do OpenPose, para o ponto (x,y) do joelho direito. As linhas contendo “NaN” se referem à perda do sinal quando utilizado o referido valor do hiperparâmetro.

net_resolution	SNR joelho x (dB)	SNR joelho y (dB)
-1x160	7.0856	2.3462
-1x176	8.7809	6.1205
-1x192	9.1476	3.5315
-1x208	8.5487	2.3752
-1x224	8.0577	4.2390
-1x240	7.6510	3.2576
-1x256	8.3289	4.6298
-1x272	8.0180	5.6246
-1x288	NaN	NaN
-1x304	8.2948	5.6607
-1x320	8.8137	3.6513
-1x336	8.5029	6.2241
-1x352	8.4319	4.9150
-1x368	8.6745	4.2356

4.1.4 Iluminação e escala de cinza para imagens processadas

Um dos fatores que pode influenciar bastante na performance de algoritmos de visão computacional é a iluminação do ambiente em que é feito o registro das imagens ou vídeos a serem processados. De um modo geral, uma iluminação ruim tende a, de acordo com os dados em que a rede neural da ferramenta fora treinada, dificultar a detecção do objeto na cena. Pensando nisso, testes foram efetuados tanto no LEMOH quanto no Laboratório de Processamento de Sinais, o LAPS, localizado na UFPA, com o objetivo de visualizar os impactos desse fator, conforme ilustrado nas imagens 15a e 15b, na Figura 15. Vale ressaltar também o teste da conversão dos canais de imagem, em RGB, para escala de cinza, uma prática que é comum da área de detecção de objetos e visão computacional, mas que fora notado não ser performado pelo algoritmo do OpenPose. Sendo assim, os mesmos vídeos foram convertidos, sendo exibidos nas imagens 16a e 16b na Figura 16, para investigar o auxílio que esse tratamento poderia oferecer à ferramenta.

4.1.5 Teste de variação de pontos do OpenPose

Conforme fora observado o comportamento do algoritmo para os dados de testes adquiridos, um evento ficou evidente com auxílio do esqueleto plotado pela saída do OpenPose: os pontos centrais (ponto do pescoço e o ponto central do quadril) que norteiam o tronco do indivíduo presente nos dados de entrada tendiam a apresentar uma variação, uma espécie de “trepidação” em sua estimativa. Querendo examinar o quão grande era essa variação, um teste foi conduzido utilizando os dados gravados no LEMOH e no LaPS realizando o movimento de

Tabela 3 – Taxa de SNR para conjuntos de valores do hiperparâmetro “net_resolution” do OpenPose, para o ponto (x,y) do joelho direito, porém com ajuste de deslocamento convertido de pixel para metro. As linhas contendo “NaN” se referem à perda do sinal quando utilizado o referido valor do hiperparâmetro.

net_resolution	SNR joelho x c/ ajuste (dB)	SNR joelho y c/ ajuste (dB)
-1x160	7.7653	2.5137
-1x176	9.4607	6.1792
-1x192	9.9486	3.4408
-1x208	9.3120	2.2220
-1x224	8.8910	3.8910
-1x240	8.5465	3.1122
-1x256	9.4016	4.5188
-1x272	8.8627	5.3198
-1x288	NaN	NaN
-1x304	9.0267	5.5998
-1x320	9.6330	3.5139
-1x336	9.2337	6.0302
-1x352	9.0394	4.7752
-1x368	9.2955	4.0106


Tabela 4 – Taxa de SNR para diferentes modelos de filtros IIR passa-baixas de 7ª ordem, utilizando o ponto (x,y) do joelho direito do output do OpenPose.

Modelo de filtro (7ª ordem)	SNR joelho x (dB)	SNR joelho y (dB)
Butterworth	7.4245	5.7158
Chebyshev I	9.3592	6.3316
Chebyshev II	9.2337	6.0302
Cauer/Elliptic	9.3370	5.9677
Remez Exchange Algorithm	9.5331	5.7834


abdução lateral do braço esquerdo no plano coronal, consistindo em estimar o ponto da lombar conhecido como L5 (devido ser localizado na 5ª vértebra da lombar), sendo dois terços da distância entre o ponto do pescoço e o ponto central do quadril de acordo com o modelo de esqueleto do OpenPose. A partir do deslocamento desse ponto ao longo do vídeo, foi possível extrair o desvio padrão janelado e a variância janelada ao longo do vídeo para o ponto estimado, representando assim uma medida da inconsistência intrínseca à ferramenta, uma vez que o tronco da pessoa presente no vídeo não estava realizando nenhum movimento perceptível pela câmera. Os gráficos das variâncias e desvios padrões podem ser vistos nas figuras 17 e 18. Neles, podemos notar tanto nos valores de variância quanto de desvio padrão janelados que as amostras coletadas no LaPS, por possuírem captura em um ambiente mais iluminado e um bom contraste de roupas com o fundo do cenário, obtiveram valores menores e mais consistentes, o que corrobora com o resultado obtido pelo teste anterior. Entretanto, ambas capturas apresentaram variação mesmo

Figura 14 – Teste de oclusão de membros para o OpenPose. Fonte: autor.

(a) Oclusão de membros superiores.



(b) Oclusão de membros inferiores.



sem movimento realizado pelo sujeito, sendo assim, deve ser levado em consideração esse ruído, caso seja de interesse a análise de pontos que constituem a coluna vertebral do indivíduo.

Figura 15 – Teste de iluminação para o Openpose. Imagens em RGB. Fonte: autor.**(a) Aquisição no LEMOH.****(b) Aquisição no LaPS.**

4.1.6 Teste de erro mínimo

Investigando a possibilidade de erro mínimo característico à estimativa dos pontos anatômicos feita pelo OpenPose, conduzimos um teste, nos padrões estabelecidos para a coleta de dados de avaliação final (conforme explicado na seção 3.2) com a diferença de não realizar movimento algum durante a captura, ou seja, com o indivíduo em repouso. A partir disso, extraímos os gráficos de erro do deslocamento e o valor máximo absoluto de erro dos pontos anatômicos avaliados na validação (Acrômio, Olécrano e Pulso esquerdo). Exemplos gráficos desse teste podem ser vistos na Figura 19, e os resultados de erro obtidos, na Tabela 5.

4.1.7 Resultados finais

Para a validação do OpenPose como uma ferramenta alternativa para análise de movimento, uma coleta de sinais, utilizando 3 indivíduos, fora conduzida, utilizando as especificidades do movimento e aquisição de acordo com a descrição realizada nas seções 3.2, 3.3 e 3.4 desse trabalho, onde métricas para o deslocamento e variação angular, ambos contendo dados para velocidade e aceleração, foram extraídas para comparação entre os sistemas. Nas tabelas 6 e 7 estão presentes os dados de deslocamento, referentes ao movimento lento e rápido, respectivamente, ao passo que nas tabelas 8 e 9 se encontram os registros para a velocidade do deslocamento, também separadas de acordo com a velocidade de execução do movimento. Já nas tabelas 10 e 11, constam as métricas para a aceleração do deslocamento. As tabelas 12, 13 e 14 por sua

Figura 16 – Teste de iluminação para o Openpose. Imagens em escala de cinza. Fonte: autor.


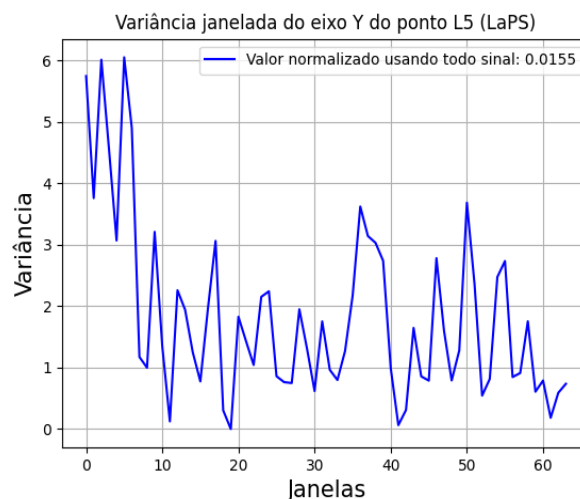



Figura 17 – Gráficos das variâncias janeladas dos pontos estimados para a vértebra lombar número 5 (L5). A variância é dada pelo deslocamento em pixels dos pontos. Fonte: autor.

(a) Teste efetuado no LEMOH.

(b) Teste efetuado no LaPS.



vez, compõem os registros para as variações angulares da articulação do ombro esquerdo, dessa vez com ambas as velocidades de execução dos movimentos contidas na mesma tabela. Foram avaliados 3 pontos anatômicos (acrômio, olécrano e pulso esquerdo), decompondo a análise em dois eixos: *x* e *y*. Para os dados estimados referentes ao ângulo da articulação do ombro, essa decomposição não foi necessária.

Analisando os dados obtidos, é possível enxergar a similaridade presente entre os sistemas

Figura 18 – Gráficos dos desvios padrões janelados dos pontos estimados para a vértebra lombar número 5 (L5). Tais valores são obtidos pelo deslocamento em pixels dos pontos. Fonte: autor.

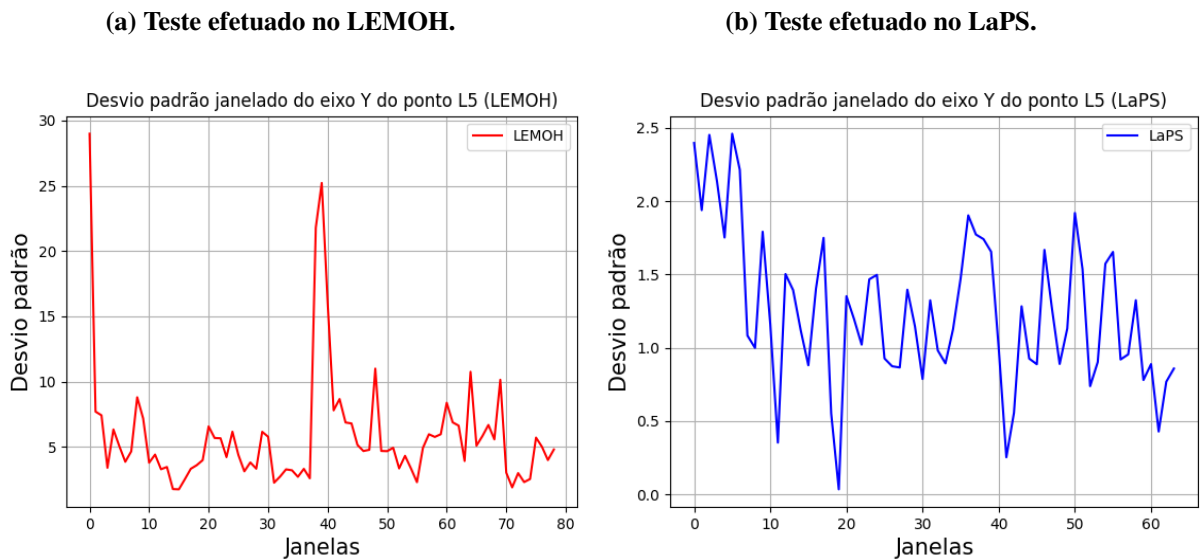



Figura 19 – Gráficos de análise de erro para o teste de erro mínimo inerente ao OpenPose. Fonte: autor



nas componentes x e y que caracterizam o deslocamento nos pontos anatômicos onde há maiores variações de amplitude, ou seja, nos pontos que deslocam de forma significativa durante a execução do movimento, onde a velocidade de execução da abdução não apresentou mudança significativa na precisão das medidas, conforme pode ser apreciado nas métricas obtidas nas tabelas 6 e 7 para os eixos que compõem os pontos do Olécrano e Pulso esquerdo. A Figura 20 ilustra essa similaridade durante a análise de erro conduzida nesses pontos. Podemos visualizar esses resultados também para os gráficos de nuvem de pontos na Figura 21, nos gráficos de correlação cruzada da Figura 22 mostra e por fim, no domínio da frequência, com os gráficos das DFT's dos sinais, que podem ser vistos na Figura 23. Entretanto, para os valores de correlação de Pearson e para as frequências de pico presentes nos dados que compõem o ponto do Acrômio esquerdo (linhas 2,7 e 13 da Tabela 6), pode-se notar tanto valores baixos de correlação (abaixo

Tabela 5 – Valores máximos absolutos do erro de deslocamento para o teste estático do OpenPose.

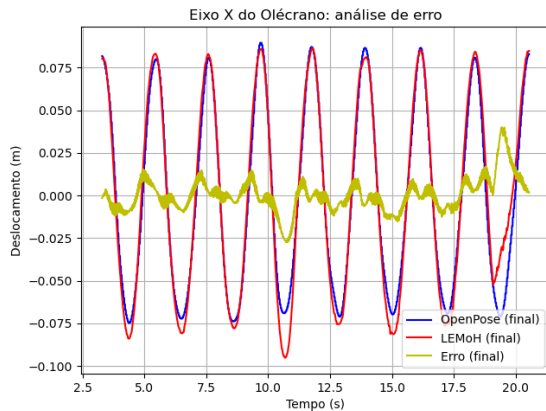
Sujeito	Ponto anatômico	Valor máximo absoluto do erro (m)
A	Acrômio esq. X	0.0033
	Acrômio esq. Y	0.0043
	Olécrano esq. X	0.0048
	Olécrano esq. Y	0.0053
	Pulso esq. X	0.0062
	Pulso esq. Y	0.0090
B	Acrômio esq. X	0.0066
	Acrômio esq. Y	0.0047
	Olécrano esq. X	0.0016
	Olécrano esq. Y	0.0081
	Pulso esq. X	0.0011
	Pulso esq. Y	0.0228
C	Acrômio esq. X	0.0028
	Acrômio esq. Y	0.0022
	Olécrano esq. X	0.0036
	Olécrano esq. Y	0.0037
	Pulso esq. X	0.0039
	Pulso esq. Y	0.0076

de 0.5) quanto diferenças nos valores de frequência, o que aponta o ruído sobrepondo os sinais, devido a baixa amplitude de movimento realizado por esse ponto, o que reflete em uma captura não tão precisa por parte do OpenPose. O mesmo pode ser observado na Tabela 7 nas linhas 1,2, 7 e 13 para as medidas de correlação de Pearson e para as linhas 2 e 7 nas medidas de frequência de pico, todas referentes aos eixos integram o Acrômio esquerdo dos 3 indivíduos. Já nas linhas 8, 10, 12 e 17 da Tabela 6, é possível observar valores altos de erro em relação aos demais (acima de 10 centímetros), o que é causado, nos pontos referentes ao Acrômio, por ruído e artefatos, ao passo que para as linhas 12 e 17, do eixo Y e X do pulso, para os indivíduos B e C, respectivamente, são provenientes de um leve desalinhamento em uma das repetições dentro de 10 executadas em cada velocidade, presente mesmo após as etapas de alinhamento no pós-processamento, porém pequenos em comparação à média de amplitude total do movimento, que é de aproximadamente 38 centímetros.


Prosseguindo com a verificação da semelhança dos dados adquiridos pelos dois sistemas, é possível observar, para a análise da velocidade do deslocamento que os resultados continuam satisfatórios, caso seja observado apenas os pontos em que a amplitude do movimento seja significativa. Os gráficos presentes na Figura 24 ilustram bem isso. O mesmo pode ser visto com a análise da aceleração do deslocamento, conforme a Figura 25 explicita, porém tendo uma pequena queda em relação a qualidade das medidas, devido ser derivada de uma medida que já é estimada, contendo assim um erro propagado. Além disso, como mostrado na Tabela 11, o aumento na velocidade da execução do movimento pelo sujeito fez com que as medidas de

Figura 20 – Gráficos de análise de erro para o deslocamento dos pontos anatômicos com maior amplitude de movimento durante a abdução lateral do braço. Fonte: autor.

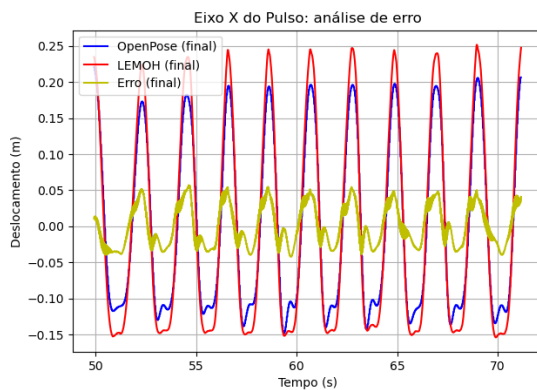
(a) Eixo X do olécrano (lento).



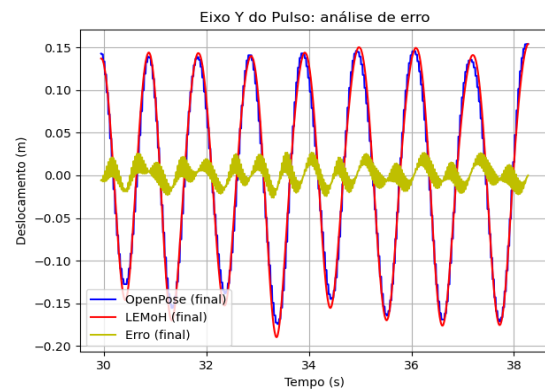
(b) Eixo Y do olécrano (lento).



(c) Eixo X do pulso (rápido).



(d) Eixo Y do pulso (rápido).




aceleração se tornassem um pouco mais precisas. Na Tabela 8 é possível ver uma discrepância nos dados referentes às frequências de pico dos sinais de velocidade para o deslocamento lento, nas linhas 1, 2, 7 e 13, que compreendem o Acrômio esquerdo dos 3 sujeitos, ocasionados pelo ruído sobrepondo esses sinais, pelo fato da amplitude total do movimento ser muito baixa, favorecendo o aumento de erros na detecção. O mesmo pode ser visto na Tabela 9 na linha 13 e nas linhas 1, 2, 7, 8, 13, 15, sendo o da linha 15 devido há uma diferença nas amplitudes máximas, onde o OpenPose possui valor maior na frequência menor ($0.2586Hz$), ao passo que os resultados do LEMOH obtiveram amplitude maior no valor de frequência maior ($0.5431Hz$).

Entretanto, em contraponto com as medidas satisfatórias obtidas para os pontos anatômicos em que se tem uma amplitude significativa no movimento executado, para pontos onde essa amplitude é menor e mais sensível, nesse caso, para o acrômio por exemplo, o OpenPose apresentou dificuldades na determinação do deslocamento com precisão, conforme ilustrado na Figura 26, o que acarretou em medidas piores para velocidade e aceleração desse ponto, conforme mostrado nas figuras 27 e 28.

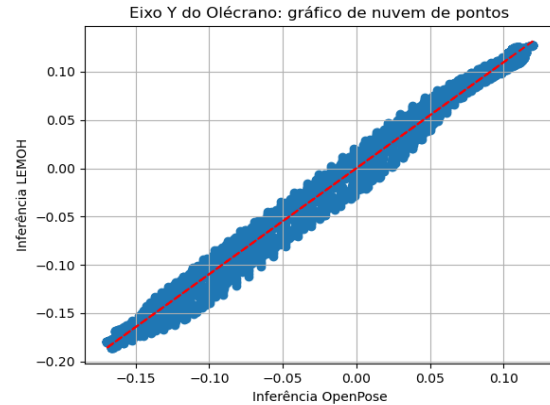
Agora, voltando a atenção para os dados da análise para o ângulo da articulação do

Figura 21 – Gráficos de nuvem de pontos para o deslocamento dos pontos anatômicos com maior amplitude de movimento durante a abdução lateral do braço. Fonte: autor.


(a) Eixo X do olécrano (lento).




(b) Eixo Y do olécrano (lento).



(c) Eixo X do pulso (rápido).




(d) Eixo Y do pulso (rápido).




ombro, podemos visualizar na Tabela 12 que os registros estimados de variação angular ao longo do tempo apresentaram resultado satisfatório, onde o OpenPose conseguiu alcançar amplitudes dessa alteração até maiores que os sinais estimados pelo LEMOH, como ilustrado na Figura 29, obtendo valores de erro bem baixos (abaixo de 36°) comparados a amplitude desses sinais (90° a 180°). Entretanto, quando olhamos para os dados de velocidade angular, na Tabela 13, e aceleração angular, na Tabela 14, estimados a partir dos valores da variação angular, houve uma queda drástica referente a qualidade das informações captadas pelo OpenPose e pelo LEMOH, baixando assim no geral o valor das métricas, conforme é exemplificado nas figuras 30 e 31, referentes à avaliação qualitativa da velocidade e aceleração angular, respectivamente. Isso pode ser visualizado nos valores baixos de SNR na linha 1 do deslocamento rápido da Tabela 13 e na Tabela 14 para os dois tipos de deslocamento, salientando como o erro se propaga de acordo com o nível de derivação dos dados obtidos.

Figura 22 – Gráficos de correlação cruzada para o deslocamento dos pontos anatômicos com maior amplitude de movimento durante a abdução lateral do braço. Fonte: autor.

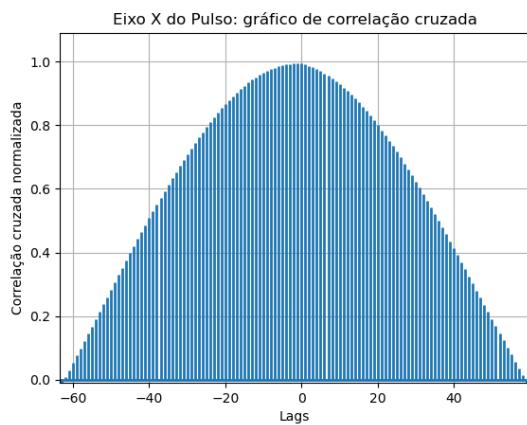
(a) Eixo X do olécrano (lento).



(b) Eixo Y do olécrano (lento).



(c) Eixo X do pulso (rápido).



(d) Eixo Y do pulso (rápido).






Figura 23 – Gráficos no domínio da frequência para o deslocamento dos pontos anatômicos com maior amplitude de movimento durante a abdução lateral do braço. Fonte: autor.


(a) Eixo X do olécrano (lento).



(b) Eixo Y do olécrano (lento).



(c) Eixo X do pulso (rápido).



(d) Eixo Y do pulso (rápido).






Figura 24 – Gráficos de avaliação qualitativa para a velocidade do deslocamento (rápido) do olécrano esquerdo no eixo X durante a abdução lateral do braço. Fonte: autor.


(a) Gráfico de erro para velocidade.



(b) Gráfico de nuvem de pontos para velocidade.



(c) Gráfico de correlação cruzada para velocidade.



(d) Gráfico da DFT para velocidade.


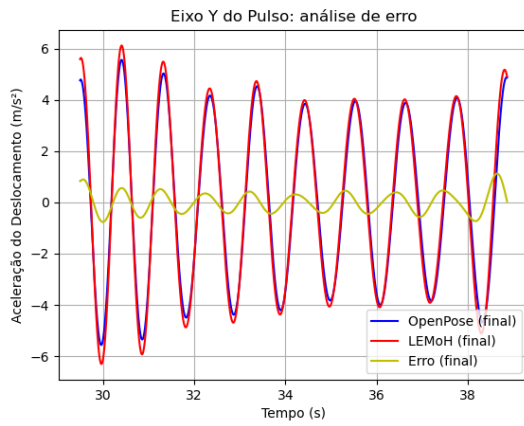



Figura 25 – Gráficos de avaliação qualitativa para a aceleração do deslocamento (rápido) do pulso esquerdo no eixo Y durante a abdução lateral do braço. Fonte: autor.


(a) Gráfico de erro para aceleração.



(b) Gráfico de nuvem de pontos para aceleração.



(c) Gráfico de correlação cruzada para aceleração.



(d) Gráfico da DFT para aceleração.

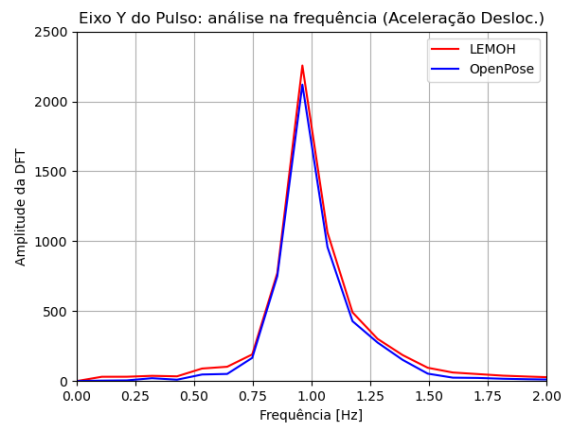




Figura 26 – Gráficos de avaliação qualitativa para o deslocamento (lento) do acrômio esquerdo no eixo Y durante a abdução lateral do braço. Fonte: autor.


(a) Gráfico de erro para o deslocamento.



(b) Gráfico de nuvem de pontos para o deslocamento.



(c) Gráfico de correlação cruzada para o deslocamento.



(d) Gráfico da DFT para o deslocamento.


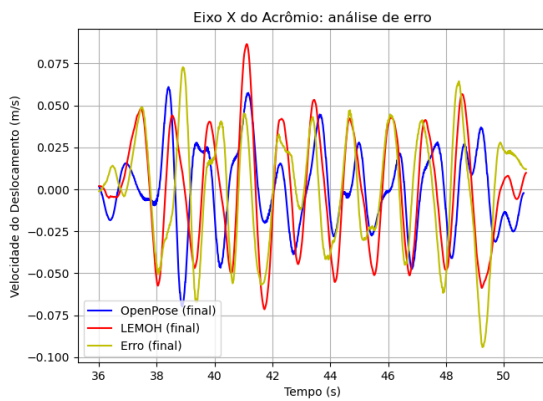



Figura 27 – Gráficos de avaliação qualitativa para a velocidade do deslocamento (rápido) do acrômio esquerdo no eixo X durante a abdução lateral do braço. Fonte: autor.


(a) Gráfico de erro para velocidade.



(b) Gráfico de nuvem de pontos para velocidade.



(c) Gráfico de correlação cruzada para velocidade.



(d) Gráfico da DFT para velocidade.



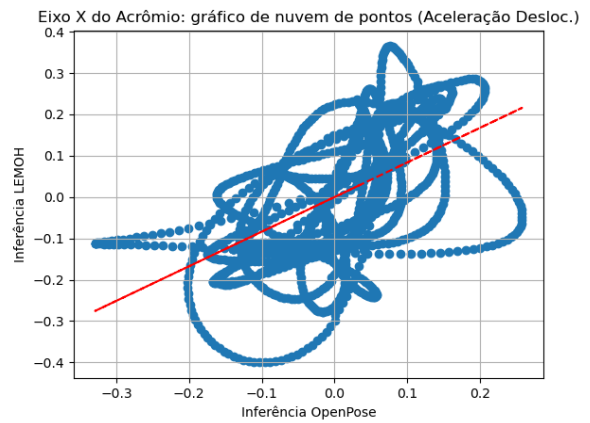


Figura 28 – Gráficos de avaliação qualitativa para a aceleração do deslocamento (rápido) do acrômio esquerdo no eixo X durante a abdução lateral do braço. Fonte: autor.


(a) Gráfico de erro para aceleração.



(b) Gráfico de nuvem de pontos para aceleração.



(c) Gráfico de correlação cruzada para aceleração.



(d) Gráfico da DFT para aceleração.



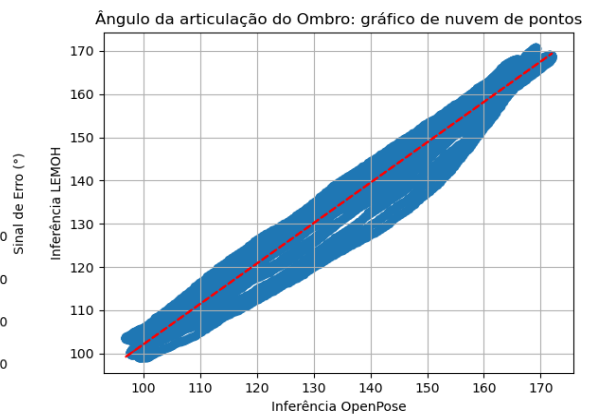


Figura 29 – Gráficos de avaliação qualitativa para a variação angular no deslocamento (lento) do ângulo da articulação do ombro esquerdo durante a abdução lateral do braço. Fonte: autor.


(a) Gráfico de erro para a variação angular.



(b) Gráfico de nuvem de pontos para a variação angular.



(c) Gráfico de correlação cruzada para a variação angular.



(d) Gráfico da DFT para a variação angular.






Figura 30 – Gráficos de avaliação qualitativa para a velocidade angular no deslocamento (lento) do ângulo da articulação do ombro esquerdo durante a abdução lateral do braço. Fonte: autor.


(a) Gráfico de erro para velocidade angular.



(b) Gráfico de nuvem de pontos para velocidade angular.



(c) Gráfico de correlação cruzada para velocidade angular.



(d) Gráfico da DFT para velocidade angular.






Figura 31 – Gráficos de avaliação qualitativa para a aceleração angular no deslocamento (lento) do ângulo da articulação do ombro esquerdo durante a abdução lateral do braço. Fonte: autor.


(a) Gráfico de erro para aceleração angular.




(b) Gráfico de nuvem de pontos para aceleração angular.



(c) Gráfico de correlação cruzada para aceleração angular.



(d) Gráfico da DFT para aceleração angular.



5 CONCLUSÃO

Apesar dos sistemas de análise de movimento humano possuírem grande impacto na indústria e pesquisa nos dias atuais, sua disseminação ainda se concentra apenas no uso de grandes empresas ou no âmbito laboratorial de pesquisadores, sendo pouco aplicado ao grande público. Essa centralização ocorre, em sua maioria, por dois fatores principais: o número de equipamentos necessários para a utilização desse sistema e seu alto custo associado.

Desse modo, a utilização do OpenPose como uma ferramenta no desenvolvimento de um sistema de baixo custo visa superar esses dois problemas, uma vez que há uma diminuição considerável nos equipamentos necessários para utilizá-lo, oferecendo também uma boa resposta com recursos reduzidos, tendo potencial de atingir um público bem maior e impactar vidas de forma positiva, dadas as aplicações importantes que esses sistemas proporcionam. Neste trabalho em questão isso fora comprovado com o sistema de baixo custo atingindo uma correlação acima de 85% em comparação com o sistema de alto padrão presente no LEMOH para os dados de deslocamento, velocidade e aceleração dos pontos anatômicos estudados que contribuem de forma significativa para o movimento executado. Foi obtido ainda uma correlação acima de 80% para os dados estimados de variação, velocidade e aceleração angular entre os sistemas comparados. Os valores de SNR também foram considerados satisfatórios, sendo acima de 8dB para os dados de deslocamento, 4dB para os dados de velocidade e aceleração e por fim, uma média de 7dB para os dados angulares, incluindo velocidade e aceleração. Entretanto, algumas limitações foram observadas que podem afetar diretamente a performance do algoritmo de detecção do OpenPose e, por consequência, a qualidade dos sinais capturados. Tais limitações se referem ao cenário e condições de captura das imagens, como iluminação, poluição por objetos na cena, oclusão de membros do campo de visão da câmera, e contraste das peças de roupa em relação ao cenário de fundo. Além disso, o OpenPose apresenta erro intrínseco a sua aferição, tendo uma leve flutuação, mesmo em pontos estáticos, que deve ser levado em consideração no tratamento desses dados. Esse erro mostrou-se presente quando analisamos pontos anatômicos que não contribuíam de forma significativa para o movimento executado, onde o ruído sobrepôs o sinal, o que prejudicou as medidas sobre esses pontos.

5.0.1 Trabalhos futuros

Como trabalhos futuros, é importante ressaltar a essencialidade de explorar o treinamento das redes do OpenPose para dados mais específicos de aplicação, possibilitando assim uma melhora na qualidade das estimativas geradas por ele, e ter a possibilidade de adicionar ou remover pontos anatômicos do modelo de acordo com a necessidade da aplicação, além de possivelmente contornar o problema do plano anatômico adotado para estudos, uma vez que o OpenPose é treinado majoritariamente utilizando dados do plano frontal. Quanto ao *pipeline* desenvolvido para o tratamento e análise desses sinais, fica evidente a importância da auto-

matização de algumas etapas do processo, como escolha de parâmetros de filtro, seleção de evento e extração de métricas, além da possível implementação dos algoritmos utilizados em um aplicativo de celular para facilitar o uso por pessoas de outras áreas e sem conhecimento técnico, além da utilização da computação em nuvem para diminuir ainda mais o número de equipamentos utilizados.

REFERÊNCIAS

- Aggarwal e Cai 1999 AGGARWAL, J. K.; CAI, Q. Human motion analysis: A review. **Computer vision and image understanding**, Elsevier, v. 73, n. 3, p. 428–440, 1999.
- Anton e Busby 2003 ANTON, H.; BUSBY, R. C. **Contemporary linear algebra**. [S.l.]: Wiley, 2003.
- Brockwell e Davis 2016 BROCKWELL, P. J.; DAVIS, R. A. **Introduction to time series and forecasting**. 3. ed. Cham, Switzerland: Springer International Publishing, 2016. (Springer texts in statistics).
- Cao et al. 2019 Cao, Z. et al. Openpose: Realtime multi-person 2d pose estimation using part affinity fields. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 2019.
- Cao et al. 2017 CAO, Z. et al. **openpose**. 2017. <<https://github.com/CMU-Perceptual-Computing-Lab/openpose>>, note = Acessado em 09 de setembro de 2023.
- Cao et al. 2017 CAO, Z. et al. Realtime multi-person 2d pose estimation using part affinity fields. In: **CVPR**. [S.l.: s.n.], 2017.
- Carse et al. 2013 CARSE, B. et al. Affordable clinical gait analysis: An assessment of the marker tracking accuracy of a new low-cost optical 3d motion analysis system. **Physiotherapy**, Elsevier, v. 99, n. 4, p. 347–351, 2013.
- Colyer et al. 2018 COLYER, S. L. et al. A review of the evolution of vision-based motion analysis and the integration of advanced computer vision methods towards developing a markerless system. **Sports medicine-open**, SpringerOpen, v. 4, n. 1, p. 1–15, 2018.
- Duarte et al. 2022 DUARTE, M. B. et al. Validity and reliability of a smartphone-based assessment for anticipatory and compensatory postural adjustments during predictable perturbations. **Gait & Posture**, v. 96, p. 9–17, 2022. ISSN 0966-6362. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0966636222001278>>.
- E. et al. 2021 E., B. et al. Data-driven gait analysis for diagnosis and severity rating of parkinson’s disease. **Medical Engineering Physics**, v. 91, p. 54–64, 2021. ISSN 1350-4533. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S135045332100028X>>.
- FFTO FFTO, G. de Pesquisa da. Disponível em: <<https://www.ffto.ufpa.br/index.php/grupos-de-pesquisa-da-ffto>>.
- Gouwanda e Senanayake 2008 GOUWANDA, D.; SENANAYAKE, S. M. N. A. Emerging trends of body-mounted sensors in sports and human gait analysis. In: OSMAN, N. A. A. et al. (Ed.). **4th Kuala Lumpur International Conference on Biomedical Engineering 2008**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 715–718. ISBN 978-3-540-69139-6.
- Haykin e Moher HAYKIN, S.; MOHER, M. **SISTEMAS DE COMUNICAÇÃO**. [S.l.: s.n.].

- Hellsten et al. 2021 HELLSTEN, T. et al. The potential of computer vision-based marker-less human motion analysis for rehabilitation. **Rehabilitation Process and Outcome**, v. 10, p. 11795727211022330, 2021. PMID: 34987303. Disponível em: <<https://doi.org/10.1177/11795727211022330>>.
- Herran, Garcia-Zapirain e Mendez-Zorrilla 2014 HERRAN, A. Muro-de-la; GARCIA-ZAPIRAIN, B.; MENDEZ-ZORRILLA, A. Gait analysis methods: An overview of wearable and non-wearable systems, highlighting clinical applications. **Sensors**, v. 14, n. 2, p. 3362–3394, 2014. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/14/2/3362>>.
- Kale e Patil 2016 KALE, G. V.; PATIL, V. H. A study of vision based human motion recognition and analysis. **International Journal of Ambient Computing and Intelligence**, IGI Global, v. 7, n. 2, p. 75–92, jul 2016. Disponível em: <<https://doi.org/10.4018%2Fijaci.2016070104>>.
- Lathi 2007 LATHI, B. P. **Sinais e Sistemas Lineares**. [S.l.: s.n.], 2007.
- LeCun, Bengio e Hinton 2015 LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.
- Liu 2021 LIU, J. Convolutional neural network-based human movement recognition algorithm in sports analysis. **Frontiers in Psychology**, v. 12, 2021. ISSN 1664-1078. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fpsyg.2021.663359>>.
- Moro et al. 2020 MORO, M. et al. Markerless gait analysis in stroke survivors based on computer vision and deep learning: A pilot study. In: **Proceedings of the 35th Annual ACM Symposium on Applied Computing**. New York, NY, USA: Association for Computing Machinery, 2020. (SAC '20), p. 2097–2104. ISBN 9781450368667. Disponível em: <<https://doi.org/10.1145/3341105.3373963>>.
- Muybridge 1887 MUYBRIDGE, E. **Animal locomotion**. [S.l.]: Da Capo Press Cambridge, MA, 1887. v. 534.
- Nieto-Hidalgo et al. 2018 NIETO-HIDALGO, M. et al. **Gait analysis using computer vision based on Cloud Platform and mobile device**. Hindawi, 2018. Disponível em: <<https://www.hindawi.com/journals/misy/2018/7381264/>>.
- Oppenheim, Schafer e Buck 1999 OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. **Discrete-Time Signal Processing**. Second. [S.l.]: Prentice-hall Englewood Cliffs, 1999.
- Pascal and Philipp Russ 2023 Pascal and Philipp Russ. **Simi: reality motion systems**. 2023. Disponível em: <<http://www.simi.com/en/>>.
- Proakis e Manolakis 2006 PROAKIS, J. G.; MANOLAKIS, D. K. **Digital Signal Processing (4th Edition)**. 4. ed. Prentice Hall, 2006. ISBN 0131873741. Disponível em: <<http://www.amazon.com/Digital-Signal-Processing-John-Proakis/dp/0131873741%3FSubscriptionId%3D192BW6DQ43CK9FN0ZGG2%26tag%3Dws%26linkCode%3Dxm2%26camp%3D2025%26creative%3D165953%26creativeASIN%3D0131873741>>.
- Rodrigues et al. 2022 RODRIGUES, L. A. et al. Wearable devices and smartphone inertial sensors for static balance assessment: A concurrent validity study in young adult population. **Journal of Personalized Medicine**, v. 12, n. 7, 2022. ISSN 2075-4426. Disponível em: <<https://www.mdpi.com/2075-4426/12/7/1019>>.

- Shumway e Stoffer 2017 SHUMWAY, R. H.; STOFFER, D. S. **Time series analysis and its applications**. 4. ed. Cham, Switzerland: Springer International Publishing, 2017. (Springer texts in statistics).
- Simon et al. 2017 SIMON, T. et al. Hand keypoint detection in single images using multiview bootstrapping. In: **CVPR**. [S.l.: s.n.], 2017.
- Simonyan e Zisserman 2014 SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.
- Wang, Hu e Tan 2003 WANG, L.; HU, W.; TAN, T. Recent developments in human motion analysis. **Pattern Recognition**, v. 36, n. 3, p. 585–601, 2003. ISSN 0031-3203. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0031320302001000>.
- Wei et al. 2016 WEI, S.-E. et al. Convolutional pose machines. In: **CVPR**. [S.l.: s.n.], 2016.
- Wong, Wong e Lo 2007 WONG, W. Y.; WONG, M. S.; LO, K. H. Clinical applications of sensors for human posture and movement analysis: A review. **Prosthetics and Orthotics International**, v. 31, n. 1, p. 62–75, 2007. PMID: 17365886. Disponível em: <https://doi.org/10.1080/03093640600983949>.
- Zhu e Li 2016 ZHU, X.; LI, K. F. Real-time motion capture: An overview. In: **2016 10th International Conference on Complex, Intelligent, and Software Intensive Systems (CISIS)**. [S.l.: s.n.], 2016. p. 522–525.

6 APÊNDICES

Nesse capítulo estão dispostos os apêndices contando com os diferentes resultados obtidos a partir da coleta de dados realizada no LEMOH.

6.1 Apêndice A - Dados do deslocamento

Neste apêndice são apresentadas as tabelas referentes aos resultados obtidos para os dados de deslocamento comparados entre os sistemas avaliados pelo trabalho.

Tabela 6 – Resultados das métricas para o deslocamento lento realizado pelos sujeitos.

Sujeito	Ponto anatômico	SNR (dB)	Valor absoluto de erro (m)	Valor de correlação de Pearson	Correlação cruzada [lag; score]	Frequências de pico (Hz) [OpenPose; LEMOH]
A	Acrómio eq. X	-3,5386	0.0162	0.5908	-19; 0.6501	0.4884; 0.4884
	Acrómio eq. Y	0.6258	0.0133	0.4172	5; 0.4218	0.9444; 0.4444
	Olécrano eq. X	15.4631	0.0401	0.9867	0; 0.9867	0.4635; 0.4635
	Olécrano eq. Y	11.7975	0.0413	0.9674	-6; 0.9794	0.4627; 0.4627
	Pulso eq. X	14.1047	0.0384	0.9949	-1; 0.9950	0.4635; 0.4635
	Pulso eq. Y	16.1843	0.0377	0.9965	-1; 0.9968	0.4631; 0.4631
B	Acrómio eq. X	-2.1307	0.0852	0.42989	8; 0.4320	0.0397; 0.3571
	Acrómio eq. Y	-2.3689	0.1345	0.6096	-18; 0.6525	0.3314; 0.3682
	Olécrano eq. X	12.45608	0.0649	0.9750	4; 0.9781	0.3612; 0.3612
	Olécrano eq. Y	13.6113	0.1224	0.9810	0; 0.9810	0.3345; 0.3345
	Pulso eq. X	13.8066	0.0808	0.9875	4; 0.9900	0.3632; 0.3632
	Pulso eq. Y	10.6927	0.1796	0.9668	7; 0.9779	0.3679; 0.3679
C	Acrómio eq. X	-0.3345	0.0173	0.0301	-175; 0.2204	0.0263; 0.2633
	Acrómio eq. Y	9.7410	0.0162	0.9599	4; 0.9618	0.2682; 0.2682
	Olécrano eq. X	12.1293	0.0515	0.9700	-12; 0.9857	0.2654; 0.2654
	Olécrano eq. Y	17.4004	0.0403	0.9947	3; 0.9958	0.2649; 0.2649
	Pulso eq. X	11.4468	0.1075	0.9694	13; 0.9890	0.2648; 0.2648
	Pulso eq. Y	16.2422	0.0636	0.9981	0; 0.9981	0.2676; 0.2676

Tabela 7 – Resultados das métricas para o deslocamento rápido realizado pelos sujeitos.

Sujeito	Ponto anatômico	SNR (dB)	Valor absoluto de erro (m)	Valor de correlação de Pearson	Correlação cruzada [lag; score]	Frequências de pico (Hz) [OpenPose; LEMOH]
A	Acrómio eq. X	-3,5993	0.0179	0.4931	106; 0.7109	0.9669; 0.9669
	Acrómio eq. Y	-0.0174	0.0203	0.0380	-87; 0.3719	0.0971; 0.9709
	Olécrano eq. X	10.7482	0.0568	0.9607	2; 0.9667	0.9457; 0.9457
	Olécrano eq. Y	10.3540	0.0446	0.9715	-1; 0.9729	0.9634; 0.9634
	Pulso eq. X	11.2856	0.0519	0.9630	3; 0.9748	0.9590; 0.9590
	Pulso eq. Y	19.6064	0.0268	0.9949	0; 0.9948	0.9590; 0.9590
B	Acrómio eq. X	0.5915	0.0225	0.5122	15; 0.5514	0.0753; 0.8281
	Acrómio eq. Y	2.0800	0.0215	0.8480	-6; 0.8728	0.8081; 0.8081
	Olécrano eq. X	13.4286	0.0397	0.9788	1; 0.9796	0.7973; 0.7973
	Olécrano eq. Y	12.3289	0.0550	0.9707	-2; 0.9749	0.7968; 0.7968
	Pulso eq. X	13.0330	0.0827	0.9752	0; 0.9752	0.7963; 0.7963
	Pulso eq. Y	12.3192	0.0899	0.9820	0; 0.9820	0.8054; 0.8054
C	Acrómio eq. X	0.1882	0.0190	0.2170	-19; 0.2546	0.5242; 0.4766
	Acrómio eq. Y	9.6627	0.0138	0.9628	-1; 0.9634	0.4720; 0.4720
	Olécrano eq. X	19.6517	0.0269	0.9948	0; 0.9948	0.4697; 0.4697
	Olécrano eq. Y	13.4627	0.0586	0.9828	-6; 0.9926	0.4732; 0.4732
	Pulso eq. X	14.0731	0.0571	0.9939	-1; 0.9942	0.4704; 0.4704
	Pulso eq. Y	13.4451	0.0905	0.9896	-4; 0.9955	0.4720; 0.4720

6.2 Apêndice B - Dados da velocidade do deslocamento

Neste segundo apêndice são apresentadas as tabelas referentes aos resultados obtidos para os dados de velocidade do deslocamento comparados entre os sistemas avaliados pelo trabalho.

Tabela 8 – Resultados das métricas para a velocidade do deslocamento lento realizado pelos sujeitos.

Sujeito	Ponto anatômico	SNR (dB)	Valor absoluto de erro (m/s)	Valor de correlação de Pearson	Correlação cruzada [lag; score]	Frequências de pico (Hz) [OpenPose; LEMOH]	
A	Acrômio esq. X	-5.9001	0.0685	0.5872	6; 0.6116	0.9137; 0.4873	
	Acrômio esq. Y	0.1097	0.0510	0.2218	-8; 0.2388	0.9235; 0.4617	
	Olécrano esq. X	12.9937	0.1511	0.9751	0; 0.9751	0.4609; 0.4609	
	Olécrano esq. Y	9.7521	0.1127	0.9503	6; 0.9641	0.4615; 0.4615	
	Pulso esq. X	10.9323	0.2416	0.9668	4; 0.9723	0.4647; 0.4647	
	Pulso esq. Y	15.9612	0.1092	0.9947	1; 0.9948	0.4615; 0.4615	
	Acrômio esq. X	-6.3949	0.3153	0.1487	0; 0.1487	1.2534; 0.3581	
	Acrômio esq. Y	-7.0764	0.4399	0.3811	-16; 0.4098	0.3565; 0.3565	
	Olécrano esq. X	10.4677	0.2406	0.9553	-7; 0.9703	0.3515; 0.3515	
	Olécrano esq. Y	8.4508	0.5098	0.9258	-3; 0.9279	0.3607; 0.3607	
B	Pulso esq. X	12.7700	0.2028	0.9830	1; 0.9831	0.3486; 0.3486	
	Pulso esq. Y	10.3305	0.5442	0.9589	-2; 0.9595	0.3608; 0.3608	
	Acrômio esq. X	0.3787	0.0317	0.3071	-5; 0.3098	0.7922; 0.2811	
	Acrômio esq. Y	4.7476	0.0450	0.8689	17; 0.9081	0.2638; 0.2638	
	Olécrano esq. X	15.5378	0.0634	0.9862	-8; 0.9950	0.2581; 0.2581	
	Olécrano esq. Y	15.7370	0.0718	0.9955	-3; 0.9968	0.2596; 0.2596	
	Pulso esq. X	9.4756	0.3033	0.9486	-16; 0.9891	0.2571; 0.2571	
	Pulso esq. Y	13.8713	0.1584	0.9953	-2; 0.9958	0.2628; 0.2628	
	C	Acrômio esq. X	-5.9001	0.0685	0.5872	6; 0.6116	0.9137; 0.4873
		Acrômio esq. Y	0.1097	0.0510	0.2218	-8; 0.2388	0.9235; 0.4617
Olécrano esq. X		12.9937	0.1511	0.9751	0; 0.9751	0.4609; 0.4609	
Olécrano esq. Y		9.7521	0.1127	0.9503	6; 0.9641	0.4615; 0.4615	
Pulso esq. X		10.9323	0.2416	0.9668	4; 0.9723	0.4647; 0.4647	
Pulso esq. Y		15.9612	0.1092	0.9947	1; 0.9948	0.4615; 0.4615	
Acrômio esq. X		-6.3949	0.3153	0.1487	0; 0.1487	1.2534; 0.3581	
Acrômio esq. Y		-7.0764	0.4399	0.3811	-16; 0.4098	0.3565; 0.3565	
Olécrano esq. X		10.4677	0.2406	0.9553	-7; 0.9703	0.3515; 0.3515	
Olécrano esq. Y		8.4508	0.5098	0.9258	-3; 0.9279	0.3607; 0.3607	

Tabela 9 – Resultados das métricas para a velocidade do deslocamento rápido realizado pelos sujeitos.

Sujeito	Ponto anatômico	SNR (dB)	Valor absoluto de erro (m/s)	Valor de correlação de Pearson	Correlação cruzada [lag; score]	Frequências de pico (Hz) [OpenPose; LEMOH]	
A	Acrômio esq. X	-3.9572	0.0994	0.5484	-16; 0.7606	0.9712; 0.9712	
	Acrômio esq. Y	0.2370	0.1037	0.3403	106; 0.3851	0.9600; 0.9600	
	Olécrano esq. X	11.9339	0.2748	0.9757	-1; 0.9770	0.9541; 0.9541	
	Olécrano esq. Y	10.6771	0.2127	0.9778	0; 0.9778	0.9686; 0.9686	
	Pulso esq. X	12.4514	0.2529	0.9729	3; 0.9814	0.9515; 0.9515	
	Pulso esq. Y	13.6745	0.3358	0.9784	3; 0.9869	0.9600; 0.9600	
	Acrômio esq. X	1.2240	0.0729	0.5238	-143; 0.5445	0.8108; 0.8108	
	Acrômio esq. Y	-0.7223	0.1530	0.6459	-13; 0.7617	0.8098; 0.8098	
	Olécrano esq. X	17.2978	0.1369	0.9953	-1; 0.9961	0.8245; 0.8245	
	Olécrano esq. Y	18.9077	0.1022	0.9936	0; 0.9936	0.7833; 0.7833	
B	Pulso esq. X	6.6473	0.4921	0.9907	2; 0.9936	0.8214; 0.8214	
	Pulso esq. Y	4.7858	0.7117	0.9599	-5; 0.9791	0.7777; 0.7777	
	Acrômio esq. X	-0.0209	0.0465	0.1429	42; 0.5142	0.9488; 0.4970	
	Acrômio esq. Y	7.8848	0.0395	0.9421	0; 0.9421	0.4817; 0.4817	
	Olécrano esq. X	16.3131	0.0861	0.9895	3; 0.9936	0.4708; 0.4708	
	Olécrano esq. Y	15.6547	0.1155	0.9977	-1; 0.9979	0.4815; 0.4815	
	Pulso esq. X	12.4772	0.2187	0.9871	2; 0.9893	0.4706; 0.4706	
	Pulso esq. Y	13.7449	0.2154	0.9980	0; 0.9980	0.4815; 0.4815	
	C	Acrômio esq. X	-3.9572	0.0994	0.5484	-16; 0.7606	0.9712; 0.9712
		Acrômio esq. Y	0.2370	0.1037	0.3403	106; 0.3851	0.9600; 0.9600
Olécrano esq. X		11.9339	0.2748	0.9757	-1; 0.9770	0.9541; 0.9541	
Olécrano esq. Y		10.6771	0.2127	0.9778	0; 0.9778	0.9686; 0.9686	
Pulso esq. X		12.4514	0.2529	0.9729	3; 0.9814	0.9515; 0.9515	
Pulso esq. Y		13.6745	0.3358	0.9784	3; 0.9869	0.9600; 0.9600	
Acrômio esq. X		1.2240	0.0729	0.5238	-143; 0.5445	0.8108; 0.8108	
Acrômio esq. Y		-0.7223	0.1530	0.6459	-13; 0.7617	0.8098; 0.8098	
Olécrano esq. X		17.2978	0.1369	0.9953	-1; 0.9961	0.8245; 0.8245	
Olécrano esq. Y		18.9077	0.1022	0.9936	0; 0.9936	0.7833; 0.7833	

6.3 Apêndice C - Dados da aceleração do deslocamento

Neste terceiro apêndice são apresentadas as tabelas referentes aos resultados obtidos para os dados de aceleração do deslocamento comparados entre os sistemas avaliados pelo trabalho.

Tabela 10 – Resultados das métricas para a aceleração do deslocamento lento realizado pelos sujeitos.

Sujeito	Ponto anatômico	SNR (dB)	Valor absoluto de erro (m/s ²)	Valor de correlação de Pearson	Correlação cruzada [lag; score]	Frequências de pico (Hz) [OpenPose; LEMOH]
A	Acrômio esq. X	-10.3109	0.4058	0.1535	-123; 0.1568	1.3158; 0.4737
	Acrômio esq. Y	0.1064	0.1836	0.2821	13; 0.4268	0.9456; 0.4728
	Olécrano esq. X	7.7260	0.5859	0.9124	8; 0.9358	0.4602; 0.4602
	Olécrano esq. Y	5.2573	0.4090	0.8803	-6; 0.8998	0.4637; 0.4637
	Pulso esq. X	9.6648	0.6426	0.9461	-7; 0.9713	0.4800; 0.4800
	Pulso esq. Y	13.7956	0.4650	0.9879	0; 0.9879	0.4598; 0.4598
B	Acrômio esq. X	-12.2910	1.6787	0.0553	112; 0.1034	1.2260; 0.4087
	Acrômio esq. Y	-11.1987	2.1521	0.2627	-11; 0.2857	1.2342; 0.3526
	Olécrano esq. X	6.3836	1.1231	0.8823	3; 0.8890	0.3533; 0.3533
	Olécrano esq. Y	5.2095	2.1515	0.8510	-3; 0.8573	0.3597; 0.3597
	Pulso esq. X	9.8253	0.8544	0.9526	2; 0.9564	0.3519; 0.3519
	Pulso esq. Y	5.5425	2.2299	0.8555	-10; 0.9022	0.3580; 0.3580
C	Acrômio esq. X	-1.9095	0.1004	0.1628	-135; 0.4478	0.8121; 0.2707
	Acrômio esq. Y	-0.6038	0.1125	0.6115	-20; 0.6772	0.5224; 0.5224
	Olécrano esq. X	10.6358	0.2398	0.9600	4; 0.9657	0.2586; 0.5431
	Olécrano esq. Y	10.8218	0.2965	0.9752	-5; 0.9807	0.2617; 0.2617
	Pulso esq. X	7.0555	0.6090	0.9005	-14; 0.9733	0.5431; 0.5431
	Pulso esq. Y	7.1168	0.8026	0.9112	1; 0.9117	0.2725; 0.2725

Tabela 11 – Resultados das métricas para a aceleração do deslocamento rápido realizado pelos sujeitos.

Sujeito	Ponto anatômico	SNR (dB)	Valor absoluto de erro (m/s ²)	Valor de correlação de Pearson	Correlação cruzada [lag; score]	Frequências de pico (Hz) [OpenPose; LEMOH]
A	Acrômio esq. X	-1.2305	0.4442	0.8329	-7; 0.8905	0.9800; 0.9800
	Acrômio esq. Y	0.3525	0.4933	0.4589	102; 0.5242	1.4004; 0.9695
	Olécrano esq. X	11.3179	1.0516	0.9677	-3; 0.9830	0.9695; 0.9695
	Olécrano esq. Y	11.3281	0.8046	0.9759	3; 0.9847	0.9651; 0.9651
	Pulso esq. X	12.7748	1.4511	0.9786	-2; 0.9863	0.9609; 0.9609
	Pulso esq. Y	18.5786	1.1242	0.9951	0; 0.9951	0.9609; 0.9609
B	Acrômio esq. X	1.5450	0.3751	0.5579	147; 0.5830	0.7777; 0.7777
	Acrômio esq. Y	4.7600	0.2983	0.9191	8; 0.9742	0.8044; 0.8044
	Olécrano esq. X	8.5097	1.1737	0.9283	9; 0.9931	0.8189; 0.8189
	Olécrano esq. Y	13.9525	0.6291	0.9800	4; 0.9933	0.8093; 0.8093
	Pulso esq. X	6.0038	2.5677	0.9675	5; 0.9901	0.8184; 0.8184
	Pulso esq. Y	4.6687	3.3196	0.9668	5; 0.9922	0.7762; 0.7762
C	Acrômio esq. X	-0.0299	0.1546	0.1829	-8; 0.1903	0.7253; 0.4987
	Acrômio esq. Y	6.0386	0.1503	0.9050	2; 0.9067	0.4872; 0.4872
	Olécrano esq. X	8.9203	0.4935	0.9451	-6; 0.9681	0.4835; 0.4835
	Olécrano esq. Y	11.3201	0.5997	0.9899	0; 0.9899	0.4874; 0.4874
	Pulso esq. X	7.3887	1.5190	0.9323	-8; 0.9754	0.4946; 0.4946
	Pulso esq. Y	10.1493	1.2095	0.9882	2; 0.9898	0.4872; 0.4872

6.4 Apêndice D - Dados das medidas angulares

Neste quarto apêndice são apresentadas as tabelas referentes aos resultados obtidos para os dados de variação, velocidade e aceleração angulares comparados entre os sistemas avaliados pelo trabalho.

Tabela 12 – Resultados das métricas para a variação angular do deslocamento lento e rápido realizados pelos sujeitos.

Deslocamento lento							
Sujeito	Ponto anatômico	SNR (dB)	Valor máximo absoluto do erro (°)	Valor de correlação de Pearson	Correlação cruzada [lag; score]	Frequências de pico (Hz) [OpenPose; LEMOH]	
A	Articulação do ombro esq.	6.0418	32.7117	0.9863	0; 0.9994	0.4584; 0.4584	
B	Articulação do ombro esq.	11.8738	18.6512	0.9677	0; 0.9990	0.3613; 0.3613	
C	Articulação do ombro esq.	15.5276	13.1590	0.9884	0; 0.9996	0.2650; 0.2650	
Deslocamento rápido							
Sujeito	Ponto anatômico	SNR (dB)	Valor máximo absoluto do erro (°)	Valor de correlação de Pearson	Correlação cruzada [lag; score]	Frequências de pico (Hz) [OpenPose; LEMOH]	
A	Articulação do ombro esq.	1.9572	35.7847	0.9522	0; 0.9987	0.9739; 0.9739	
B	Articulação do ombro esq.	12.8527	14.8609	0.9739	0; 0.9995	0.7973; 0.7973	
C	Articulação do ombro esq.	10.9497	14.9276	0.9631	0; 0.9988	0.4566; 0.4566	

Tabela 13 – Resultados das métricas para a velocidade angular do deslocamento lento e rápido realizados pelos sujeitos.

Deslocamento lento							
Sujeito	Ponto anatômico	SNR (dB)	Valor máximo absoluto do erro (rad/s)	Valor de correlação de Pearson	Correlação cruzada [lag: score]	Frequências de pico (Hz) [OpenPose; LEMOH]	
A	Articulação do ombro esq.	5.9025	0.9060	0.9805	-2; 0.9811	0.4584; 0.4584	
B	Articulação do ombro esq.	8.8184	1.0080	0.9321	10; 0.9511	0.3613; 0.3613	
C	Articulação do ombro esq.	13.1144	0.5664	0.9781	-6; 0.9819	0.2650; 0.2650	
Deslocamento rápido							
Sujeito	Ponto anatômico	SNR (dB)	Valor máximo absoluto do erro (rad/s)	Valor de correlação de Pearson	Correlação cruzada [lag: score]	Frequências de pico (Hz) [OpenPose; LEMOH]	
A	Articulação do ombro esq.	1.8503	2.4841	0.9308	-2; 0.9348	0.9739; 0.9739	
B	Articulação do ombro esq.	10.3064	1.9703	0.9527	0; 0.9526	0.7973; 0.7973	
C	Articulação do ombro esq.	10.2689	1.0054	0.9562	7; 0.9700	0.4566; 0.4566	

Tabela 14 – Resultados das métricas para a aceleração angular do deslocamento lento e rápido realizados pelos sujeitos.

Deslocamento lento							
Sujeito	Ponto anatômico	SNR (dB)	Valor máximo absoluto do erro (rad/s ²)	Valor de correlação de Pearson	Correlação cruzada [lag: score]	Frequências de pico (Hz) [OpenPose; LEMOH]	
A	Articulação do ombro esq.	4.1590	3.9322	0.9025	-2; 0.9033	0.4584; 0.4584	
B	Articulação do ombro esq.	4.1400	4.8161	0.7911	13; 0.8255	0.3613; 0.3613	
C	Articulação do ombro esq.	7.1348	1.5608	0.9054	-5; 0.9075	0.2650; 0.2650	
Deslocamento rápido							
Sujeito	Ponto anatômico	SNR (dB)	Valor máximo absoluto do erro (rad/s ²)	Valor de correlação de Pearson	Correlação cruzada [lag: score]	Frequências de pico (Hz) [OpenPose; LEMOH]	
A	Articulação do ombro esq.	1.2287	16.9244	0.8334	-3; 0.8439	0.9739; 0.9739	
B	Articulação do ombro esq.	5.1720	14.1457	0.8613	0; 0.8613	0.7973; 0.7973	
C	Articulação do ombro esq.	6.7700	4.7093	0.8963	7; 0.9104	0.4566; 0.4566	