



Universidade de Brasília - UnB  
Faculdade UnB Gama - FGA  
Engenharia Eletrônica

**Análise e Classificação *Online* e *Offline* de  
Forma Automática do Movimento Humano de  
Sentar e Levantar com Informações de IMU**

Autor: Pedro Augusto Ferreira da Silva  
Orientador: Roberto de Souza Baptista

Brasília, DF  
Maio de 2021





Pedro Augusto Ferreira da Silva

**Análise e Classificação *Online* e *Offline* de Forma Automática do Movimento Humano de Sentar e Levantar com Informações de IMU**

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica.

Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Orientador: Roberto de Souza Baptista

Brasília, DF

Maior de 2021

Pedro Augusto Ferreira da Silva

## **Análise e Classificação *Online* e *Offline* de Forma Automática do Movimento Humano de Sentar e Levantar com Informações de IMU**

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica.

Trabalho aprovado. Brasília, DF, :



---

**Roberto de Souza Baptista**  
Orientador



---

**(Claudia Patricia Ochoa Diaz)**  
Convidado 1



---

**(Amilton Vieira)**  
Convidado 2

Brasília, DF  
Maio de 2021

# Agradecimentos

Gostaria de agradecer, primeiramente a Deus, por todo o aprendizado que adquiri, pelas pessoas incríveis presentes na minha vida e pela minha saúde. Agradeço também à minha mãe e ao meu pai, ao meu padrinho e à minha madrinha, pessoas que se esforçaram para possibilitar os meus estudos e que são fonte das minhas inspirações. Eu gostaria de fazer um agradecimento ainda mais especial ao meu padrinho, Ubiratan, pois desde sempre, me ensinou a ser uma pessoa que busca ser justa, me ensinou sobre o tipo de profissional que eu quero ser, que não poupou esforço para me fornecer o melhor possível para os meus estudos, que abriu mão de fazer coisas em seu benefício para me incentivar a buscar conhecimento e para cuidar da minha saúde, é o meu maior exemplo.

Também agradeço à Gabriela Barbosa, minha companheira e grande amiga, que sempre acreditou em mim, me incentivou, me inspirou e não me deixou desanimar quando eu já estava no limite. Além de todo o apoio, passou e sofreu comigo durante os momentos mais difíceis da minha vida, quando estive com câncer, se atrasou na graduação para não abrir mão de estar do meu lado e me ajudou a passar por esse momento de uma forma um pouco mais leve.

Aos meus familiares, Maria Rosa, Dulcineia, Dorgival, Gabriela, ao meu padrinho Jhonatan, aos amigos maravilhosos que fiz, Lucas Jordão, Matheus Arcoverde, Gabriel Jordão, Breno, Benedito, Mateus, Igor, Vinícius, Camila, Francileide, Larissa, entre tantas outras pessoas incríveis que conheci, que me incentivaram, acreditaram, me inspiraram a ser melhor como pessoa e que, de certa forma, moldaram um pouco da pessoa que sou hoje.

Agradeço à minha instituição de ensino, Universidade de Brasília, à assistência estudantil, que me possibilitou continuar lutando para ser graduado pela universidade dos meus sonhos. Agradeço também, ao meu orientador, por ter me auxiliado, ensinado e acreditado em mim. Por fim, agradeço à todos os professores e professoras incríveis e inspiradores com quem estive o prazer de ter aulas e de participar de projetos.



# Resumo

O movimento é uma componente essencial para vida humana e pode ser influenciado por diversos fatores, então conhecer e entender o comportamento do corpo é uma área imprescindível de estudo para a ciência. Para o movimento de sentar e levantar, existem alguns parâmetros temporais e de angulação que são capazes de indicar fragilidades do ser humano, mais especificamente relacionadas à área definida entre o tronco e os membros inferiores. Esse trabalho se propõe a realizar a análise e classificação automática do movimento de sentar e levantar, utilizando um banco de dados disponibilizado para pesquisa, a partir de dois métodos de segmentação automática, sendo um *offline* e o outro *online*. Para o método de segmentação automática *offline*, utilizou-se o algoritmo *Dynamic Time Warping*, o qual realiza uma comparação entre duas séries temporais, sendo uma série de referência e a outra série o alvo, onde a série alvo seria o dado a ser correlacionado à referência para a extração das informações de interesse. Para o método de segmentação automática *online*, utilizou-se o algoritmo *Interacting Multiple Model*, o qual utiliza-se de modelos de filtros de Kalman para cada modo do movimento, gerando uma probabilidade de qual modelo melhor representa o estado atual do movimento. Para os dois métodos de classificação, foram realizadas uma comparação com dados segmentados manualmente, extraíndo métricas da qualidade dos classificadores utilizados, além das métricas dos movimentos objeto de estudo.

**Palavras-chaves:** Análise Automática de Movimento, Sentar, Levantar, Dynamic Time Warping, Filtro de Kalman, Cadeia de Markov, Interacting Multiple Model.



# Abstract

Movement is an essential component for human life and can be influenced by several factors, therefore knowing and understanding the behavior of the human body is an essential area of study. There are some temporal and angulation parameters, for the movement of sitting and standing that are capable of indicating weaknesses, more specifically related to the groups between the trunk and the lower limbs. This work aims to perform an analysis and classification of the movement of sitting and standing, thus it was used a database available for research, using two methods of automatic segmentation, one offline and the other online. For the offline automatic selection method, the Dynamic Time Warping algorithm is used to compare two time series, one reference series and the other target series, where the target series it would be the data to be correlated to the reference for the extraction of the information of interest. Now, for the online automatic selection method, the Interacting Multiple Model algorithm is used, which uses Kalman filter models for each movement mode, generating a probability of which model best represents the current state of the movement. For both classification methods, a comparison with manually segmented data was evaluated, extracting metrics of the quality of the classifiers used, in addition to the metrics of the movements object of study.

**Key-words:** Automatic Motion Analysis, Sitting, Lifting, Dynamic Time Warping, Kalman Filter, Markov Chain, Interacting Multiple Model.



# Lista de ilustrações

Figura 1 – Comparação da resposta em frequência de diferentes ordens do filtro <i>Butterworth</i> . . . . .	24
Figura 2 – Na sequencia, da esquerda para direita estão as séries temporais, sua correspondência ideal e por fim sua correspondência não ideal. Adaptado de (SALVADOR; CHAN, 2007) . . . . .	26
Figura 3 – Custo cumulativo $D(i, j)$ da matriz representando duas séries temporais (SALVADOR; CHAN, 2007) . . . . .	27
Figura 4 – Diagrama do modelo de estados da aplicação do filtro de Kalman (LABBE, 2014). . . . .	30
Figura 5 – Exemplo de uma etapa da aplicação do filtro de Kalman (LABBE, 2014). . . . .	30
Figura 6 – Exemplo do início do processo que causa a explosão combinatória. . . . .	31
Figura 7 – Exemplo das transições de estados de uma cadeia de Markov. . . . .	33
Figura 8 – Posições aproximadas das IMUs para aquisição de dados de movimento dos voluntários. . . . .	38
Figura 9 – Posições aproximadas dos sensores utilizados para o estudo, representados pelo retângulo branco. . . . .	39
Figura 10 – Diferenças de assentos para o movimento de sentar e levantar fornecidos por (GHORBANI et al., 2020). . . . .	40
Figura 11 – Fases do movimento do sit-to-stand (SCHENKMAN et al., 1990). . . . .	41
Figura 12 – Fases do movimento levantar definido para o desenvolvimento desse projeto. Adaptado de (SCHENKMAN et al., 1990). . . . .	42
Figura 13 – Fases do movimento sentar definido para o desenvolvimento desse projeto. Adaptado de (SCHENKMAN et al., 1990). . . . .	42
Figura 14 – Resultado do cálculo da densidade espectral de potência do movimento de sentar e levantar da coxa direita para um voluntário escolhido aleatoriamente (voluntário 6). . . . .	44
Figura 15 – Dados de aceleração da coxa direita para o voluntário 6. . . . .	45
Figura 16 – Comparação dos dados da coxa direita do voluntário 6 filtrados em 3Hz e sem filtragem que foram convertidos de aceleração em ângulos. . . . .	46
Figura 17 – Imagem ilustrativa para relacionar as fases do movimento de sentar e levantar com o gráfico obtido após a filtragem e conversão para ângulos dos dados das IMUs do tronco e da coxa. . . . .	47
Figura 18 – Diagrama de blocos para aplicação da segmentação <i>offline</i> do movimento. . . . .	48
Figura 19 – Exemplo aleatório para ilustrar a obtenção do melhor caminho pelo DTW. . . . .	49

Figura 20 – Exemplo de aplicação em um vale com valores de alvo menor que os da referência. . . . .	50
Figura 21 – Diagrama de blocos para a aplicação de segmentação <i>online</i> do movimento. . . . .	52
Figura 22 – Exemplo aleatório para ilustrar a obtenção do melhor caminho pelo DTW. . . . .	53
Figura 23 – Exemplo aleatório para ilustrar a obtenção do melhor caminho pelo DTW. . . . .	55
Figura 24 – Probabilidades de cada modelo (filtro) aplicados de forma errada para o movimento de sentar. . . . .	56
Figura 25 – Probabilidades de cada modelo (filtro) aplicados após a aplicação das matrizes $Q_k$ e $R_k$ . . . . .	56
Figura 26 – Gráficos da densidade espectral de potência para o sinal da coxa esquerda apresentados em escala logarítmica (a) e em escala decimal (b), coxa direita apresentados em escala logarítmica (c) e em escala decimal (d) e do tronco apresentados em escala logarítmica (e) e em escala decimal (f). . . . .	57
Figura 27 – Gráficos da densidade espectral de potência para o sinal da coxa esquerda (a), coxa direita (b) e tronco (c) com um zoom na faixa de 0 a 5 Hz. . . . .	58
Figura 28 – Gráficos de comparação, da conversão dos dados de aceleração para dados ângulos, do sinal filtrado com o sinal não filtrado para a coxa esquerda (a), coxa direita (b) e tronco (c). . . . .	59
Figura 29 – <i>Warping path</i> para os dados de ângulos da coxa esquerda (a), coxa direita (b) e tronco (c). . . . .	60
Figura 30 – Correspondência entre referência e alvo para os dados de ângulos durante o movimento para a coxa esquerda (a), coxa direita (b) e tronco (c). Em vermelho está as ligações de correspondências entre os sinais. . . . .	60
Figura 31 – Gráfico com os pontos de referência do movimento de sentar e levantar rotulados manualmente para o voluntário 52. . . . .	61
Figura 32 – Resultado da aplicação do DTW para o tronco e coxa esquerda com o alvo sendo o voluntário 23 e para o tronco e coxa direita com o alvo sendo o voluntário 21. . . . .	62
Figura 33 – Segmentação das fases do movimento de sentar e levantar para a referência. . . . .	63
Figura 34 – Resultado do DTW aplicado na segmentação das fases do movimento de forma automática. . . . .	64
Figura 35 – Resultado do IMM aplicado aos dados do tronco para o movimento de sentar e levantar. . . . .	67

Figura 36 – Resultado do IMM aplicado aos dados da coxa para o movimento de sentar e levantar. . . . .	67
Figura 37 – Resultado dos atrasos na identificação das transições de fases do movimento do tronco e da coxa para o voluntário 52. . . . .	68
Figura 38 – Gráfico de comparação do sinal do movimento da coxa com os estados obtidos pelas probabilidades geradas pelo IMM para o voluntário 21. . . . .	69
Figura 39 – Resultado da identificação das transições de fases do movimento do tronco e da coxa para o voluntário 52 gerados através de um modelo mais genérico. . . . .	70
Figura 40 – Resultado dos atrasos na identificação das transições de fases do movimento do tronco e da coxa para o voluntário 21, com um algoritmo mais genérico. . . . .	70
Figura 41 – Resultado da segmentação automática e <i>online</i> gerada pelo IMM (azul) em comparação com a segmentação manual (preto), para o voluntário 52. . . . .	71
Figura 42 – Gráfico da relação entre o erro temporal com o erro do ângulo de máxima inclinação do tronco para o movimento de sentar. . . . .	72
Figura 43 – Resultado da segmentação automática e <i>online</i> gerada pelo IMM (azul) em comparação com a segmentação manual (preto), para o voluntário 21. . . . .	72



# Lista de tabelas

Tabela 1 – Descrição estatística de altura, de peso, de IMC e de idade dos voluntários do banco de dados (média(desvio padrão)). . . . .	37
Tabela 2 – Análise de erro da segmentação automática <i>offline</i> das fases do movimento de sentar e levantar (média (desvio padrão)). . . . .	65
Tabela 3 – Análise do tempo para das fases II e III do movimento de sentar e levantar comparando a segmentação manual com a segmentação automática <i>offline</i> (média (desvio padrão)). . . . .	66
Tabela 4 – Análise de erro da segmentação automática <i>online</i> das fases do movimento de sentar e levantar (média (desvio padrão)). . . . .	73
Tabela 5 – Análise do tempo para das fases II e III do movimento de sentar e levantar comparando a segmentação manual com a segmentação automática <i>online</i> (média (desvio padrão)). . . . .	74



# Lista de abreviaturas e siglas

AVC	Acidente Vascular Cerebral
DTW	Dynamic Time Warping
HMM	Hidden Markov Model
IA	Inteligência Artificial
IMC	Índice de Massa Corporal
IMM	Interacting Multiple Model
IMU	Unidade de Medição Inercial



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>19</b>
1.1	Estudos e Aplicações da Análise e Classificação do Movimento Humano	19
1.2	Avanços e Benefícios da Análise e Classificação do Movimento de Sentar e Levantar	20
1.3	Objetivos	22
1.3.1	Objetivos Específicos	22
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>23</b>
2.1	Filtragem através da Análise do Espectro de Potência	23
2.1.1	Densidade Espectral de Potência	23
2.1.2	Filtro Butterworth	24
2.2	Dynamic Time Warping	25
2.3	Filtro de Kalman	28
2.4	Interactive Multiple Modes	31
<b>3</b>	<b>METODOLOGIA</b>	<b>37</b>
3.1	Banco de Dados	37
3.2	Fases do Movimento de Sentar e Levantar	40
3.3	Tratamento dos Dados	43
3.3.1	Filtragem	43
3.3.2	Conversão de Aceleração Para Ângulo	45
3.4	Segmentação <i>Offline</i> das Fases.	46
3.4.1	Aplicação do Dynamic Time Warping	48
3.4.2	Sensibilidade do Dynamic Time Warping	50
3.5	Segmentação <i>Online</i> das Fases.	51
3.5.1	Aplicação do Filtro de Kalman	53
3.5.2	Aplicação do Interacting Multiple Model	54
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>57</b>
4.1	Análise Espectral e Filtragem	57
4.2	Aplicação do Algoritmo DTW	59
4.3	Segmentação Automática <i>Offline</i> das Fases do Movimento de Sentar e Levantar.	63
4.4	Aplicação do Algoritmo IMM	66

4.5	<b>Segmentação Automática <i>Online</i> das Fases do Movimento de Sentar e Levantar.</b> . . . . .	<b>71</b>
5	<b>CONCLUSÃO</b> . . . . .	<b>75</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>77</b>

# 1 Introdução

O estudo do movimento humano é uma área da ciência que visa compreender como as pessoas se movem e os motivos pelos quais esses movimentos podem ser limitados. Estudar sobre o movimento humano é comum em todas as áreas da ciência, onde o entendimento desse fenômeno é aplicado de forma a beneficiar a sociedade. Essas áreas de estudo estão apresentadas de diversas formas, já que o desempenho do movimento humano pode estar atrelado a fatores biológicos (idade, preparo físico e estilo de vida), fatores médicos (lesões e doenças), fatores sociais (oportunidade, formas de motivação) entre outros (ABERNETHY B.; HANRAHAN, 1996).

Para realizar a classificação do movimento são necessários dados que podem ser obtidos por unidade de medição inercial (IMU) (SIDDIQUI; CHAN, 2020), eletromiografia (EMG) (KRASOULIS; VIJAYAKUMAR; NAZARPOUR, 2020), câmera (ALMASI, 2020), *kinect* (KIM; KIM; KWAK, 2017), *smartphone* (ZHUO et al., 2020), *smartwatch* (TCHUENTE; BADDOUR; LEMAIRE, 2020) entre outras.

Cada uma dessas formas de aquisição fornece dados em um formato específico, os quais podem ser tratados para extração da informação desejada. Esses pré-processamentos raramente possuem algum padrão ou estudo sistêmico sobre o seu impacto para o resultado da classificação, por esse motivo, em (BURDACK et al., 2020) foi realizado um estudo da interferência de alguns métodos no resultado do desempenho de classificadores, porém fornece apenas as primeiras recomendações de utilização em aprendizado de máquina.

A aprendizagem de máquina é atualmente uma das linhas de pesquisas mais fortes em relação à análise e classificação automática. Devido ao seu crescente desenvolvimento, existe uma grande quantidade de algoritmos nessa área, dificultando o conhecimento de todas as técnicas (P.C. HAJRA M., 2020).

## 1.1 Estudos e Aplicações da Análise e Classificação do Movimento Humano

A prática de corrida é realizada com movimentos que se repetem ao longo do tempo e com poucas variações, porém em um estudo realizado por (SUDA et al., 2020) foi observado que há diferenças na mecânica do pé de corredores iniciantes e experientes. Esses resultados demonstram que é possível utilizar a classificação de movimento de corrida visando a melhoria de rendimento, assim como para reabilitação e para prevenção de lesões.

Por outro lado, os sistemas de classificação de movimento são muito utilizados para auxiliar pacientes com deficiências locomotoras, um exemplo disso foi trabalhado por (CAI et al., 2020), onde verificou-se que pacientes com AVC tendem a gerar movimentos com compensações, gerando uma dificuldade na reabilitação. Para fazer a verificação, utilizou-se o classificador de máquina de vetores de suporte (SVM) gerando assim o feedback que auxiliou na correção do movimento, mostrando que esse classificador pode ser implementado a um robô para auxiliar na reabilitação de pacientes com AVC. Seguindo essa mesma linha, o estudo (KASHI et al., 2020) construiu um modelo de aprendizagem de máquina, mais precisamente o *random-forest* ou floresta aleatória, com precisão média de 85%. Esse modelo já foi adaptado para uso clínico e residencial de pacientes pós AVC.

Em (YOSHIKAWA; LOSING; DEMIRCAN, 2020), foi recriado em laboratório um ambiente industrial para simular e adquirir os dados de movimento de trabalhadores, a partir disso foi feita a análise postural afim de realizar a avaliação ergonômica do movimento, principalmente em ações em que são necessárias uma alta utilização de força. Adicionalmente, também foi apresentada uma tecnologia robótica que auxilia fisicamente a movimentação do trabalhador, no qual foram utilizado o aprendizado de máquina e visão computacional para trazer a sensibilidade necessária aos movimentos robóticos.

## 1.2 Avanços e Benefícios da Análise e Classificação do Movimento de Sentar e Levantar

O controle e a coordenação do corpo junto com a força muscular são essenciais para o movimento de sentar e levantar, já que são movimentos que fazem a transição de uma posição estável para outra. Além do controle e coordenação dos movimentos do tronco e dos membros inferiores, que são as partes do corpo com maior responsabilidade pela realização destes movimentos, a correção da força muscular durante o movimento também é considerado na avaliação clínica para definir possíveis patologias, de forma que essa análise é muito significativa para avaliar pacientes com limitações funcionais (GALLI et al., 2008). Ainda nesse estudo, foi reunido um grupo de indivíduos saudáveis para gerar dados normativos do movimento de se levantar e para isso foi necessário definir as fases do movimento, gerando dados normativos para esse movimento específico, como por exemplo, para o movimento completo, o tempo médio foi de 2.42 segundos.

Alguns questionários e testes são aplicados para avaliar a função física, porém os resultados são em geral mais qualitativos do que quantitativos e diferenças mais sutis podem não ser detectadas. Falando especificamente sobre o movimento de sentar e levantar, em (MILLOR et al., 2014) podemos observar que a duração da transição do movimento é um dos parâmetros mais utilizados para avaliação em ambientes clínicos, de forma que transições mais longas estão relacionadas a indivíduos frágeis e com alto risco de quedas.

Além disso, dados de inclinação do tronco (TULLY; FOTOHABADI; GALEA, 2005) podem diferenciar níveis de fragilidade. Esses dados podem auxiliar as avaliações dos especialistas clínicos e ajudar na prescrição de determinada ação para correção do possível deficit identificado.

Em estudo realizado com pessoas de 55 anos ou mais e com alguma deficiência locomotora, observou-se que existem diversas doenças e deficiências que afetam a qualidade do movimento, como, por exemplo, acidente vascular cerebral (AVC), doença de Parkinson, insuficiência cardíaca, hipertensão, osteoporose, entre outros (ODDING et al., 2001). Com o objetivo de comparar o movimento de levantar de pacientes saudáveis com os que sofreram AVC, o estudo (SILVA et al., 2017) verificou que o pior desempenho de pacientes que sofreram AVC está relacionado a sua pior capacidade de gerar e transferir o movimento de flexão ao tronco.

O movimento de levantar a partir do estado sentado pode ser auxiliado por assistência robótica, o que é estudado em (LI et al., 2021), onde é utilizado modelos tradicionais de controle e otimização e o reconhecimento da intenção humana com base em inteligência artificial (IA) para gerar informações de trajetórias e da dinâmica do corpo humano durante o movimento. Ainda nessa linha, em (MARTINEZ-HERNANDEZ; DEGHANI-SANIJ, 2019) utilizou-se dados de aceleração de uma unidade de medição inercial (IMU) conectada à coxa dos voluntários, onde uma formulação Bayesiana e um método de análise sequencial são utilizados para fazer a identificação dos movimentos de sentar e levantar. Em ambos os casos, os resultados indicam que os métodos possibilitam a geração de mecanismos para a assistência desses movimentos. Esses equipamentos podem ser excelentes para idosos e pessoas que possuem dificuldades de realizar esses movimentos e, para conseguirem uma maior independência, necessitam de dispositivos capazes de auxiliar a realização desses movimentos com a postura correta, evitando acidentes e sobrecargas (LI et al., 2019).

Para realizar a análise e classificação do movimento humano, podemos ter duas abordagens, uma abordagem *offline* e uma abordagem *online*. Para a primeira abordagem, o objetivo da análise está apenas em obter métricas do movimento de maneira quantitativa, podendo adquirir os dados em um primeiro momento e apenas em um segundo momento realizar a análise. Porém, para obter o *feedback* imediato ou em aplicações que necessitam de respostas em tempo real, como os dispositivos robóticos de auxílio ao movimento comentados anteriormente, é necessário um processamento *online*, ou seja, com resposta quase que simultânea ao movimento.

## 1.3 Objetivos

O objetivo desse trabalho é usar informações extraídas de IMUs, fornecidas pelo banco de dados *MoVi DataSet* (GHORBANI et al., 2020) para classificar, de forma automática, as fases do movimento de sentar e levantar. Para tanto, foi desenvolvido códigos em *python* para obtenção das informações das IMUs contidas no banco de dados e a partir delas, realizar a classificação automática do movimento de sentar e levantar de duas maneiras, uma *offline*, utilizando o algoritmo dynamic time warping (DTW) e outra *online*, utilizando uma combinação de filtro de Kalman com cadeia de Markov que podem ser utilizados para análise de sistemas dinâmicos lineares.

### 1.3.1 Objetivos Específicos

- Acessar o banco de dados cedido por (GHORBANI et al., 2020);
- Realizar a separação dos dados de aceleração para os movimentos de sentar e levantar de todos os voluntários;
- Realizar a filtragem dos dados de aceleração e converter esses dados em ângulos em relação ao solo, ou centro de Terra, de forma a facilitar as segmentações das fases do movimento de sentar e levantar;
- Aplicar de forma automática a segmentação das fases do movimento de sentar e levantar, de forma *offline* utilizando o algoritmo DTW;
- Aplicar de forma automática a segmentação das fases do movimento de sentar e levantar, de forma *online* utilizando uma combinação de filtros de Kalman com cadeia de Markov;
- Extrair métricas de qualidade dos métodos desenvolvidos;

## 2 Referencial Teórico

Este capítulo destina-se a apresentar o referencial teórico que apoia o desenvolvimento deste trabalho. Os temas tratados são: Filtragem através da análise do espectro de potência, tratada na seção, 2.1, DTW, na seção 2.2 e HMM, na seção 2.4.

### 2.1 Filtragem através da Análise do Espectro de Potência

Esta seção apresentará o equacionamento para a obtenção da densidade espectral de potência que ajudará na definição da frequência de corte utilizada no filtro *butterworth* passa-baixas, o qual é equacionando na sequência.

#### 2.1.1 Densidade Espectral de Potência

A potência média de um sinal  $x(t)$  é definida conforme a equação 2.1 (HAYKIN; MOHER, 2009).

$$P = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T |x(t)|^2 dt \quad (2.1)$$

Para obter a distribuição de potência de um sinal no domínio da frequência é necessário aplicar a transformada de Fourier ao sinal. Para um sinal do tipo potência (sinal em que  $P < \infty$ ), a energia é infinita, então o sinal pode não possuir uma transformada de Fourier, portanto, é necessário limita-lo dentro de um intervalo finito, para obter um sinal de energia finita e consequentemente garantir que esse novo sinal ( $x_T(t)$ ) possua uma transformada de Fourier.

A partir desse sinal truncado  $x_T(t)$ , que possui energia finita, é possível escrever a energia de  $x_T(t)$  em termos da sua transformada de Fourier  $X_T(f)$  utilizando o teorema de Rayleigh para a energia, dessa forma temos que:

$$\int_{-\infty}^{\infty} |x_T(t)|^2 dt = \int_{-\infty}^{\infty} |X_T(f)|^2 df \quad (2.2)$$

Em que  $X_T(f)$  é o espectro de amplitude do sinal  $x_T(t)$ . Assim podemos apresentar a equação 2.1 substituindo o sinal  $x(t)$  por  $x_T(t)$ , utilizando a equação 2.2.

$$P = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-\infty}^{\infty} |X_T(f)|^2 df \quad (2.3)$$

A partir da equação 2.3, é possível observar que para P (potência média) ser finita, T deve tender a infinito na mesma taxa que  $|X_T(f)|^2$ . Dessa forma, temos uma integral

convergente para  $T \rightarrow \infty$  e isso permite alterar a ordem das operações de integração e de limite, assim podemos reescrever a equação 2.3 da seguinte forma:

$$P = \int_{-\infty}^{\infty} \left( \lim_{T \rightarrow \infty} \frac{1}{2T} |X_T(f)|^2 \right) df \quad (2.4)$$

Utilizando a equação 2.4, podemos apresentá-la da seguinte forma:

$$P = \int_{-\infty}^{\infty} S_x(f) df \quad (2.5)$$

Onde,

$$S_x(f) = \lim_{T \rightarrow \infty} \frac{1}{2T} |X_T(f)|^2 \quad (2.6)$$

e  $S_x(f)$  é a densidade espectral de potência e o periodograma do sinal é dado por  $\frac{|X_T(f)|^2}{2T}$  (HAYKIN; MOHER, 2009).

### 2.1.2 Filtro Butterworth

Os filtros *Butterworth* foram descritos inicialmente em (BUTTERWORTH et al., 1930) e a sua ideia é ter uma resposta o mais estável possível, com uma sensibilidade uniforme. A sua resposta é plana, não possui *ripple* nem ondulações na banda passante, diferentemente de outras opções de filtros. Além disso, podemos definir diferentes ordens para o filtro de forma a ter uma resposta mais rápida ou mais lenta, a figura 1 exemplifica essas diferentes respostas para cada ordem do filtro *Butterworth* com frequência de corte em 10 Hz. O

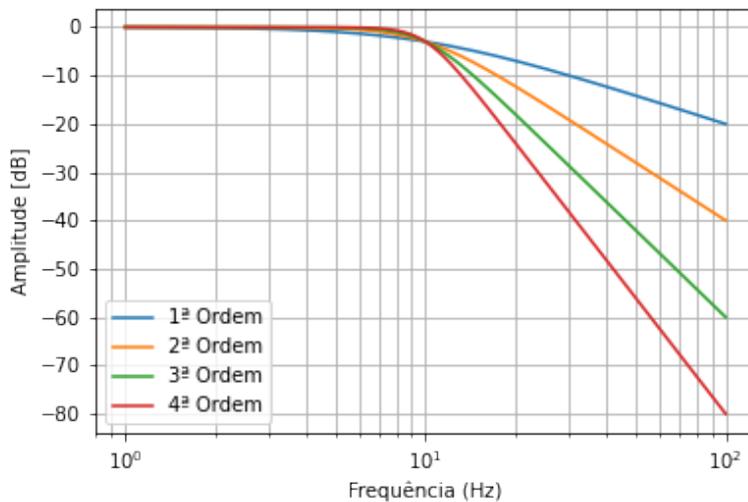


Figura 1 – Comparação da resposta em frequência de diferentes ordens do filtro *Butterworth*.

número de ordens representa o número de polos do filtro que é a quantidade de elementos reativos como capacitores e indutores necessários para a sua implementação.

Claramente os filtros de maiores ordens possuem uma resposta mais próxima da ideal, porém a construção desse filtro é muito mais cara, limitando a aplicação desses filtros à ordens menores em aplicações de baixo custo.

A resposta do ganho do filtro, para a frequência de corte de  $\omega = 1$  radiano por segundo, é apresentada na seguinte equação 2.7:

$$G(\omega) = \frac{1}{\sqrt{1 + \omega^{2n}}} \quad (2.7)$$

Em que  $\omega$  é a frequência angular dada em radianos por segundo e  $n$  é o número da ordem do filtro. Como pode ser observado por 1, a resposta do filtro decresce linearmente, de forma que para cada ordem existe um fator de inclinação, por exemplo, para um filtro de primeira ordem, o ganho por década é de -3dB, para o filtro de segunda ordem é de -6dB por década, enquanto que para um filtro de terceira ordem o ganho é de -9dB por década e assim sucessivamente, incrementando um aumento de -3dB por década para cada ordem acrescentada.

O ganho  $G(\omega)$  de um filtro *Butterworth* passa-baixa de ordem  $n$  é dado em termos da sua função de transferência  $H(j\omega)$  e esse equacionamento é apresentado em 2.8.

$$G^2(\omega) = |H(j\omega)|^2 = \frac{G_0^2}{1 + \left(\frac{j\omega}{j\omega_c}\right)^{2n}} \quad (2.8)$$

Onde  $n$  é a ordem do filtro,  $\omega_c$  é a frequência de corte e  $G_0$  é o ganho DC na frequência zero. Dessa forma, pode-se observar que ao aumentarmos o valor de  $n$  tendendo ao infinito, o ganho vai se aproximando de uma função retângulo e as frequências abaixo de  $\omega_c$  ficarão com o ganho  $G_0$  e as frequências acima de  $\omega_c$  são suprimidas. Para outros valores de  $n$ , existe uma atenuação que varia de forma similar ao apresentado na figura 1.

## 2.2 Dynamic Time Warping

O *Dynamic Time Warping* (DTW) é um algoritmo para comparar e alinhar duas séries temporais de comportamentos semelhantes, onde um sinal é a referência e o outro é o alvo dessa comparação. A intensão é mapear os pontos de maiores semelhanças, para isso, o sinal alvo é comprimido ou estendido, dependendo da variação dos sinais. Dessa maneira, é possível encontrar padrões entre sinais de eventos com diferentes ritmos.

Essas características tornam o DTW um método robusto quanto a frequência, distorção e duração dos sinais. Uma técnica comum é utilizada por algoritmo computacional

que tem como função encontrar o melhor alinhamento entre duas séries temporais independentes. Esse alinhamento é feito através dos pontos de maiores semelhanças entre os dois sinais, de forma que um mesmo ponto de referência pode se alinhar a 1 ou a mais pontos do sinal alvo. Mesmo em sequências do mesmo tamanho, as formas do sinal podem não se alinhar no eixo  $x$ , o algoritmo percorre o eixo  $y$  enquanto distorce o eixo  $x$ , dessa forma cria-se a relação do sinal referência com o alvo da comparação (KEOGH; PAZZANI, 2001). Caso os sinais de referência e de alvo fossem os mesmos, a representação encontrada pelo algoritmo não deve ser distorcida, de forma que cada relação estaria conectada verticalmente em ângulos de  $90^\circ$  (MUDA; BEGAM; ELAMVAZUTHI, 2010).

O algoritmo é sensível a identificação de picos e/ou vales que são mais altos ou mais baixos que a referência, dessa forma, em alguns casos o algoritmo pode não encontrar a correspondência correta (KEOGH; PAZZANI, 2001). A figura 2 é um exemplo de quando o algoritmo DTW não fornece as correspondências corretamente.

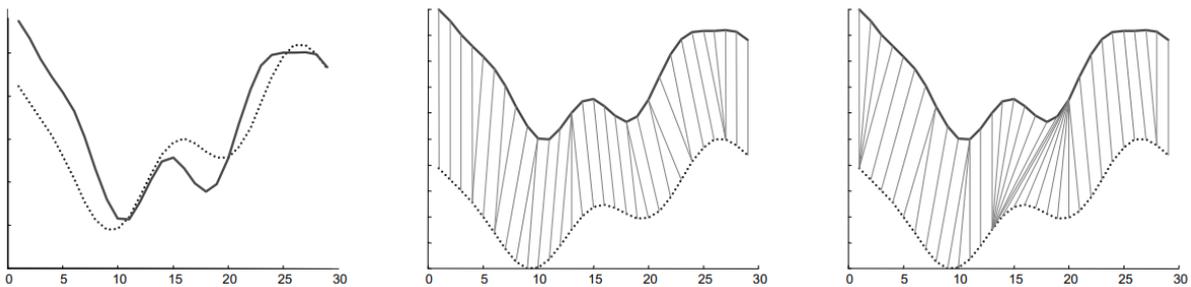


Figura 2 – Na sequência, da esquerda para direita estão as séries temporais, sua correspondência ideal e por fim sua correspondência não ideal. Adaptado de (SALVADOR; CHAN, 2007)

Para encontrar o melhor alinhamento entre as duas séries, vamos supor duas sequências temporais,  $X$  e  $Y$  de tamanhos  $n$  e  $m$ , respectivamente. Supondo que  $X$  esteja no eixo  $x$  e que  $Y$  esteja no eixo  $y$ , podemos mostrar essas séries temporais dispostas em uma matriz, onde essa matriz terá dimensão  $n \times m$  e seus valores são constituídos a partir das distâncias euclidianas entre os sinais.

A distância entre os sinais é dada por  $d(i, j)$ , apresentado na equação 2.9.

$$d(i, j) = (X_i - Y_j)^2 \quad (2.9)$$

Além disso, o algoritmo faz uma comparação entre 3 valores associados ao valor atual, de maneira a identificar o menor valor entre eles. As comparações são entre linha e coluna anterior, entre linha anterior e entre coluna anterior. O resultado da soma da distância métrica com o menor valor é armazenado em  $D(i, j)$ , que é descrito matemati-

camente pela equação 2.10.

$$D(i, j) = d(i, j) + \min[D(i-1, j-1), D(i-1, j), D(i, j-1)] \quad (2.10)$$

A figura 3 representa graficamente as equações apresentadas anteriormente, onde cada elemento  $(i, j)$  da matriz corresponde ao alinhamento entre os pontos  $(X_i, Y_j)$

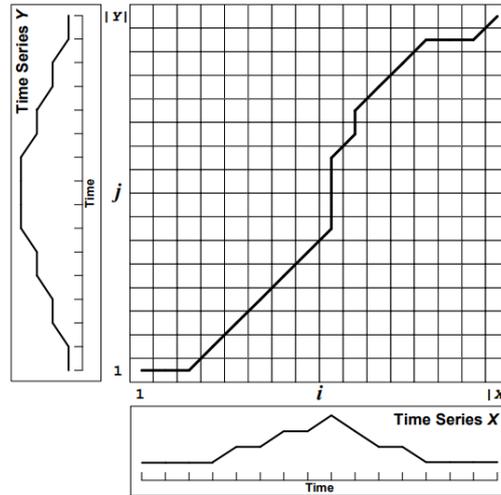


Figura 3 – Custo cumulativo  $D(i, j)$  da matriz representando duas séries temporais (SALVADOR; CHAN, 2007)

O conjunto desses elementos que representam o mapeamento entre as séries é comumente chamado de *Warping Path* e a equação 2.11 apresenta seus valores de forma que  $\omega_K$  é o  $K$ -ésimo elemento da diagonal da matriz.

$$W = \omega_1, \omega_2, \dots, \omega_K \quad (2.11)$$

E de acordo com (KEOGH; PAZZANI, 2001), para encontrar o caminho distorcido  $W$ , é necessário adotar as seguintes condições:

- **Fronteira:** O caminho deve-se iniciar no primeiro elemento  $(X_1, Y_1)$ , canto inferior esquerdo da matriz e finalizar no canto superior direito  $(X_n, Y_m)$ , dessa forma a garantir que toda a matriz é percorrida;
- **Monotonicidade:** É uma forma de garantir que o caminho seja mapeado de forma crescente, ou seja, que o caminho não volta para si mesmo, dessa forma as direções são restringidas a  $(i-1, j-1)$ ,  $(i-1, j)$  e  $(i, j-1)$ ;
- **Continuidade:** Com índices incrementados de forma unitária, percorrendo linhas e/ou colunas, garante-se que nenhum elemento da matriz foi ignorado.

Existem diversos caminhos para satisfazer essas condições, porém pode-se encontrar um caminho que minimiza a distorção e, esse caminho pode ser encontrado através da distância cumulativa  $D(i, j)$  definida pela equação 2.10, onde a distância cumulativa é a soma da distância  $d(i, j)$  e o valor dos elementos adjacentes ao elemento atual.

## 2.3 Filtro de Kalman

Em 1960 foi publicado o artigo (KALMAN, 1960), onde é descrita uma solução recursiva para o problema de filtragem linear discreta. Desde então, com o avanço do poder computacional, o filtro de Kalman tem sido objeto de diversas pesquisas e aplicações (JULIER; UHLMANN, 1997), como por exemplo, no rastreamento da trajetória de partículas ou objetos no espaço (WENG; KUO; TU, 2006) e na análise de movimento humano (BAPTISTA; Bó; HAYASHIBE, 2017).

Na física, sistemas dinâmicos, como os observados nesse trabalho (movimento humano de sentar e levantar), podem ser representados por um modelo em espaço de estados que é baseado em entradas, em saídas e em um conjunto de variáveis de estados que descrevem completamente o movimento no tempo.

Assumindo que as variáveis são amostradas no tempo, que este é um sistema causal, o qual só depende de entradas de estados passados e que o sistema pode ser definido por equações lineares invariáveis de dimensões finitas, a equação 2.12 pode definir o modelo de predição de estados.

O filtro de Kalman pode ser definido por equações de predição e de atualização. Na predição usa-se a estimativa do estado anterior para obter uma estimativa do estado no tempo atual, chamada de estimativa *a priori*, a qual não inclui informação do estado atual. A predição do estado e a predição da covariância estão definidos nas equações 2.12 e 2.13.

### Predição:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{F}_k \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{B}_k \mathbf{u}_k \quad (2.12)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}_k \mathbf{P}_{k-1|k-1} \mathbf{F}_k^T + \mathbf{Q}_k \quad (2.13)$$

Onde,

- $\hat{\mathbf{x}}_{k|k-1}$  é a predição de estado *a priori*;
- $\mathbf{F}$  é o modelo de transições de estados;
- $\mathbf{B}$  é o modelo das entradas de controle;

- $\mathbf{u}$  é o vetor de entradas;
- $\mathbf{P}_{k|k-1}$  é a predição da covariância a *priori*;
- $\mathbf{P}_{k-1|k-1}$  é a covariância estimada a *posteriori* da atualização anterior;
- $\mathbf{Q}$  é a covariância do ruído do processo.

Na atualização, o dado da observação atual é combinada de forma ponderada com a predição a *priori* para refinar a estimativa do estado atual, chamada de estimativa a *posteriori*. As equações 2.14, 2.15, 2.16, 2.17 e 2.18 são necessárias para etapa de atualização, que representam a atualização do resíduo da medição, resíduo da covariância, ganho de Kalman (que é responsável pela ponderação para atualização entre dado da observação com o dado do modelo), estado a *posteriori* e estimativa da covariância a *posteriori*, respectivamente.

#### Atualização:

$$\tilde{\mathbf{y}}_k = \mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1} \quad (2.14)$$

$$\mathbf{S}_k = \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^\top + \mathbf{R}_k \quad (2.15)$$

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^\top \mathbf{S}_k^{-1} \quad (2.16)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \tilde{\mathbf{y}}_k \quad (2.17)$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} \quad (2.18)$$

Onde,

- $\tilde{\mathbf{y}}$  é o resíduo da medição;
- $\mathbf{z}_k$  é uma medição realizada no tempo  $k$ ;
- $\mathbf{H}$  é o modelo de observação;
- $\mathbf{S}$  é Resíduo da covariância;
- $\mathbf{R}_k$  é a covariância do ruído da observação no tempo  $k$ ;
- $\mathbf{K}$  é o ganho ótimo de Kalman;

- $\hat{\mathbf{x}}_{k|k}$  é o estado atualizado a *posteriori*;
- $\mathbf{P}_{k|k}$  é a covariância estimada a *posteriori*;
- $\mathbf{I}$  é a matriz identidade;

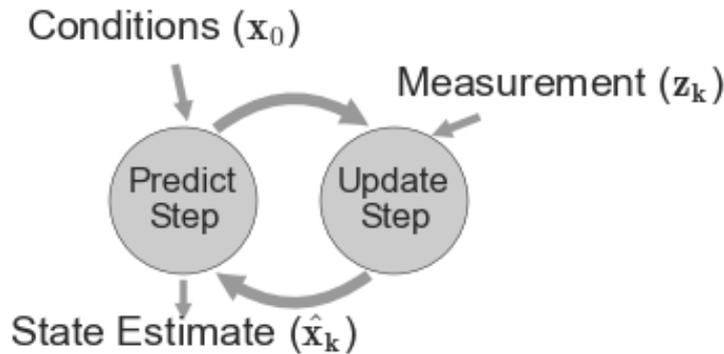


Figura 4 – Diagrama do modelo de estados da aplicação do filtro de Kalman (LABBE, 2014).

Normalmente as fases de predição e atualização se alteram, onde a predição calcula um estado até o instante da observação que é atualizado com a observação, prevendo assim o estado final, com informação do modelo e da observação, a figura 4 apresenta um diagrama dessas transições.

Para representar uma etapa de predição e atualização de forma simplificada, é apresentado a figura 5, onde um estado a *posteriori* do tempo anterior é utilizado para prever o estado a *priori* atual (em vermelho). Em seguida é recebida a medida  $z$  (em azul), que juntamente com a estimativa a *priori* atual, possibilitam calcular a estimativa de posição real, ou seja, a estimativa a *posteriori* de tempo  $t$  atual.

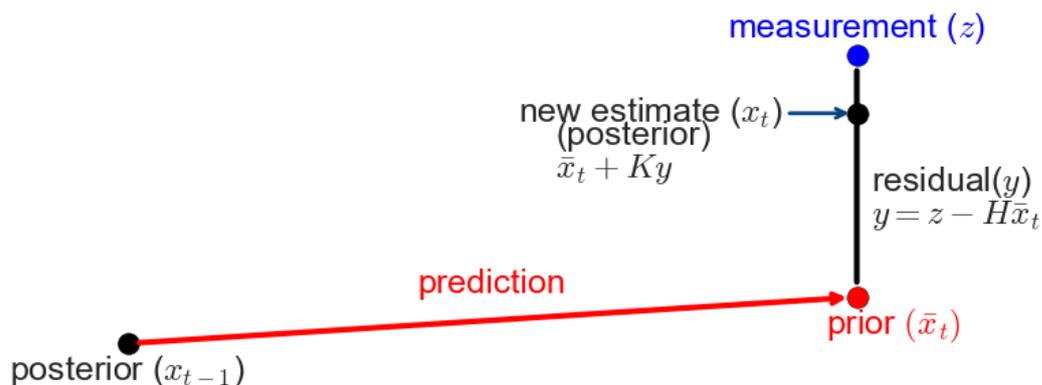


Figura 5 – Exemplo de uma etapa da aplicação do filtro de Kalman (LABBE, 2014).

Apesar de, normalmente, as etapas de atualização e predição se alternarem, não existe a necessidade, ou seja, se alguma observação não estiver disponível, a fase pode ser atualizada apenas com o passo de predição, sendo feita a atualização com base na observação assim que o dado for recebido, dessa maneira o algoritmo consegue superar possíveis falhas de comunicação.

## 2.4 Interactive Multiple Modes

Para trabalhar com a identificação de diferentes modelos de movimentos, podemos projetar um conjunto de filtros de Kalman com essas diferentes suposições de modelos, cada um com as suas características para o movimento que deve representar. Dessa forma, a cada nova entrada, cada filtro teria uma probabilidade de ser o modelo correto para o movimento.

Porém, ao realizar essa sequência de passos, podemos chegar à uma explosão combinatória, ou seja, teremos tantas possibilidades que seria inviável computacionalmente cobrir todas as hipóteses porque, na primeira etapa será gerada  $N$  hipóteses, onde  $N$  é o número de filtros de Kalman ou modelos para o movimento. Na segunda etapa, é gerada outras  $N$  hipóteses que são combinadas com as hipóteses da primeira etapa, gerando  $N^2$  hipóteses (LABBE, 2014). Dessa forma, após um certo número de interações, não é mais possível trabalhar com todas as hipóteses, causando um elevado tempo de processamento, impossibilitando o processamento *online*. A figura 6 apresenta um exemplo desse processo com 3 modelos, onde as escalas não estão sendo aplicadas, sendo essa figura, apenas uma representação para facilitar o entendimento.

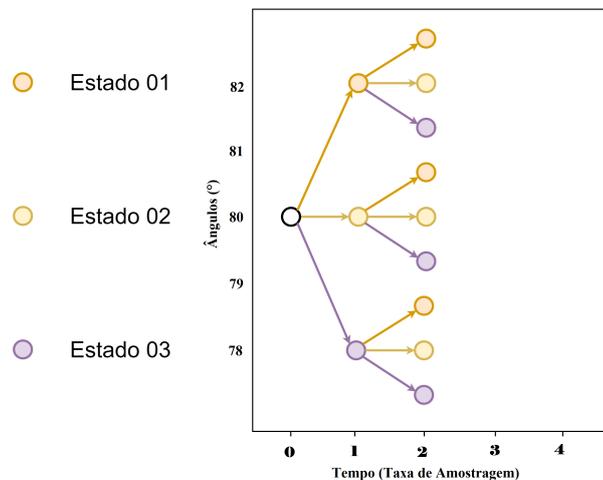


Figura 6 – Exemplo do início do processo que causa a explosão combinatória.

Podemos observar que para cada novo dado recebido são geradas outras 3 hipóteses para cada hipótese anterior, assim, para o primeiro dado temos 3 hipóteses, para o segundo dado teremos 9 hipóteses e assim por diante, aumentando exponencialmente o número de possibilidades.

Para resolver o problema da explosão combinatória de múltiplos modelos, o algoritmo Interacting Multiple Models (IMM) foi desenvolvido por Blom (BLOM, 1984), concluindo que a relação do desempenho com capacidade computacional é muito melhor utilizando o IMM e em (BLOM; BAR-SHALOM, 1988) é mostrado que o IMM tem um bom resultado com uma baixa carga computacional implicando em significativa mudança

no estado da arte da filtragem Bayesiana aproximadas para sistemas com coeficientes Markovianos.

Passando rapidamente e de maneira bem simplificada, um sistema Markoviano é caracterizado por um processo em que se pode realizar previsões de estados futuros com base apenas em informações do estado atual, de maneira que essas previsões são tão boas quanto as previsões realizadas conhecendo o processo completamente (LATOUCHE; RAMASWAMI, 1999).

Voltando à aplicação do algoritmo IMM, a ideia é ter um filtro para cada fase do movimento, ou seja, um filtro para cada comportamento possível do sistema analisado. Dessa forma, para eliminar a necessidade de analisar todas as hipóteses, são feitas ponderações probabilísticas entre os filtros para melhorar a estimativa de cada um, de maneira que o filtro mais perto do estado atual do sistema é um filtro com maior probabilidade de representar a resposta correta e conseqüentemente um filtro mais distante possui uma menor probabilidade de representar o sistema. Essas ponderações são feitas de maneira que o filtro mais provável de representar o estado atual interfere muito nos filtros menos prováveis, assim como os filtros menos prováveis também interferem no filtro mais provável, porém interfere em uma proporção menor (LABBE, 2014).

Para cada filtro, tem-se uma probabilidade do mesmo ser o correto, dessa forma é necessário um vetor que contenham essas probabilidades. Chamaremos de  $\mu$  o vetor de probabilidades dos filtros, onde  $\mu_i$  é a probabilidade do filtro  $i$ . Dessa forma,  $\mu$  é obtido pela probabilidade anterior  $m_i$  de cada estado  $i$  dadas as medidas anteriores  $Z$ . Matematicamente, podemos definir como a equação 2.19.

$$\mu_i = P(m_i|Z) \quad (2.19)$$

Em seguida, é necessário obter as probabilidades das transições de cada modo, dessa forma, podemos modelar as transições de estados como uma cadeia de Markov, onde cada um desses modos (filtros) é um estado de uma cadeia de Markov.

Para representarmos a cadeia de Markov em uma matriz de probabilidades de transições, seguimos a definição de que a probabilidade de se mover de  $i$  para  $j$  em um intervalo de tempo é  $Pr(j|i) = P(i, j)$  e assim a matriz estocástica do sistema pode ser definida da seguinte maneira:

$$\mathbf{P} = \begin{bmatrix} P_{1,1} & P_{1,2} & \dots & P_{1,j} \\ P_{2,1} & P_{2,2} & \dots & P_{2,j} \\ \vdots & \vdots & \ddots & \vdots \\ P_{i,1} & P_{i,2} & \dots & P_{i,j} \end{bmatrix} \quad (2.20)$$

Lembrando que a probabilidade de transição de um estado  $i$  para todos os outros estados deve ser igual a 1, seguindo a equação 2.21.

$$\sum_{j=1}^S P_{i,j} = 1; \quad (2.21)$$

Dessa forma, temos que a probabilidade de mudança de um estado  $i$  para um outro estado  $j$  se dá pela quantidade de transições do estado  $i$  para o estado  $j$  dividido pela quantidade de transições do estado  $i$  para todos os outros estados, incluindo a transição do estado  $i$  para o próprio estado  $i$ . Assim, temos que a matriz de transição de estados pode ser gerada a partir da equação 2.22.

$$M_{i,j} = \frac{\sum_{t=2}^T \mathcal{Y}_{i,j}}{\sum_{t=1}^T \mathcal{E}_i} \quad (2.22)$$

Onde  $\mathcal{Y}_{i,j}$  é a função da quantidade de transições de  $i$  para  $j$  e  $\mathcal{E}_i$  é a quantidade de transições de  $i$ . A figura 7 apresenta um exemplo do modelo da cadeia de Markov para 2 estados.

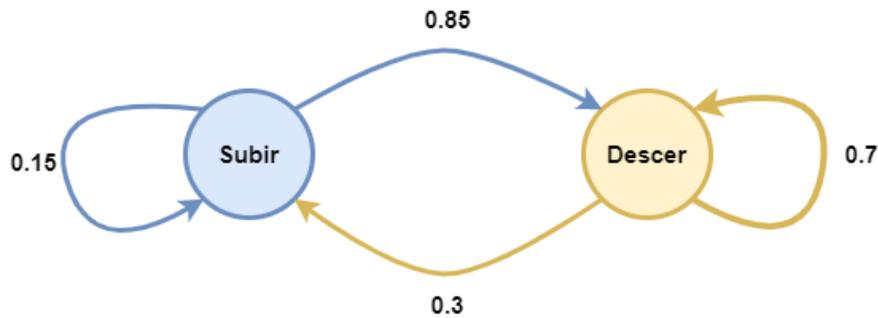


Figura 7 – Exemplo das transições de estados de uma cadeia de Markov.

Chamaremos de  $M$ , a matriz de transição de estados para esse exemplo, de forma que "Subir" é representado pelo índice 1 e "Descer" representado pelo índice 2 de 2.23. A identidade dessa matriz representa a probabilidade de se manter no mesmo estado.

$$M = \begin{bmatrix} 0.15 & 0.85 \\ 0.3 & 0.7 \end{bmatrix} \quad (2.23)$$

De outra forma,  $M[i, j]$  é a probabilidade do modo ser  $j$  dado que o último modo foi  $i$ , para esse exemplo, temos que a probabilidade do próximo estado ser "Descer" dado que o último estado foi "Subir" é de 0.85 ou 85%.

Usando o teorema da probabilidade total, o qual afirma que a probabilidade de vários eventos distintos é dado pela equação 2.24.

$$P(A) = \sum P(A | B) P(B) \quad (2.24)$$

Onde  $P(A | B)$  é a matriz de transição  $M$  e  $P(B)$  é igual a  $\mu$ . Dessa forma, a multiplicação dessas duas matrizes, temos como resultado um somatório, usando como exemplo, matrizes genéricas com apenas 2 estados, temos:

$$\begin{bmatrix} \mu_1 & \mu_2 \end{bmatrix} \begin{bmatrix} m_{11} & m_{12} \\ m_{21} & m_{22} \end{bmatrix} = \begin{bmatrix} \mu_1 m_{11} + \mu_2 m_{21} & \mu_1 m_{12} + \mu_2 m_{22} \end{bmatrix} \quad (2.25)$$

Generalizando, podemos representar esse cálculo pela equação 2.26.

$$\bar{c}_j = \sum_{i=1}^N \mu_i M_{ij} \quad (2.26)$$

Para cada modo (filtro de Kalman), é calculado a probabilidade do modo como: a probabilidade do modo atual baseada nas possíveis transições vezes a probabilidade de estados do filtro de Kalman e por fim as probabilidades são normalizadas para sua soma ser igual a 1.

O filtro de Kalman calcula a probabilidade do estado de acordo com o estado atual do filtro, para isso, utiliza-se a equação 2.27, onde  $S$  é a matriz do resíduo da covariância de cada filtro de Kalman.

$$\mathcal{L} = \frac{1}{\sqrt{2\pi S}} \exp\left[-\frac{1}{2} \mathbf{y}^T \mathbf{S}^{-1} \mathbf{y}\right] \quad (2.27)$$

Utilizando o teorema de Bayes, pode-se calcular as probabilidades dos novos estados. O teorema de Bayes afirma que:

$$\text{probabilidade a } \textit{posteriori} = \frac{\text{probabilidade a } \textit{priori} \cdot \text{probabilidade do filtro de Kalman}}{\text{fator de normalização}}$$

Matematicamente, pode-se reescrever essa equação da seguinte forma:

$$\mu_i = \|\mathcal{L}_i \bar{c}_i\| \quad (2.28)$$

Dessa forma a nova probabilidade de cada modo (filtro) é atualizada a cada interação do filtro de Kalman.

Teoricamente, poderíamos usar as transições de modos para calcular as probabilidades de todas as transições possíveis, porém, computacionalmente isso é inviável, pois a quantidade de possíveis probabilidades de estados aumentam exponencialmente, consumindo rapidamente vários gigas de memória RAM (LABBE, 2014), como exemplificado anteriormente na figura 6.

Por isso utilizamos o algoritmo IMM, o qual resolve esse problema computando uma combinação das probabilidades. Isso é feito utilizando os filtros com maiores probabilidades para ajustar os filtros de menores probabilidades, fazendo uma média ponderada entre todos os filtros, introduzido anteriormente neste capítulo.

Para realizar esses ajustes, temos que os valores de média e covariância de cada filtro de Kalman são atualizados a cada etapa, porém esse cálculo será realizado novamente utilizando, para cada filtro, uma soma ponderada dessas médias e covariâncias de acordo com as probabilidades de misturas, que será chamada de  $\omega$ . Os filtros prováveis serão ligeiramente ajustados pelos filtros improváveis e os filtros improváveis serão fortemente ajustados pelos prováveis. Com isso, temos as seguintes equações de atualização:

$$\mathbf{x}_j^m = \sum_{i=1}^N \omega_{ij} \mathbf{x}_i \quad (2.29)$$

$$\mathbf{P}_j^m = \sum_{i=1}^N \omega_{ij} [(\mathbf{x}^i - \mathbf{x}_i^m)(\mathbf{x}^i - \mathbf{x}_i^m)^\top + \mathbf{P}_i] \quad (2.30)$$

onde  $\mathbf{x}_j^m$  é o estado misto e  $\mathbf{P}_j^m$  é a covariância mista.

Apesar da notação, a ideia é simples, incorporar as estimativas dos filtros prováveis nas estimativas dos filtros improváveis, garantindo que todos tenham uma boa estimativa.

Para calcular as probabilidades de misturas, devemos mais uma vez, recorrer ao teorema de Bayes, onde a probabilidade da mistura é dada pela probabilidade normalizada  $\mu$  e a matriz de probabilidade de transição  $M$ , obtida através da equação 2.31.

$$\omega_{ij} = \|\mu_i \cdot \mathbf{M}_{ij}\| \quad (2.31)$$

Dessa forma, o filtro de Kalman deve realizar a etapa de predição da nova estimativa, utilizando as probabilidades de mistura, dessa forma temos uma atualização para as equações de predição do filtro de Kalman, apresentadas anteriormente em 2.12 e 2.13 e atualizadas para 2.32 e 2.33, respectivamente.

$$\bar{\mathbf{x}}_j = \mathbf{F}_j \mathbf{x}_j^m \quad (2.32)$$

$$\bar{\mathbf{P}}_j = \mathbf{F}_j \mathbf{P}_j^m \mathbf{F}_j^\top + \mathbf{Q}_j \quad (2.33)$$

Agora, para finalizar, precisamos de uma estimativa de qual filtro é o que melhor representa o movimento atual (modo ou estado). Deve-se então, ponderar as estimativas mistas de cada filtro de Kalman, para isso, temos as seguintes equações:

$$\mathbf{x} = \sum_{j=1}^N \mu_j \bar{\mathbf{x}}_j \quad (2.34)$$

$$\mathbf{P} = \sum_{j=1}^N \mu_j [(\bar{\mathbf{x}}_j - \bar{\mathbf{x}})(\bar{\mathbf{x}}_j - \bar{\mathbf{x}})^\top + \bar{\mathbf{P}}_j] \quad (2.35)$$

Observando a equação 2.34, podemos observar que esse cálculo só pode ser realizado se e somente se o estado  $x$ , em cada filtro, for das mesmas dimensões. Esse caso de uso pressupõe que todos os filtros do banco tenham o mesmo projeto dimensional. Além disso, a interpretação de  $x[i]$  deve ser a mesma para todos os filtros.

Atentando-se às dimensões dos filtros, definindo corretamente cada variável e aplicando as equações de predição e atualização, podemos segmentar séries temporais em tempo real. Dessa forma, teoricamente é possível segmentar o movimento de sentar e levantar de forma *online*.

## 3 Metodologia

O objetivo desse capítulo é de descrever, de forma a simplificar a compreensão, todos os passos para o desenvolvimento da análise cinemática do movimento proposto. Serão abordadas a descrição do banco de dados, filtragem, conversão de aceleração para ângulo, aplicação do DTW e filtro de Kalman com cadeia de Markov para a análise de sistemas dinâmicos lineares.

### 3.1 Banco de Dados

Os dados utilizados para realização desse trabalho foram fornecidos pelo banco de dados *MoVi: A Large Multipurpose Motion and Video Dataset* (GHORBANI et al., 2020). Os dados são hospedados em um repositório canadense de acesso público, o *Scholar's Portal Dataverse*. Esse banco de dados está associado ao laboratório *BioMotionLab* que faz parte da York University em Toronto, Canadá. O acesso ao BML-MoVi é limitado e disponível apenas para fins de pesquisa.

Esse banco de dados foi construído com a intenção de fornecer uma grande variedade e quantidade de dados de movimento humano de forma sincronizada. Os dados de IMU fornecidos estão no formato MATLAB e os vídeos das atividades, que foram gravadas a partir de 4 câmeras diferentes, são fornecidos nos formatos .avi e .mp4. Os voluntários foram recrutados na comunidade local em Kingston, foram obtidos os consentimentos por escrito de todos os participantes, além disso, o procedimento experimental foi realizado de acordo com a declaração de Helsinque e foi aprovado pelo comitê de ética da Queen's University, Canadá.

O *BML-MoVi* disponibiliza dados de 90 pessoas, dos quais 60 são mulheres e 30 são homens além da informação de que 5 dessas pessoas são canhotas. Algumas outras informações disponibilizadas estão apresentadas na tabela 1, onde N é o número de voluntários de cada sexo.

Todos os voluntários realizaram 5 séries de 20 movimentos pré definidos mais um

	<b>Mulheres (N = 60)</b>	<b>Homens (N = 30)</b>
Altura ( <i>m</i> )	1.65 (0.08)	1.75 (0.06)
Peso (kg)	60.35 (8.03)	72.3 (10.98)
IMC ( $\text{kg}/\text{m}^2$ )	22.16 (3.02)	23.6 (3.24)
Idade (anos)	20.47 (3.59)	23.6 (3.61)

Tabela 1 – Descrição estatística de altura, de peso, de IMC e de idade dos voluntários do banco de dados (média(desvio padrão)).

movimento de livre escolha, totalizando 21 movimentos, que são executados em ordem aleatória. Os movimentos são: andar, correr, correr sem sair do lugar, galope lateral, rastejar, salto vertical, saltos, chutar, esticar, cruzar os braços, sentar-se numa cadeira, cruzar as coxas sentado, apontar, bater palmas, coçar a cabeça, jogar e agarrar, acenar, fingir tirar uma foto, fingir falar ao telefone, fingir checar o relógio e em cada uma das sequências repetidas os participantes executaram um movimento de sua escolha.

As 5 séries de execuções das sequências de movimentos foram capturadas por sistemas de câmeras e/ou IMUs, com e sem uma pose de descanso (indivíduo parado por alguns segundos entre os movimentos). Os dados de IMU foram adquiridos em 4 séries, com 21 sensores e suas localizações são quadril, coxa direita, coxa esquerda, pé direito, pé esquerdo, Ombro direito, braço direito, braço anterior direito, mão direita, ombro esquerdo, braço esquerdo, braço anterior esquerdo, mão esquerda, cabeça, pescoço, coluna 3, coluna 2, coluna 1 e coluna.

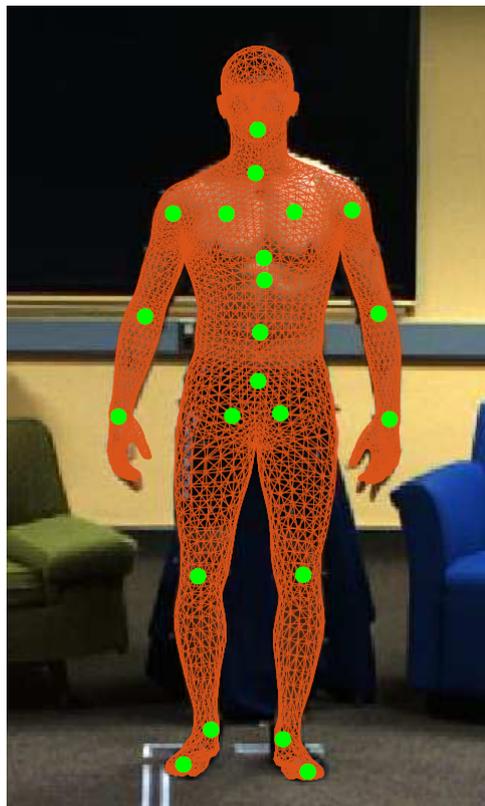


Figura 8 – Posições aproximadas das IMUs para aquisição de dados de movimento dos voluntários.

A figura 8 demonstra as posições aproximadas de cada sensor, onde os círculos são as posições dos sensores que foi disponibilizada pelo banco de dados. Porém, analisando os vídeos é possível observar que as posições dos sensores não são exatamente as indicadas, dessa forma, para ajudar na identificação, a figura 9 demonstra as posições aproximadas em que os sensores são efetivamente utilizados nos voluntários, podendo haver pequenas diferenças na sua localização entre os voluntários.



(a) Imagem para representar as posições aproximadas dos sensores da coxa.



(b) Imagem para representar a posição aproximada do sensor do tronco.

Figura 9 – Posições aproximadas dos sensores utilizados para o estudo, representados pelo retângulo branco.

Podemos assim, observar o posicionamento aproximado dos sensores, de forma que na figura 9b está representada a posição aproximada do sensor do tronco e na figura 9a estão representadas as posições aproximadas dos sensores das coxas. Os dados das coxas direita e esquerda são utilizados apenas para comparar os resultados, sendo que a ideia é aplicar os algoritmos apenas para 2 sensores, um do tronco e um da coxa.

Para cada uma das 4 séries, os dados de IMUs são codificados em S1, S2, I1 e I2 e para cada um dos sensores são gerados 16 diferentes dados de informação, de forma que:

- X = Deslocamento [ $m$ ] para os eixos  $x$ ,  $y$  e  $z$ ;
- V = Velocidade [ $m/s$ ] para os eixos  $x$ ,  $y$  e  $z$ ;
- Q = Postura em Quatérnions para os eixos  $x$ ,  $y$  e  $z$ ;
- A = Aceleração da Gravidade [ $g = 9,8m/s^2$ ] para os eixos  $x$ ,  $y$  e  $z$ ;
- W = Velocidade Angular [ $rad/m$ ] para os eixos  $x$ ,  $y$  e  $z$ ;

Os dados de IMU da série S1 foram obtidos com os voluntários realizando uma pose "A", pose de descanso, que separa cada um dos movimentos e os dados da série S2 foram

obtidos com os voluntários realizando a transição entre os movimentos de forma contínua. Para essas mesmas sequências de movimentos é apresentado os dados S1\_Synched e S2\_Synched, que são as informações extraídas por IMU e vídeo, sincronizadas.

Também são fornecidos os dados dos movimentos I1 e I2, que referentes a outras repetições dos mesmos voluntários, porém utilizando um roupa mais apropriada para exercício, facilitando a colocação dos sensores, os vídeos para esses movimentos não foram disponibilizados.



Figura 10 – Diferenças de assentos para o movimento de sentar e levantar fornecidos por (GHORBANI et al., 2020).

Durante a realização da separação das informações apenas para o movimento de sentar e levantar, utilizando os dados de vídeo como referência temporal, foi possível observar que para alguns grupos de voluntários o movimento de sentar e levantar foi realizado em cadeiras, poltronas ou bancos de diferentes alturas, que são apresentados na figura 10. Essa variação de assentos para a realização do movimento torna a análise mais complexa e ao mesmo tempo mais genérica, aumentando a flexibilidade da aplicação.

## 3.2 Fases do Movimento de Sentar e Levantar

Para definir as fase do movimento de levantar, utilizou-se a definição das fases dada por Schenkman (SCHENKMAN et al., 1990), onde são estabelecidas 4 transições de

fases para o movimento, apresentados na figura 11.

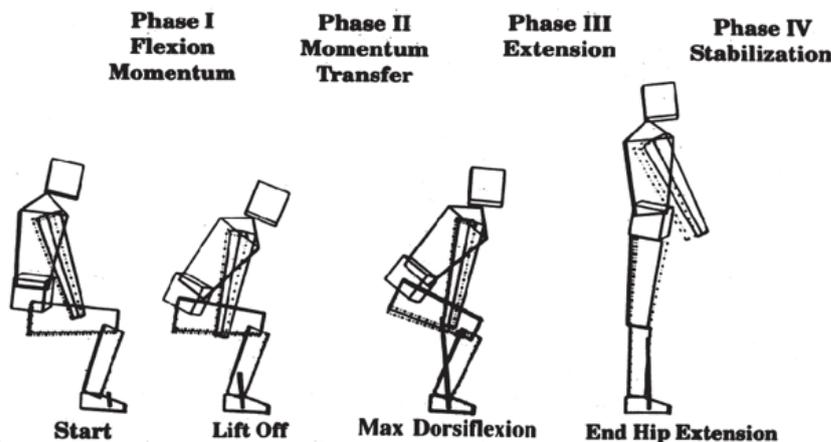


Figura 11 – Fases do movimento do sit-to-stand (SCHENKMAN et al., 1990).

Para as definições das fases, temos que a Fase I, chamada de Momento de Flexão, é identificada no momento em que acontece o início da inclinação do tronco e antes do instante em que as nádegas saem da cadeira, a Fase II, chamada de Transferência de Momento é encontrada desde o momento da retirada do assento até a dorsiflexão máxima do tornozelo (durante essa fase, o impulso da parte superior do corpo contribui para o movimento para frente e para cima do corpo). A Fase III, chamada de Extensão, acontece da fase anterior até o momento em que os quadris estão retos. A Fase IV, chamada de Estabilização, é definida como o fim da transferência do movimento. (FRYKBERG; HAGER, 2015).

A partir das definições de fases do movimento de levantar descritas, é possível observar que a os sensores da coxa e do tronco são insuficientes para classificar o movimento exatamente como definido anteriormente, já que, por exemplo, é necessário saber a dorsiflexão máxima do tornozelo. No banco de dados, é possível fazer a obtenção dessas informações, porém é necessário o acréscimo de um sensor extra, entrando em conflito com o objetivo do trabalho que é utilizar apenas 2 sensores, dessa forma será utilizado apenas os dados da coxa e do tronco. Então, para isso serão necessárias adaptações dessas definições para a aplicação neste estudo.

Sabendo disso, juntamente com a identificação das diferentes alturas dos assentos utilizados, para obter um algoritmo mais robusto foi necessário realizar uma junção da Fase I com a Fase II, onde o momento de flexão e o momento de transferência são analisados como apenas uma etapa com seu início a partir do movimento do tronco e finalizando no momento de máxima dorsiflexão, como apresentado na figura 12. Para tal, o momento de máxima dorsiflexão foi substituído pelo momento de máxima inclinação do tronco.

Dessa forma, neste trabalho, as classificações de fases que serão apresentadas para o movimento de levantar seguirá as definições de fases apresentadas na figura 12, onde a

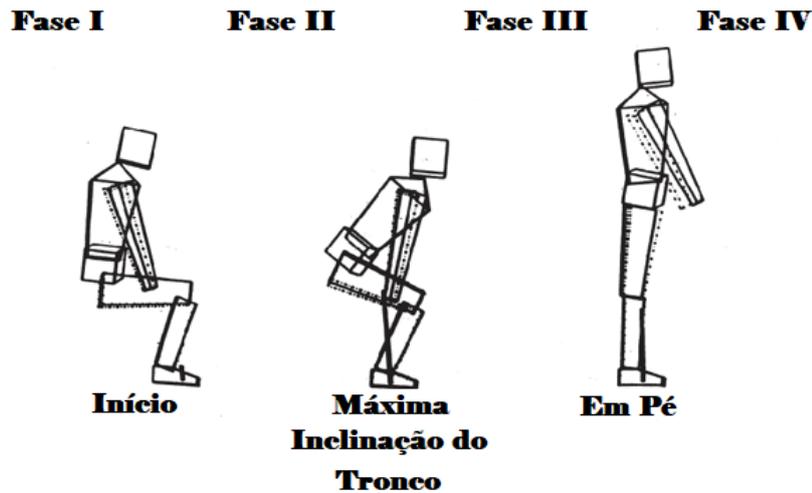


Figura 12 – Fases do movimento levantar definido para o desenvolvimento desse projeto. Adaptado de (SCHENKMAN et al., 1990).

Fase I representa o estado sentado, a Fase II se inicia com o movimento do tronco e da coxa e vai até a inclinação máxima do tronco, a Fase III se inicia a partir do momento de inclinação máxima do tronco até o momento em que a pessoa está em pé, onde é finalizado o movimento do tronco e da coxa. A Fase IV representa o momento em que a pessoa está em pé, para o movimento de levantar.

Essa classificação é válida para o movimento de levantar, porém essa análise também é feita para o movimento de sentar e, como os dois movimentos são realizados de forma semelhante, pode-se considerar apenas a alteração da ordem sequencial das fases do movimento, porque são movimentos aproximadamente espelhados no tempo, representado na figura 13.

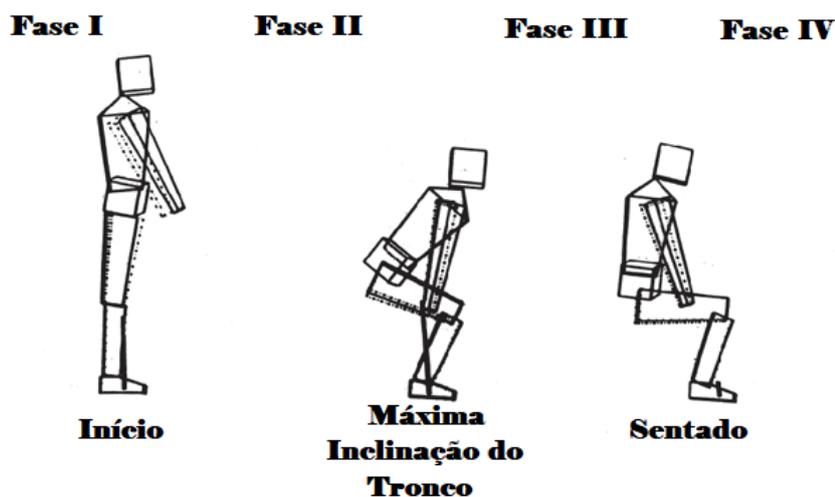


Figura 13 – Fases do movimento sentar definido para o desenvolvimento desse projeto. Adaptado de (SCHENKMAN et al., 1990).

Seguindo essa definição, temos que a Fase I representa a pessoa em pé, a Fase II se inicia com o movimento da coxa e do tronco e vai até o momento de máxima inclinação

do tronco, a Fase III começa a partir do momento de máxima inclinação do tronco e vai até o momento em que o tronco se estabiliza, onde a pessoa está sentada. A Fase IV é o momento a partir do qual a pessoa está sentada.

Esse trabalho seguirá as definições de fases do movimento de sentar e levantar simplificadas que estão apresentadas nesta seção, seguindo o apresentado nas figuras 12 e 13.

### 3.3 Tratamento dos Dados

Para acessar os dados do *MoVi Dataset*, foi utilizado um *script* cedido por (GHORBANI et al., 2020) para a leitura dos arquivos *.mat* em *python*, pois está foi a linguagem de programação escolhida como ferramenta para o desenvolvimento desse projeto. A partir da abertura dos dados e entendimento da organização dos mesmos, passou-se a trabalhar na seleção das informações de interesse.

Como a intenção desse trabalho é analisar apenas o movimento de sentar e levantar, foi necessário separar os dados desse movimento para realizar a análise. Para tanto, utilizou-se os dados dos vídeos como forma de realizar a segmentação dos dados de IMU, que também é disponibilizado de forma sincronizada com os vídeos, dessa forma, utilizando a taxa de amostragem dos vídeos que é de 30 Hz e a taxa de amostragem da IMU que é de 120 Hz, foi possível converter o tempo do vídeo no tempo dos dados de IMU e separar os dados de IMU com informações somente do movimento de sentar e levantar.

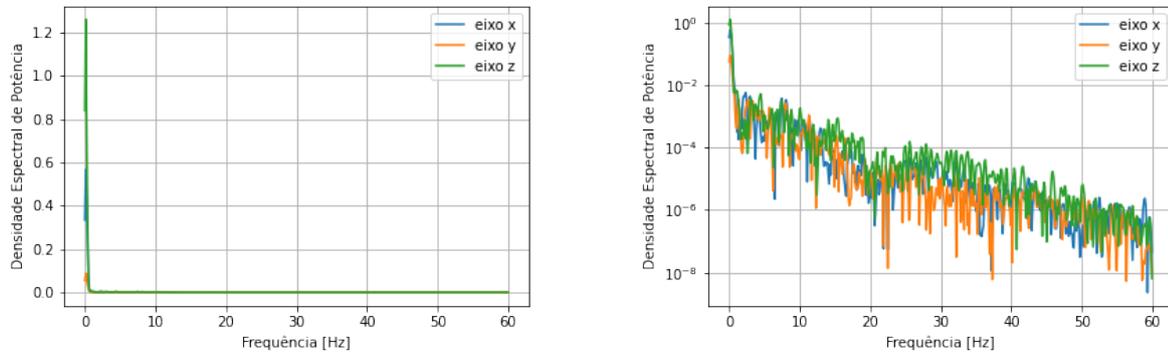
Apesar dessa diferença na taxa de amostragem poder representar resquícios de um movimento anterior ou posterior ao movimento de sentar e levantar, como esses dados foram obtidos através das repetições em que existe uma pose de separação entre os movimentos, esse possível problema não foi efetivo, ou seja, essa diferença na taxa de amostragem não teve interferência nos dados do início e final do movimento de estudo.

#### 3.3.1 Filtragem

Para realizar a etapa de filtragem do sinal, foi feita a análise do espectro de frequência dos sinais de aceleração das IMUs de vários voluntários para o movimento de sentar e levantar. Em seguida, observando esses dados, foi definida uma frequência de corte com o objetivo de manter apenas as partes que realmente representam o sinal do movimento objeto de estudo. A intenção é de atenuar as partes que representam o ruído do sensor, de maneira a obter apenas os dados de movimento e a partir dessa análise é possível definir a forma de filtragem desse sinal ruidoso.

A partir dessa estratégia, foi realizado o cálculo para encontrar a densidade espectral de potência do sinal, de forma a identificar as frequências com maior amplitude

e definir a frequência de corte. Foram obtidos gráficos com escala logarítmica e escalar decimal e um exemplo desses resultados é apresentado na figura 14.



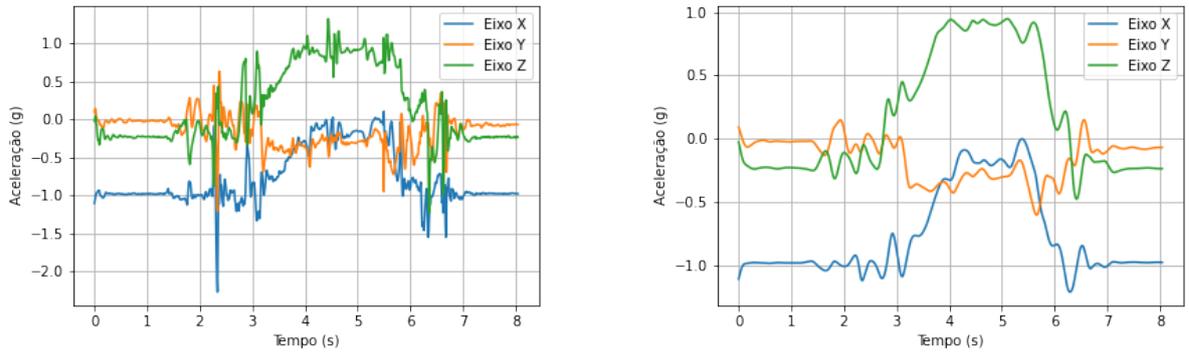
(a) Densidade espectral de potência do sinal apresentado pelo voluntário 6 em escalar decimal.

(b) Densidade espectral de potência do sinal apresentado pelo voluntário 6 em escalar logarítmica.

Figura 14 – Resultado do cálculo da densidade espectral de potência do movimento de sentar e levantar da coxa direita para um voluntário escolhido aleatoriamente (voluntário 6).

É possível observar que a maior frequência que pode ser representada é de 60 Hz, isso acontece de forma a respeitar o teorema de Nyquist, onde a frequência de amostragem deve ser pelo menos 2 vezes a frequência máxima do sinal, então, como a frequência de amostragem dos dados de IMUs são de 120 Hz, a maior frequência do sinal representado é de 60 Hz. Apesar disso, ao dar um zoom nas menores frequências, é possível observar que as frequências que possuem componentes que efetivamente representam o sinal, são as frequências mais baixas, menores que 2 Hz e, com base nessa análise, para a filtragem dos dados é utilizado um filtro *butterworth* passa-baixas de segunda ordem, pois é um filtro que possui uma resposta suficientemente rápida além de não ser muito complexo, reduzindo o custo da aplicação.

Para a definição da frequência de corte utilizada, observou-se alguns exemplos teóricos onde foram feitas as análises do movimento de sentar e levantar com dados de ângulos do tronco e da coxa, como em (BAPTISTA; Bó; HAYASHIBE, 2017) e (SCHENKMAN et al., 1990) e então, utilizou-se os resultados analisados como referência visual do gráfico do sinal filtrado que efetivamente representa o sinal do movimento estudado, ou seja, os gráficos apresentados nesses artigos são utilizados como referência visual para, juntamente com a análise da densidade espectral de potência, definir o sucesso da filtragem dos dados de aceleração e convertidos em ângulos que foram fornecidos por (GHORBANI et al., 2020). A figura 15 é um exemplo dos dados de aceleração do voluntário 6 não filtrado e filtrado em 3 Hz.



(a) Dados de aceleração sem filtragem.

(b) Dados de aceleração filtrados em 3 Hz.

Figura 15 – Dados de aceleração da coxa direita para o voluntário 6.

### 3.3.2 Conversão de Aceleração Para Ângulo

Como dito anteriormente, os dados filtrados são dados de aceleração e, para realizar a comparação com os exemplos teóricos é necessária a conversão para ângulo, já que os gráficos contidos em (BAPTISTA; Bó; HAYASHIBE, 2017) e (SCHENKMAN et al., 1990) são relacionados aos ângulos de inclinação do movimento. Para essa realização, utilizou-se da aceleração da gravidade para definir o ângulo do sensor com o centro da Terra, dessa forma, durante o desenvolvimento da escrita, ao descrever o movimento de ângulo da coxa e ângulo do tronco, faz-se referência ao movimento de inclinação do ângulo da coxa e o movimento de inclinação do ângulo do tronco, ambos em relação ao centro da Terra.

Com base em (MARDIA; JUPP, 2009), utilizando as relações de Euler, podemos aplicar as equações 3.1 e 3.2 para fazer essa conversão.

$$r = \sqrt{A_x^2, A_y^2, A_z^2} = |A| \quad (3.1)$$

Onde  $A_x$ ,  $A_y$  e  $A_z$  são as componentes de aceleração ( $A$ ) nos eixos  $x$ ,  $y$  e  $z$ , respectivamente e  $r$  é o módulo da aceleração ( $|A|$ ). Já a orientação  $\theta$  é obtida a partir da seguinte equação:

$$\theta = \arccos \frac{A_z}{r} = \arccos \frac{A_z}{|A|} \quad (3.2)$$

dessa forma, temos que  $\theta$  é o ângulo do sensor em relação ao centro da Terra obtido com base na aceleração dos 3 eixos.

A partir da aplicação da filtragem e das equações de conversão de aceleração para ângulos, os resultados da filtragem são obtidos, de forma que seja possível realizar a validação desejada. A figura 16 apresenta um exemplo de gráfico filtrado em 3 Hz, para exemplificar essa aplicação.

Aplicando essa sequência de passos para diferentes frequências de corte e comparando com os dados de exemplos teóricos, é possível chegar na melhor frequência de

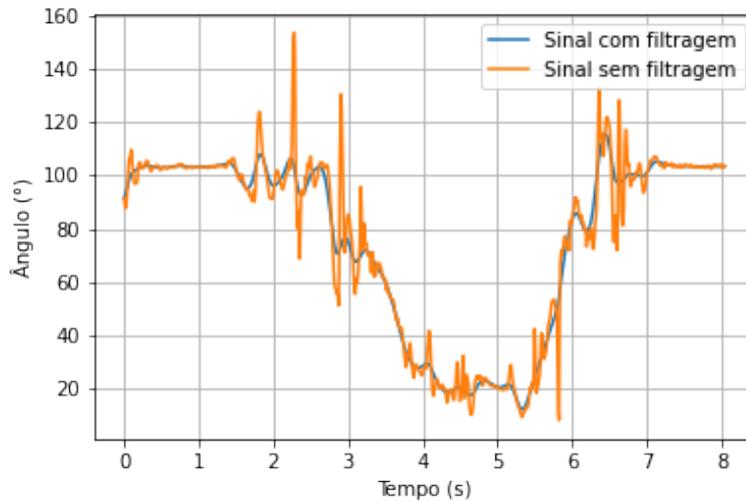


Figura 16 – Comparação dos dados da coxa direita do voluntário 6 filtrados em 3Hz e sem filtragem que foram convertidos de aceleração em ângulos.

corde para cada movimento. É importante observar que devem ser utilizadas filtrações diferentes para cada parte do movimento, nesse caso, uma filtração para o movimento das coxas e outra filtração para o movimento do tronco.

Como apresentado anteriormente, em 3.2, podemos separar o movimento de sentar e levantar em algumas fases, dessa forma, os sinais filtrados devem representar corretamente as etapas do movimento. Cada IMU entrega os dados do seu respectivo movimento, com a junção dessas informações é possível identificar e segmentar o movimento estudado, relacionando o movimento com os dados dos sensores, como apresentado na figura 17, que foi segmentada manualmente. O objetivo é gerar as marcações nos dados relacionados a cada parte do movimento de forma automática, o que será descrito nas próximas seções.

### 3.4 Segmentação *Offline* das Fases.

Para realizar a segmentação de fases do movimento de sentar e levantar, de forma automática, utilizou-se o algoritmo DWT já que o mesmo é capaz de identificar similaridades entre sinais de uma referência com um alvo, mesmo com variações de velocidade de execução e de tempo (KEOGH; PAZZANI, 2001).

Primeiramente é necessário definir um voluntário para utilizá-lo como referência de movimento, então foram utilizadas as informações de movimento do (BAPTISTA; Bó; HAYASHIBE, 2017) como referência e analisou-se, dentro do banco de dados, o voluntário cujos gráficos apresentou, visualmente, um movimento mais similar aos desejados.

O movimento alvo é o movimento de sentar e levantar do voluntário no qual se deseja realizar a classificação automática do movimento. Dessa forma, o sistema deve ter

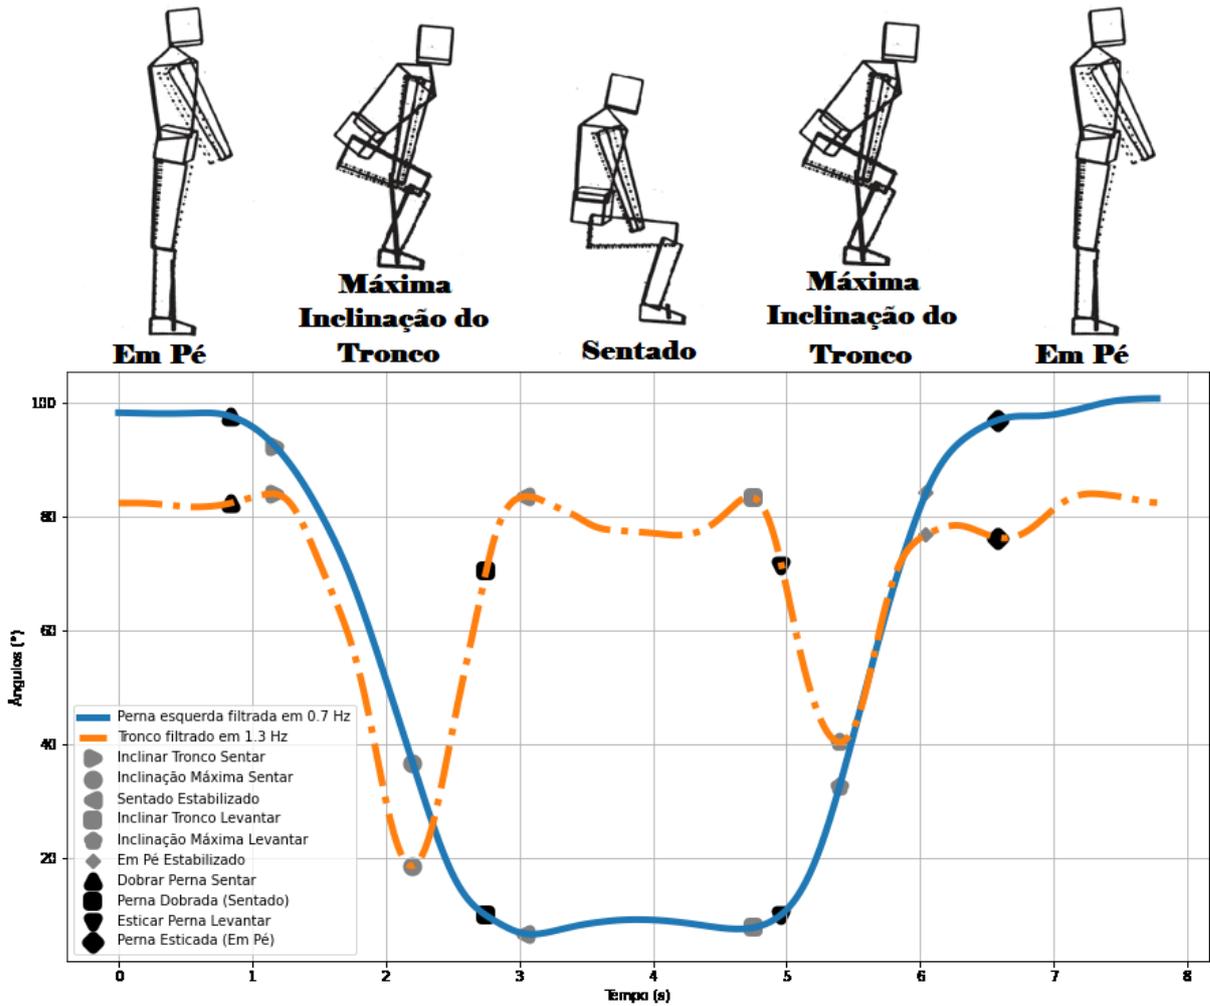


Figura 17 – Imagem ilustrativa para relacionar as fases do movimento de sentar e levantar com o gráfico obtido após a filtragem e conversão para ângulos dos dados das IMUs do tronco e da coxa.

entradas de ângulos de inclinação do tronco e da coxa, conforme indicado na seção 3.3, para cada um dos movimentos referência e alvo. A figura 18 apresenta o diagrama de blocos do sistema para segmentação automática e extração de métricas do movimento.

A partir dos dados de entrada é aplicado o algoritmo DTW, entregando a correlação entre os pontos do movimento alvo com o movimento de referência. Essa correlação entre os movimentos é utilizada para encontrar os pontos que representam as transições de fases, encontradas na segmentação manual do movimento referência, que são referentes aos pontos de transições de fases do alvo. Essa etapa é descrita com mais detalhes em 3.4.1.

Para a segmentação manual do movimento de referência, é necessário definir manualmente os pontos de separação entre as fases de interesse. Esses pontos foram obtidos identificando as transições de cada movimento, ou seja, um vetor com a sequência dos pontos que representam as transições das fases do tronco e um outro vetor com a sequên-

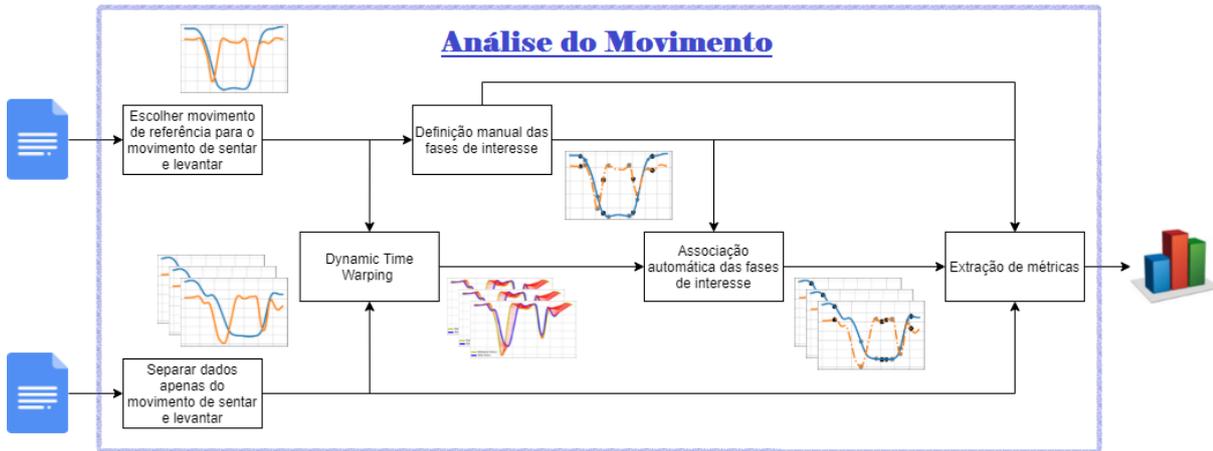


Figura 18 – Diagrama de blocos para aplicação da segmentação *offline* do movimento.

cia para as transições das fases da coxa. Esses pontos foram escolhidos de forma visual a partir dos dados dos gráficos de cada sensor, coxa e tronco.

Com essas informações é realizada, automaticamente, a segmentação em fases dos dados do voluntário alvo, faltando apenas a etapa de extração das métricas da qualidade da segmentação feita pelo DTW. As métricas de interesse são obtidas realizando a segmentação manual em fases de vários voluntários alvos, semelhante ao que foi feito para o voluntário de referência, dessa forma, temos dados segmentados em fases que foram classificados manualmente para ser comparada com os dados segmentados em fases que foram classificados pelo algoritmo.

A princípio, essas são as etapas necessárias para a realização da segmentação do movimento, porém, o algoritmo DTW possui algumas limitações em relação quanto a detecção de vales ou picos maiores ou menores do que a referência, isso ocasiona alguns problemas que serão tratados na seção 3.4.2.

### 3.4.1 Aplicação do Dynamic Time Warping

A comparação de sequências são feitas pelo algoritmo DTW, que identifica as similaridades entre os sinais de referência e alvo, onde variações de tempo e de velocidade não causam interferência nas detecções (KEOGH; PAZZANI, 2001), ou seja, as relações entre os movimentos podem ser identificadas mesmo que o tempo de execução sejam diferentes entre si.

Esse bloco tem como entrada os dados do ângulos do movimento de um voluntário de referência e de um voluntário alvo. Os dados de tronco são relacionados entre si, assim como os dados da coxa, ou seja, a aplicação do DTW é feita relacionando os dados de ângulos, em graus, de cada sensor, que estão localizados no tronco e na coxa.

O processo do algoritmo se inicia calculando as distâncias euclidianas encontradas

entre os dados de referência e alvo para os dados selecionados, os cálculos são feitos utilizando a equação 2.9. As distâncias encontradas para os troncos e as coxas são armazenadas em uma matriz, encontrando o *Warping Path*.

A partir do *Warping Path*, que é a matriz de distâncias euclidianas, se inicia o processo de custo cumulativo, partindo do primeiro elemento do canto inferior esquerdo da matriz, aplicando-se a equação 2.10, onde é comparado os valores dos elementos adjacentes com o elemento atual, de forma a encontrar o menor custo, ou o menor valor entre eles.

Dessa forma, a matriz pode ser percorrida horizontalmente, verticalmente ou pela diagonal, de acordo com o resultado da comparação dos elementos adjacentes com o elemento atual. Com isso, a matriz é percorrida em direção ao último elemento, localizado no canto superior direito da matriz. O caminho percorrido até esse momento é armazenado como o *path* que caracteriza as correspondências entre os índices de cada uma das séries de dados, referência no eixo  $x$  e alvo no eixo  $y$ .

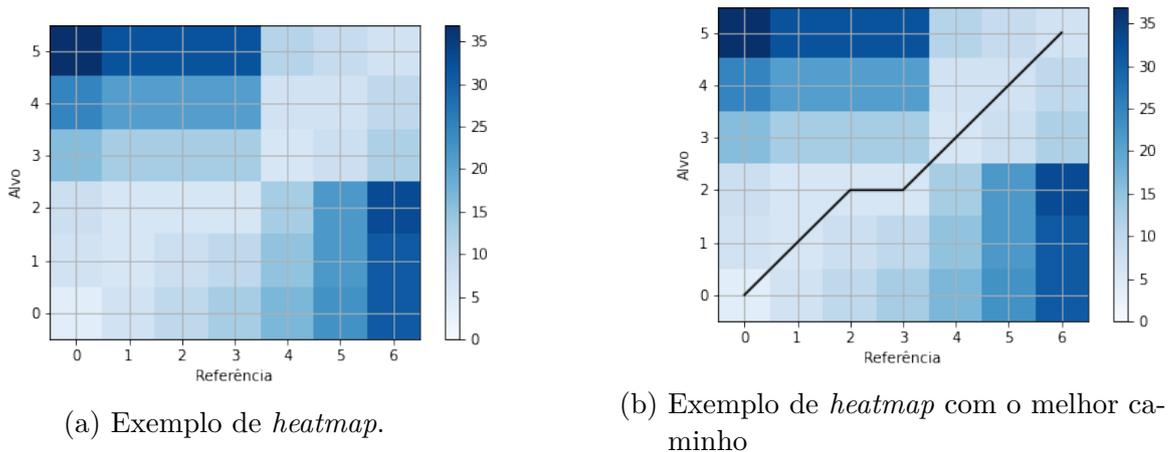


Figura 19 – Exemplo aleatório para ilustrar a obtenção do melhor caminho pelo DTW.

Para ilustração, a figura 19a apresenta o custo acumulado, em um *heatmap*, de um par de vetores aleatórios onde as maiores distâncias possuem as cores mais escuras. Ao lado, na figura 19b é apresentado o *heatmap* com o caminho do menor custo, ou seja, as correspondências entre os dois vetores de dados. A representação utilizando o DTW pode fornecer à um único ponto, vários pontos correspondentes de uma outra série (KEOGH; PAZZANI, 2001), onde essas associações são pares de índices  $(i, j)$ , que são os *path* comentado anteriormente, que carregam as menores distâncias entre as sequências de referência e alvo.

O resultado é uma linha "entortada" que é formada a partir das correspondências baseadas nas menores distâncias entre os dois movimentos, referência e alvo.

### 3.4.2 Sensibilidade do Dynamic Time Warping

A aplicação do DTW pode não encontrar a correspondência correta em alguns casos, isso pode ocorrer devido à algum pico ou vale que é mais alto ou mais baixo do que a referência (KEOGH; PAZZANI, 2001).

Como comentado em 3.1, o banco de dados possui dados de vários voluntários, onde grupos desses voluntários realizam o movimento de sentar e levantar em assentos de diferentes alturas, dessa forma, esses movimentos passam a ter diferentes inclinações entre os grupos de voluntários. Essas diferentes inclinações dificultam a aplicação correta do algoritmo, já que essas inclinações variadas geram angulações diferentes representam justamente esses picos e vales de diferentes alturas que podem causar erros na detecção. Um exemplo desse problema é apresentado na figura 20.

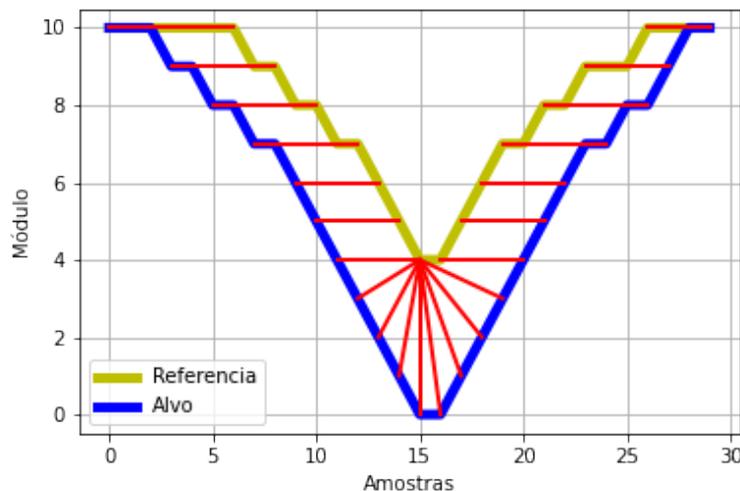


Figura 20 – Exemplo de aplicação em um vale com valores de alvo menor que os da referência.

É possível observar que os dados de referência e alvo são bem parecidos, porém os dados de alvo possui valores mínimos menores que os dados de referência, além disso, é possível observar que os dados possuem quase que um espelhamento entre as amostras 15 e 16.

Ao aplicar o DTW e verificar as conexões entre referência e alvo, é possível observar a dificuldade do algoritmo ao gerar as correspondências corretas entre os sinais. Observando a amostra 15 do dado de referência, é possível observar que ela foi considerada como correspondência de 9 pontos dos dados de alvo, enquanto que a amostra 16 é considerada como correspondência apenas de um valor do alvo, porém, ainda analisando os dados da amostra 15 e 16, é possível observar que elas correspondem aos pontos mínimos das amostras de alvo e referência, de forma que a amostra 15 da referência deveria ser relacionada a amostra 15 do alvo e a amostra 16 da referência deveria ser relacionada

com a amostra 16 do alvo, algo que não foi identificado pelo algoritmo.

Para avaliar um outro problema, vamos supor que a amostra 15 foi classificada como um ponto de transição de fases, para esse exemplo, a relação entre referência e alvo corresponde a 9 possíveis posições para o alvo. Porém esse problema foi solucionado de forma relativamente simples, onde a amostra escolhida como a correspondência correta do alvo é calculada como a média dos índices de todas as correspondências. Nesse caso, a média seria o somatório de todos os índices das amostras dividido pelo número de amostras.

Agora, para avaliar um outro problema, vamos supor que a amostra 16 foi classificada como ponto de transição de fases, para esse exemplo, a relação entre referência e alvo apresenta apenas 1 valor, de forma que a amostra 16 da referência está relacionada com a amostra 20 do alvo, um valor bem distante do ponto mais baixo do vale, ou seja, observa-se uma correspondência falha, já que a amostra 16 de referência deveria ser correspondente à amostra 16 do alvo..

Esse problema acarretou na necessidade de alteração das fases analisadas nesse trabalho, como explicado em 3.2. Como as duas primeiras fases, descritas por (FRYKBERG; HAGER, 2015) analisando as fases de (SCHENKMAN et al., 1990), são fases muito próximas uma da outra e ainda existe a diferença entre as alturas de assentos, então, afim de deixar o algoritmo mais robusto, foi necessário realizar a alteração de fases descritas.

### 3.5 Segmentação *Online* das Fases.

Para realizar a segmentação de fases do movimento de sentar e levantar em tempo real e de forma automática, utilizou-se o algoritmo IMM, pois o mesmo é capaz de identificar transições de estados de um sistema representado por um modelo Markoviano, além de necessitar de pouco poder computacional, tornando-se um método excelente para a análise de sistemas dinâmicos de modelos múltiplos (BLOM; BAR-SHALOM, 1988).

Para aplicar o algoritmo IMM, primeiro é necessário conhecer muito bem a dinâmica do sistema objeto de estudo, de forma a colher alguns parâmetros para gerar um modelo para cada fase do movimento. Porém, o movimento é composto por dois dados, dessa forma é possível aplicar o algoritmo de duas formas, uma utilizando um algoritmo para cada sensor ou aplicando o algoritmo para os dados dos dois sensores, sendo essa segunda opção ainda mais complexa. Além disso, é necessário observar necessidade que os modelos de cada sensor possuam as mesmas dimensões.

Dessa forma, para garantir os modelos corretos, sem haver a necessidade de fazer alterações por dificuldades quanto as dimensões, optou-se por gerar modelos de filtro exclusivos para cada sensor e aplica-los de forma individual ao IMM, ou seja, uma aplicação

IMM para os dados de tronco e outro para os dados da coxa. A figura 21 apresenta o diagrama de blocos com a sequência de passos para a aplicação da segmentação *online* e automática do movimento de sentar e levantar.

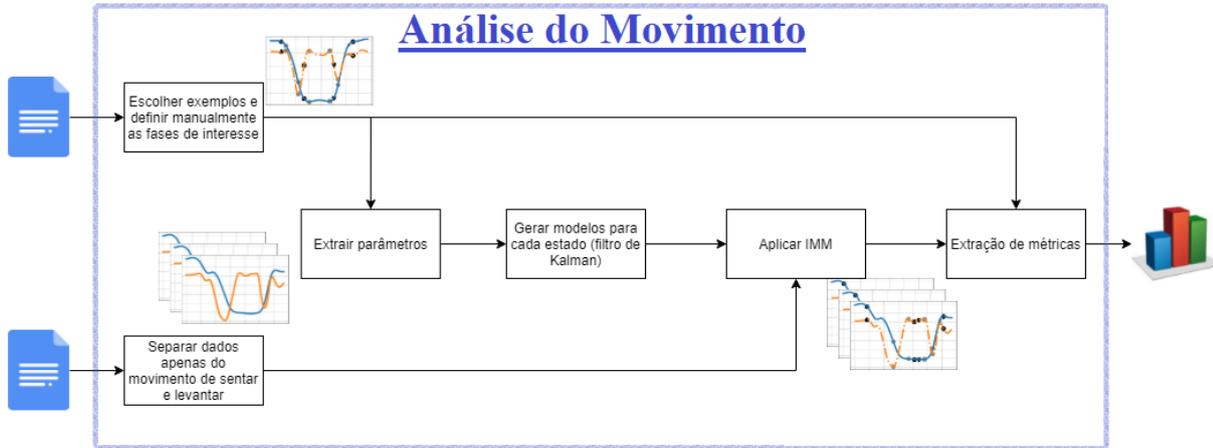


Figura 21 – Diagrama de blocos para a aplicação de segmentação *online* do movimento.

A partir dos dados do movimento estudado é necessário extrair parâmetros para modelar cada fase do movimento. Dessa forma, utilizou-se alguns voluntários para extrair esses parâmetros e, a partir dos pontos de separação de fase realizados manualmente, foi feita uma análise de velocidade média, variância da velocidade média e posição do início de cada fase do movimento, essas etapas serão descritas com mais detalhes em 3.5.1.

A segmentação manual do movimento de referência foi explicado em 3.4 e nessa etapa realizou-se os mesmos passos.

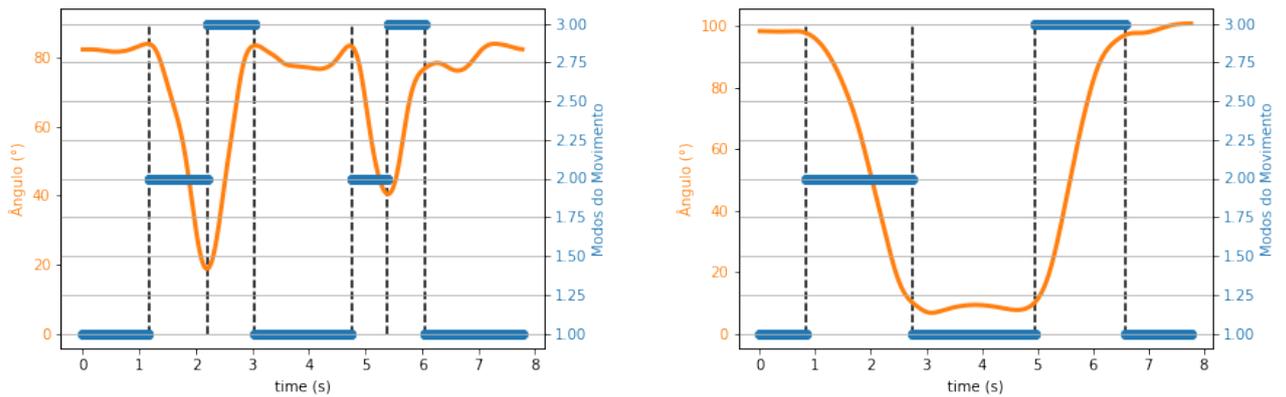
Com esses parâmetros é possível gerar um modelo para o filtro de Kalman, podemos gerar um modelo genérico para todo o movimento, porém, para realizar a segmentação com o algoritmo IMM é necessário uma aplicação menos genérica, ou seja, é necessário gerar diferentes modelos para cada parte do movimento.

Por fim, é feita a aplicação do algoritmo IMM, utilizando-se dos modelos de filtros de Kalman criados para cada parte do movimento e recebendo como entrada os dados do movimento de sentar e levantar dos voluntários. Os resultados do algoritmo são a posição estimada e as probabilidades de cada filtro ser o filtro que representa aquela fase do movimento, dessa forma, é necessário gerar uma lista para cada instante de tempo que informa qual o filtro que tem a maior probabilidade naquele instante de tempo.

Com essas informações, é realizada de forma automática e *online* a segmentação de fases do movimento de sentar e levantar, faltando apenas extrair as métricas da qualidade da segmentação realizada pelo IMM. Para isso, utilizou-se dos mesmo exemplos segmentados manualmente que foram utilizados para a extração da qualidade da segmentação do DTW.

### 3.5.1 Aplicação do Filtro de Kalman

Antes de efetivamente aplicar o filtro de Kalman, é necessário gerar os modelos para cada modo do movimento. Esse modelo será gerado de forma individual para cada sensor, ou seja, serão gerados modelos para os dados do tronco e outros modelos para os dados da coxa, até mesmo porque são movimentos diferentes. Utilizando a classificação manual de um voluntário, foi realizada a separação das fases para cada mostra. A figura 22 apresenta os estados de cada parte do movimento.



(a) Exemplo de separação dos estados para os dados do tronco.

(b) Exemplo de separação dos estados para os dados da coxa esquerda.

Figura 22 – Exemplo aleatório para ilustrar a obtenção do melhor caminho pelo DTW.

Como apresentado na figura 22, podemos observar que temos 3 modos diferentes (em azul), um com velocidade constante que é representado pelo modo 1, outro com velocidade negativa que é representado pelo modo 2 e um com velocidade positiva que é representado pelo modo 3. Para cada um desses modos, foram retiradas métricas de velocidade média, de forma que a velocidade é a diferença entre  $x_t$  e  $x_{t-1}$ .

Agora, com essas informações, além das informações das posições do início de cada modo, podemos criar um modelo de filtro de Kalman para cada modo. Para isso, vamos seguir uma sequência onde vamos gerar as variáveis de estados, a função de transição de estados e a função de medição ou modelo de observação. As definições dessas matrizes tem como base o artigo (BAPTISTA; Bó; HAYASHIBE, 2017).

A escolha das variáveis de estados é decisiva para o sucesso do IMM, já que ao utilizarmos um modelo de velocidade constante que considera a velocidade como uma entrada do sistema, o filtro se torna genérico o suficiente para em apenas um filtro ser possível ter excelentes estimativas de posição, dificultando o chaveamento de estados pretendido ao utilizar o IMM.

Dessa forma, para obter um modelo mais restrito, a variável de estado é definida como:

$$\mathbf{x} = \begin{bmatrix} x & 1 \end{bmatrix}^T$$

onde  $x$  é a posição, onde essa é a única variável de estado para o nosso modelo.

As informações de velocidade são utilizadas pela matriz  $F$ , que representa o modelo de transições de estados, de forma que cada modelo é representado pela velocidade do seu modo ( $V_s$ ). A matriz do modelo de transições de estados é:

$$F = \begin{bmatrix} 1 & V_s \\ 0 & 1 \end{bmatrix}$$

Esse valor se dá através da representação do espaço de estados do modelo dinâmico para velocidade constante. Dessa forma, temos que a função de transição de estados é dada por:

$$\begin{bmatrix} x \\ \dot{x} \end{bmatrix} = \begin{bmatrix} 1 & V_s \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ 1 \end{bmatrix}^T$$

A função de medição ou modelo de observação, define a forma que vamos das variáveis de estados às medições através da função  $\mathbf{z} = \mathbf{H}\mathbf{x}$ . Sabendo que a dimensão das variáveis de estados ( $x$ ) é  $2 \times 1$  e que temos a media ( $z$ ), ou seja,  $1 \times 1$ , sabendo dos conceitos de multiplicações de matrizes, temos que a matriz do modelo de observação deve ser  $1 \times 2$ .

Preenchendo os valores de  $H$ , queremos preencher apenas os valores de posição do sensor, dessa forma temos que:

$$\mathbf{H} = \begin{bmatrix} 1 & 0 \end{bmatrix}$$

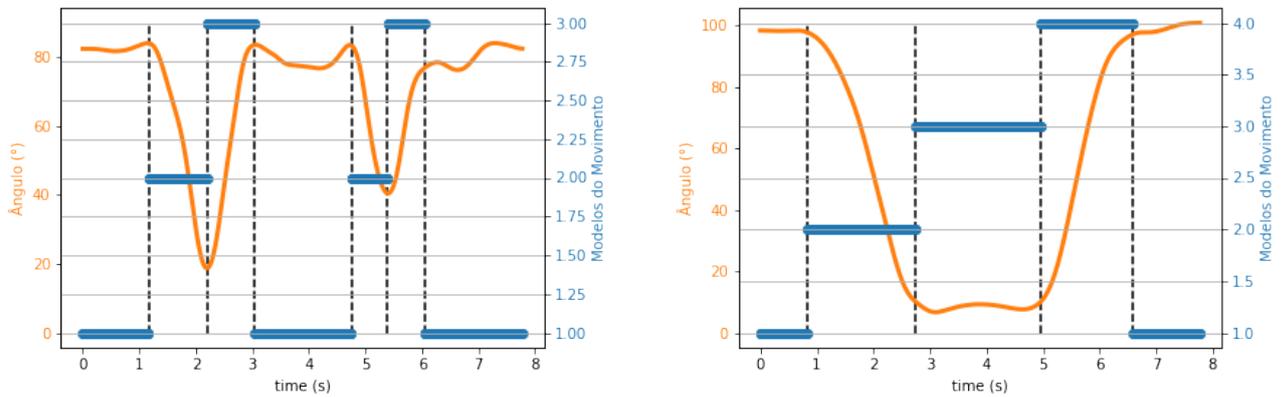
A função de medição é fixa para todos os modos, enquanto que o modelo de transições de estados é único para cada modo, sendo necessário alterar o índice  $1 \times 2$  da matriz  $F$  pelo valor da velocidade média de cada modo, gerando assim 3 modelos de transições de estados. Da mesma forma, para definir o estado inicial de cada modo, utilizamos a variável de estados, onde  $x$  representa a posição inicial de cada modo, dessa forma obtendo outros 3 modos. Na próxima seção iremos observar que para os dados da coxa, não teremos apenas 3 modelos e sim 4, isso acontece por causa da combinação de velocidade média com o estado inicial de cada modo.

### 3.5.2 Aplicação do Interacting Multiple Model

A partir das definições dos modelos de filtro de Kalman para cada modo do sistema, podemos aplicar o algoritmo IMM para a obtenção dos estados, para isso, precisamos definir duas entradas para o algoritmo, onde a primeira é a probabilidade inicial de cada

estado, ou seja, a probabilidade de cada filtro representar o estado inicial do sistema ( $\mu$ ) e também uma matriz de transição de estados, que deve ser calculada pela equação 2.22.

Dessa forma, temos que  $\mu$  deve possuir o tamanho de acordo com o número de modelos para o sinal, ou seja, para os dados de tronco, temos 3 modelos, de forma que o movimento ou está constante, ou subindo ou descendo, de forma que sempre que está com velocidade constante, a angulação média do movimento é aproximadamente a mesma. De forma similar acontece para os outros estados, onde o estado inicial é aproximadamente o mesmo para cada modo. Já para os dados da coxa, podemos observar na figura 22 que, para o modo de velocidade constante, temos dois estados iniciais possíveis, ou seja, temos dois modelos diferentes para a velocidade constante. Isso acarreta no acréscimo de um modelo extra, de forma que para a coxa serão necessários 4 modelos para representar o movimento, apresentado na figura 23.



(a) Exemplo da separação dos 3 modelos para os dados do tronco.

(b) Exemplo da separação dos 4 modelos para os dados da coxa esquerda.

Figura 23 – Exemplo aleatório para ilustrar a obtenção do melhor caminho pelo DTW.

Com isso, teremos um vetor  $\mu$  de probabilidades para cada movimento, sendo  $\mu$  de tamanho 3 para os dados do tronco e  $\mu$  de tamanho 4 para os dados da coxa. Para preencher esses vetores, sabendo que os dados apresentam uma sequência em que o voluntário inicialmente está em pé e essa fase representa o estado 1, teremos que a probabilidade inicial do filtro 1 representar o movimento é muito maior do que as dos demais filtros, tanto para o tronco como para os dados da coxa.

Podemos aplicar o algoritmo agora, porém não teremos sucesso na aplicação, isso acontece pois não temos nenhuma definição para os dados de covariância do ruído do processo e observação, de forma que o algoritmo não seria capaz identificar as transições de estados e as probabilidades de cada filtro ser o que representa o sinal não representam as transições de estados, como apresentado na figura 24.

Para corrigir esse problema é necessário aplicar as matrizes de covariância, já que os pesos aplicados ao filtro de Kalman para definir entre o estado predito e o sinal do sensor

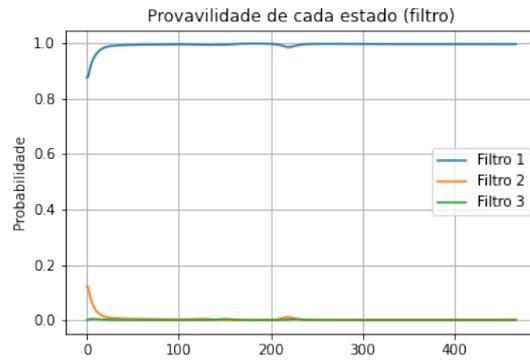


Figura 24 – Probabilidades de cada modelo (filtro) aplicados de forma errada para o movimento de sentar.

é calculado a partir dessas matrizes de incerteza. Dessa forma, para gerar esses valores de covariância do processo ( $Q_k$ ) e de observação ( $R_k$ ), utilizou-se inicialmente os valores de variância calculados para cada modo do movimento, dessa forma o resultado foi um pouco melhor, como apresentado na figura 25, porém ainda sem representar corretamente as transições de estado.

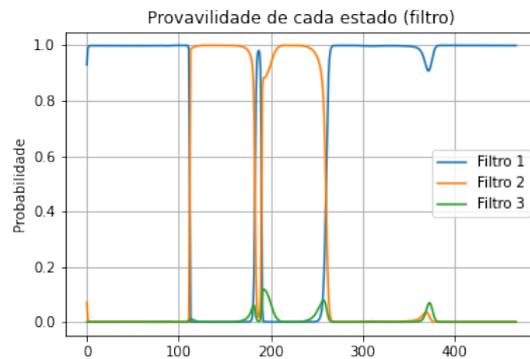


Figura 25 – Probabilidades de cada modelo (filtro) aplicados após a aplicação das matrizes  $Q_k$  e  $R_k$ .

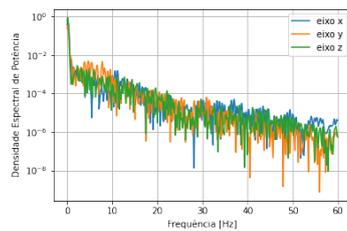
Como os valores de  $Q_k$  e  $R_k$  fornecem valores de incerteza que são utilizados para calcular uma média ponderada entre o valor medido pelo sensor e o valor previsto pelo modelo, a relação entre essas duas matrizes interferem diretamente na qualidade da classificação do filtro. Dessa forma, para aplicarmos o IMM, não queremos alterar muito os modelos, já que eles são importantes para segmentar os estados do movimento, dessa forma, foram escolhidos valores menores para a covariância do ruído do processo e valores maiores para o ruído da observação. Inicialmente, utilizou-se uma relação de  $R_k = 10 Q_k$ , em seguida aumentou-se para 100, obtendo resultados um pouco melhores. Esse processo foi realizado na base da tentativa e erro, observando o comportamento das respostas a cada mudança nas variáveis de covariância. Esse processo foi realizado até conseguir um resultado razoável para a segmentação das fases do movimento.

## 4 Resultados e Discussões

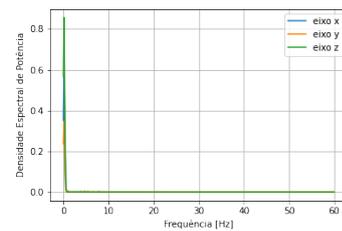
Este capítulo aborda os resultados obtidos para a análise e classificação automática dos movimentos de sentar e levantar, enfatizando dois métodos, um offline e um online, de avaliação de movimento, assim como de alguns blocos internos. Além disso, são realizadas as discussões e considerações acerca dos resultados obtidos.

### 4.1 Análise Espectral e Filtragem

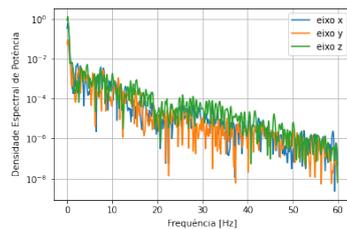
A partir dos dados de aceleração cedidos pelo (GHORBANI et al., 2020), foi realizada a análise espectral dos dados dos sensores da coxa esquerda, coxa direita e tronco, que são indexados pelo banco de dados como perna esquerda superior, perna direita superior e tronco, respectivamente.



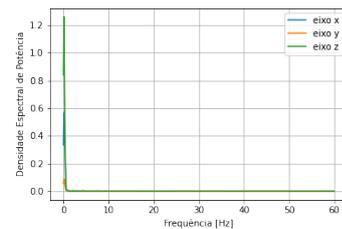
(a) Coxa esquerda em escala logarítmica



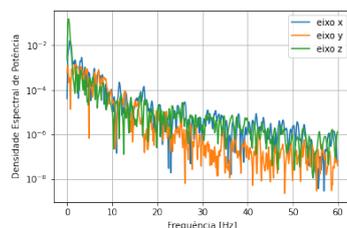
(b) Coxa esquerda em escala decimal



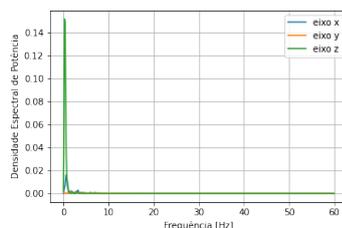
(c) Coxa direita em escala logarítmica



(d) Coxa direita em escala decimal



(e) Tronco em escala logarítmica

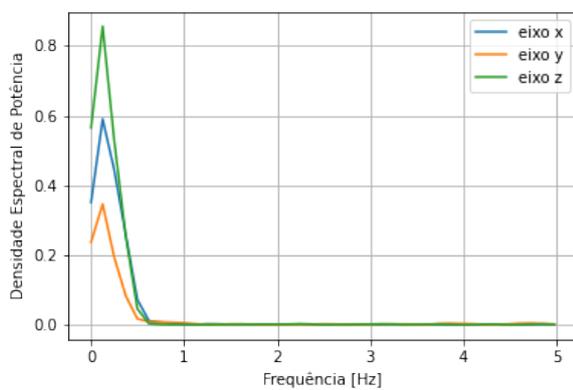


(f) Tronco em escala decimal

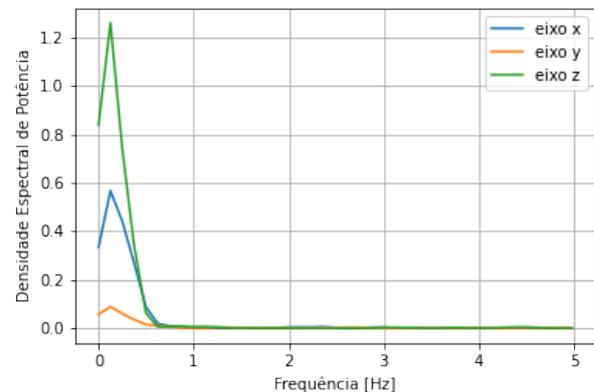
Figura 26 – Gráficos da densidade espectral de potência para o sinal da coxa esquerda apresentados em escala logarítmica (a) e em escala decimal (b), coxa direita apresentados em escala logarítmica (c) e em escala decimal (d) e do tronco apresentados em escala logarítmica (e) e em escala decimal (f).

A figura 26 apresenta essa análise com os dados obtidos de duas formas, uma com escala logarítmica e outra com escala decimal. Analisando esses resultados, é possível observar que as frequências do sinal de aceleração que realmente representam o movimento de sentar e levantar estão nas frequências mais baixas, em torno de 0 a 5 Hz.

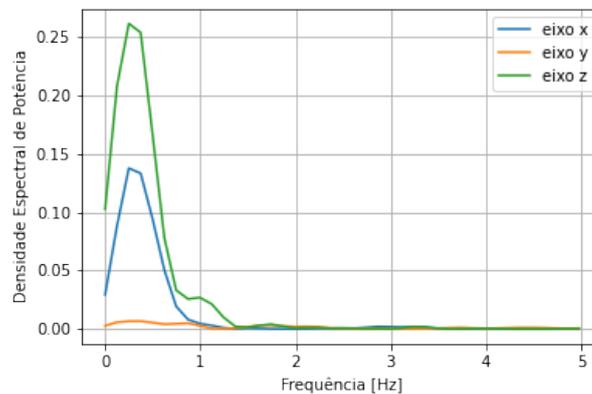
A partir desses dados, foi feita uma análise mais focada, dentro dessas frequências de interesse. Foram analisados vários exemplos, afim de escolher a melhor frequência de corte para filtrar esses sinais. Um desses exemplos é apresentado na figura 27, para os dados de coxa esquerda, coxa direita e tronco.



(a) Coxa esquerda



(b) Coxa direita



(c) Tronco

Figura 27 – Gráficos da densidade espectral de potência para o sinal da coxa esquerda (a), coxa direita (b) e tronco (c) com um zoom na faixa de 0 a 5 Hz.

Analisando os espectros dos sinais, foi definido a frequência de corte do filtro *butterwoth* de segunda ordem a ser utilizada, de forma que, para os sinais da coxa foi de 0,7 Hz e para o sinal do tronco foi de 1,3 Hz

Dessa forma foi possível obter o sinal do movimento, que é o sinal de interesse para realizar as análises posteriores. A figura 28 apresenta a comparação de um exemplo do dado filtrado e convertido em ângulo para o dado convertido em ângulo diretamente,

ou seja, o sinal com e sem filtragem.

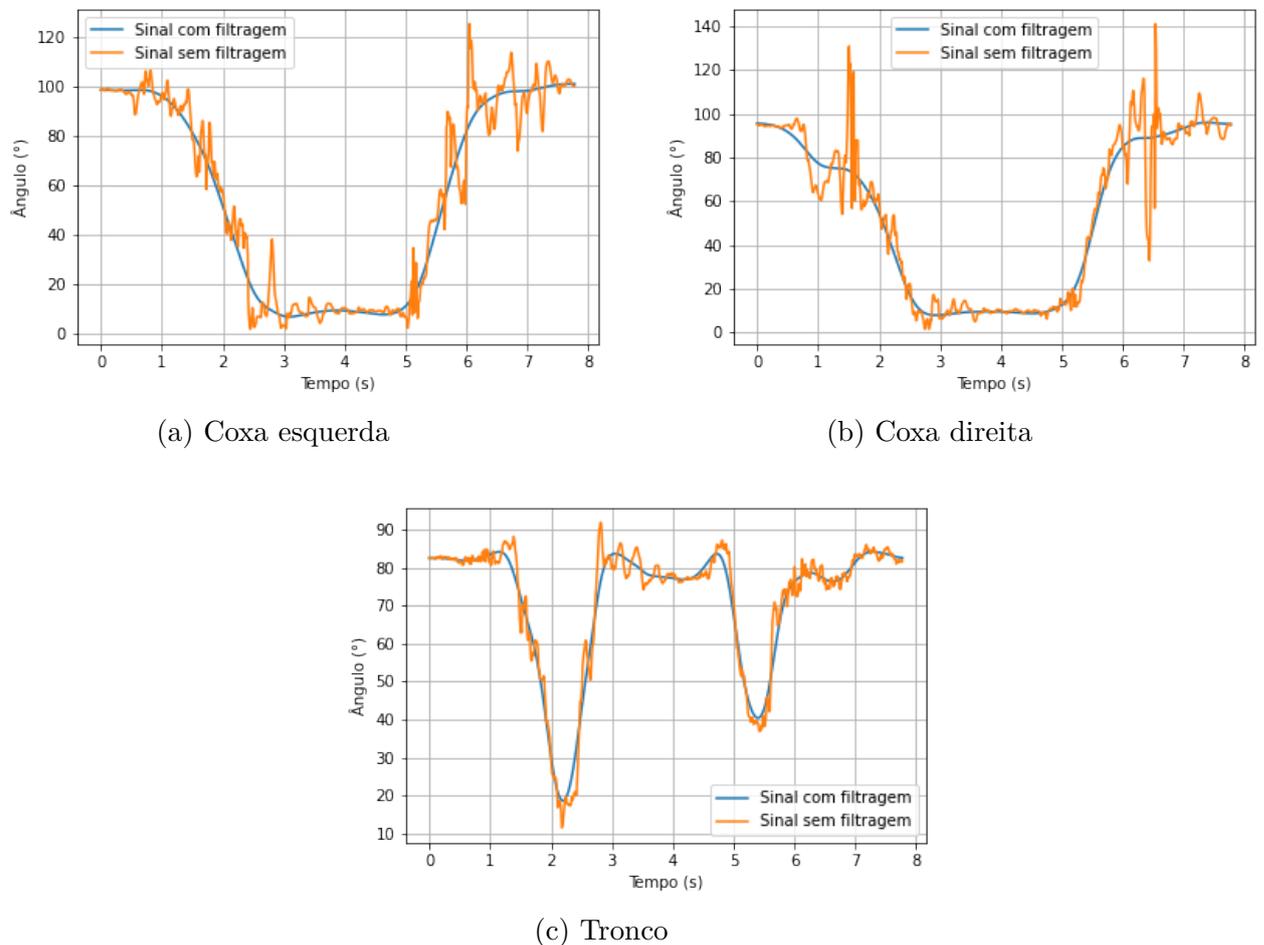


Figura 28 – Gráficos de comparação, da conversão dos dados de aceleração para dados ângulos, do sinal filtrado com o sinal não filtrado para a coxa esquerda (a), coxa direita (b) e tronco (c).

Após a aplicação do filtro, pode-se observar que o sinal do filtrado é uma boa representação do movimento de sentar e levantar para os dados de tronco e coxas.

## 4.2 Aplicação do Algoritmo DTW

A partir do movimento do voluntário escolhido como referência, realizou-se a aplicação do DTW, juntamente com os dados de movimento de um outro voluntário alvo, dessa forma foi possível obter um *heatmap*, seguindo os passos do algoritmo. Na figura 29 é apresentado os resultados desta aplicação, que representa as matrizes correspondentes aos ângulos das coxas esquerda, figura 29a, coxa direita, figura 29b e do tronco, figura 29c durante o movimento de sentar e levantar. Os caminhos encontrados na diagonal, na cor preta, representam as correspondências entre a referência e o alvo, as regiões mais escuras, na cor azul, representam os pontos nas matrizes onde a distância são maiores e

consequentemente as regiões mais claras representam as menores distâncias. Ao lado dos *heatmap* estão apresentadas as escalas das distâncias.

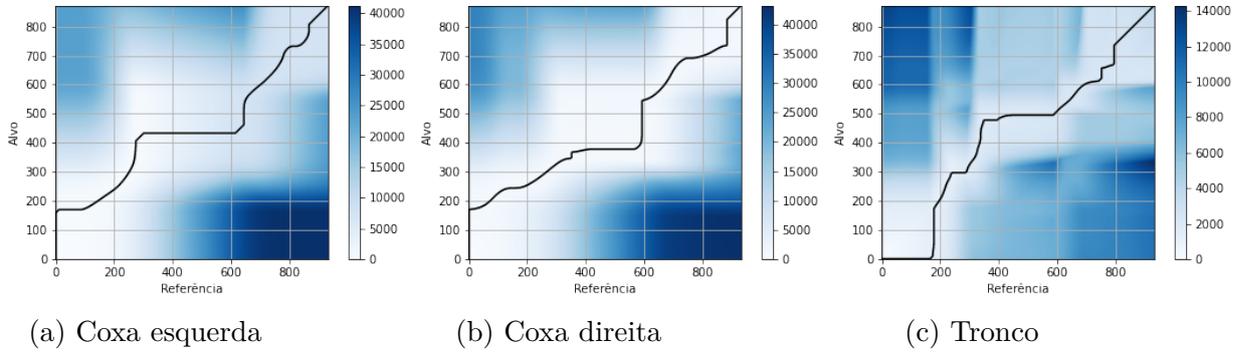


Figura 29 – *Warping path* para os dados de ângulos da coxa esquerda (a), coxa direita (b) e tronco (c).

Um outra forma de ilustrar a aplicação do DTW é através das distâncias euclidianas do custo cumulativo encontrado, que são armazenados em *path* de menores distâncias entre a referência e o alvo para cada um dos movimentos. A figura 30 apresenta os resultados dos sinais correlacionados no tempo durante o movimento de sentar e levantar.

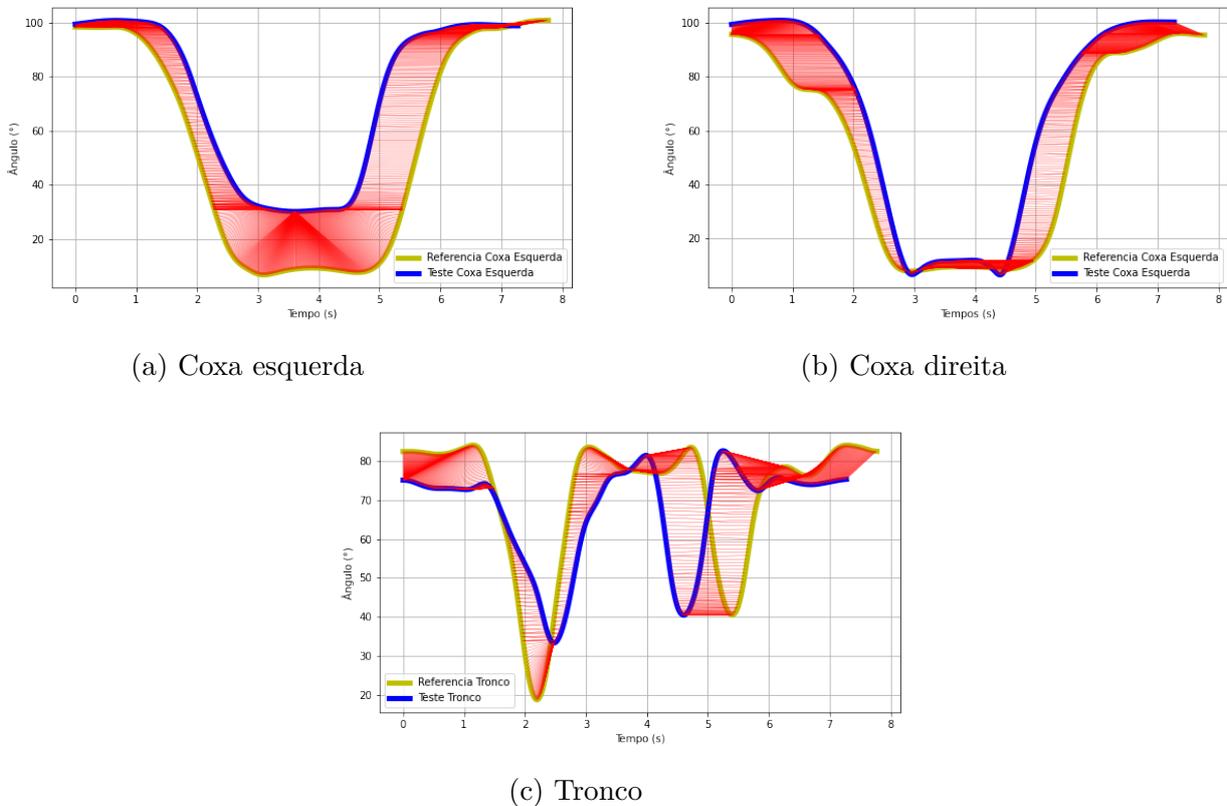


Figura 30 – Correspondência entre referência e alvo para os dados de ângulos durante o movimento para a coxa esquerda (a), coxa direita (b) e tronco (c). Em vermelho está as ligações de correspondências entre os sinais.

Nos gráficos da figura 30, as linhas vermelhas representam o mapeamento ponto a ponto de cada amostra entre os sinais durante o movimento. É possível observar que determinados pontos são conectados à vários outros pontos, demonstrando o ajuste do algoritmo para distorção causada no tempo.

Por fim, a partir dos dados de ângulos e da aplicação do algoritmo DTW, foi realizada a segmentação em fases do movimento de sentar e levantar, de forma que podemos obter dados de duração do movimento completo, de duração de cada fase e também os dados da inclinação máxima do tronco e a figura 31 apresenta os sinais e seus respectivos pontos de transição do movimento. A segmentação dos dados de referência foram realizadas manualmente utilizando o gráfico do próprio movimento para rotular os pontos de transição dos dados do movimento tronco e das coxas.

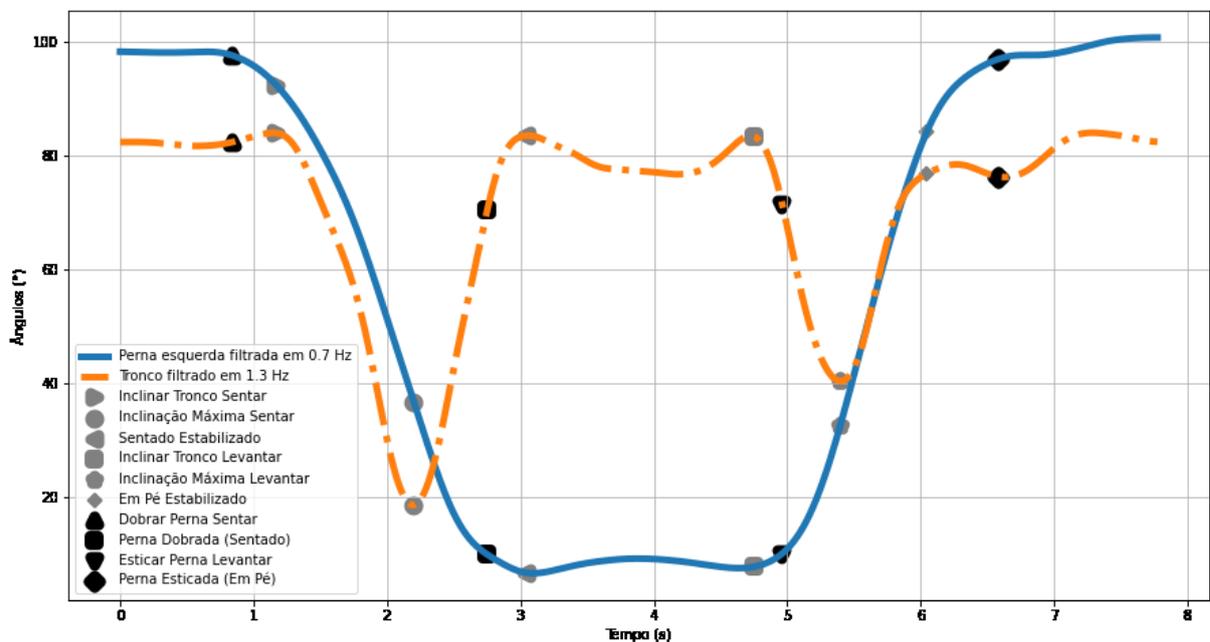
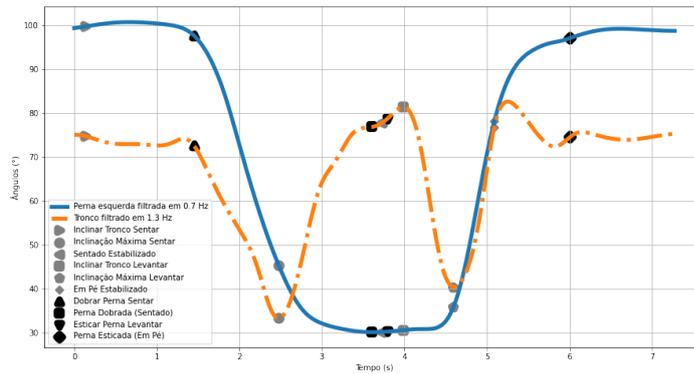


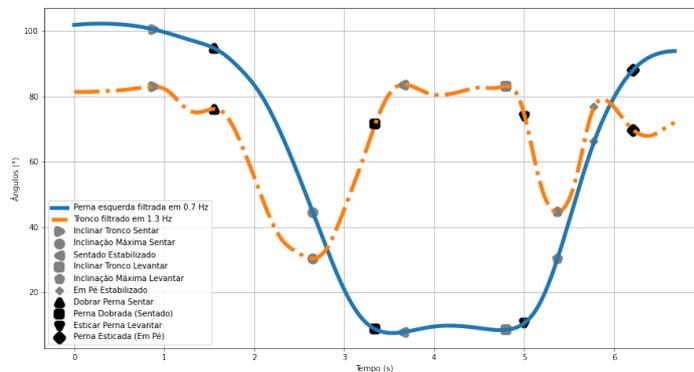
Figura 31 – Gráfico com os pontos de referência do movimento de sentar e levantar rotulados manualmente para o voluntário 52.

A partir desses dados de referência, rotulados manualmente, é necessário apenas a aplicação do algoritmo DTW e utilizar a relação encontrada para segmentar o movimento alvo. Na figura 32, são apresentados dois exemplos de segmentação automática realizada pelo DTW, uma feita para o voluntário 23 em que a aplicação gera resultados menos precisos para o início e final do movimento, apresentados na figura 32a (os dados do voluntário 23 foram utilizados como alvo nos exemplos anteriores) e outra realizada com o voluntário 21, que fornece um exemplo de segmentação com um sucesso maior na aplicação, apresentado na figura 32b.

Observando os dois resultados, podemos observar que o algoritmo DTW consegue segmentar as fases do movimento, porém o resultado pode não ser muito efetivo em alguns casos, como por exemplo, o caso do alvo ser o voluntário 23. Podemos observar na figura



(a) Voluntário 23



(b) Voluntário 21

Figura 32 – Resultado da aplicação do DTW para o tronco e coxa esquerda com o alvo sendo o voluntário 23 e para o tronco e coxa direita com o alvo sendo o voluntário 21.

32a que o algoritmo teve dificuldade para segmentar o primeiro estágio do movimento do tronco, o qual foi classificado como inclinar o tronco para sentar, quando na verdade isso acontece por volta do tempo de 1,5 segundos depois.

Analisando os dois exemplos de alvos, apresentados na figura 32 e comparando-os com o exemplo de referência, apresentados na figura 31, podemos observar que o algoritmo é bastante sensível a pequenas variações nas inclinações máximas e mínimas do tronco e da coxa durante o movimento de sentar e levantar, para melhor entendimento, vamos observar apenas os dados das coxas para os 3 movimentos. Ao comparar apenas o movimento das coxas da referência, figura 32 com o alvo 21m figura 32b, podemos observar que a fase entre a Perna Dobrada (Sentado) e Esticar Perna Levantar, possui um comportamento praticamente igual entre os dois movimentos, onde acontece uma inclinação máxima duas vezes (dois vales), uma um pouco depois de Dobrar Perna Sentar e outra um pouco antes de Esticar Perna Levantar. Nesse caso é possível observar que o algoritmo teve sucesso na detecção. Agora fazendo a comparação dessa mesma fase, porém com o voluntário 23,

figura 32a, podemos observar que existe uma inclinação máxima quase que constante e por um tempo maior, dessa forma o algoritmo teve dificuldade de identificar o momento exato em que o movimento de sentar foi finalizado assim como o momento em que o movimento de levantar começa.

Apesar da identificação individual, para cada ponto de transição movimento (tronco e coxa), ser bastante suscetível a pequenas variações do movimento, ao realizar a análise definindo as fases como um conjunto das etapas dos movimentos do tronco e da coxa, o algoritmo e as detecções passam a ser mais robustas, como apresentado na próxima seção.

### 4.3 Segmentação Automática Offline das Fases do Movimento de Sentar e Levantar.

Para a aplicação da segmentação automática das fases, utilizou-se as definições de transições descritas em 3.2, de forma que, apesar do algoritmo ter sido aplicado para a sequência sentar e levantar completa, essa segmentação de fases foi realizada separando os movimento de sentar e de levantar.

Essa separação, entre os dois movimento, foi realizada pegando a metade do tempo calculado a partir do momento em que o voluntário terminou de sentar até o momento em que o voluntário começa a se levantar. Com isso, para os dados de referência, podemos apresentar a segmentação de fases do movimento de sentar e levantar conforme a figura 33.

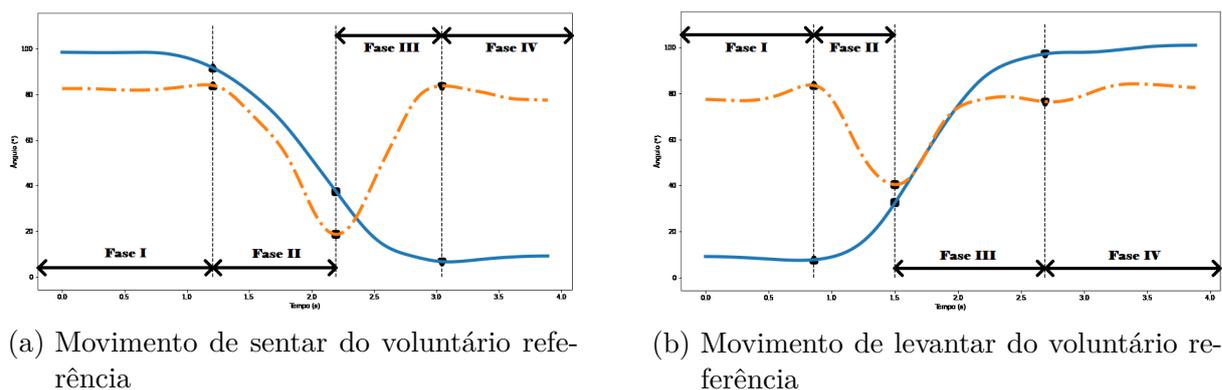


Figura 33 – Segmentação das fases do movimento de sentar e levantar para a referência.

Para o movimento de sentar, figura 33a, temos que na Fase I o voluntário está em pé, na Fase II o voluntário está sentando, de forma que a transição ocorre com o movimento do tronco e da coxa e vai até o momento de inclinação máxima do tronco. Na Fase III, que vai do momento de inclinação máxima do tronco até o momento em que o tronco se estabiliza, o voluntário está finalizando o movimento de sentar. Na Fase IV, o movimento de sentar foi finalizado e o voluntário está sentado.

Para o movimento de levantar, figura 33b, temos que na Fase I o voluntário está sentado, na Fase II o voluntário inicia o movimento de levantar, dado pelo início da inclinação do tronco até o momento de inclinação máxima. Na Fase III, que acontece do momento de inclinação máxima do tronco até o momento de estabilização do tronco ou coxa, o voluntário está finalizando o movimento de levantar. Por ultimo, na Fase IV, o movimento de levantar foi finalizado e o voluntário está em pé.

Dessa forma, aplicando o algoritmo de segmentação automática *offline* do movimento de sentar e levantar, temos como resultado, para exemplificar, a figura 34, que é referente aos dados do voluntário 23.

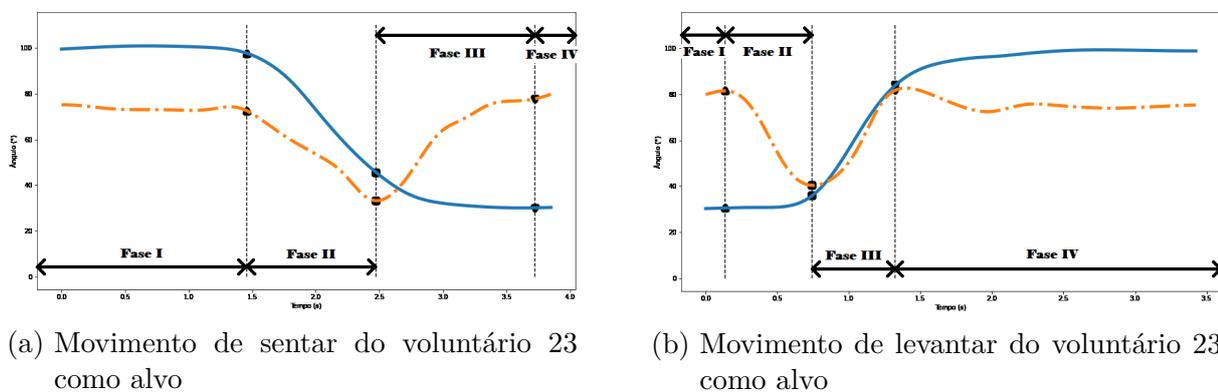


Figura 34 – Resultado do DTW aplicado na segmentação das fases do movimento de forma automática.

Observando os gráficos do resultado da segmentação do movimento de forma automática para o voluntário 23, o qual apresentou dificuldade na detecção das fases individuais do tronco e da coxa, figura 32a, ao usar esses dados simultaneamente, de acordo com 3.2, podemos observar que é possível obter uma separação de fases do movimento de sentar e levantar de forma automática que é condizente com o esperado, ou seja, essa definição de fases tornou o algoritmo mais robusto a variações.

Por fim, foi realizada um análise da aplicação do DTW em 41 exemplos, de forma que foi necessário realizar a segmentação manualmente para compara-los ao resultado do algoritmo. Os resultados estão apresentados na tabela 2, apresentando a média e desvio padrão dos erros entre as segmentação manual e automática gerada a partir do DTW. São apresentados dados para o movimento de sentar e levantar, observando em um momento, os dados do sensor do tronco e coxa direita e em um outro momento, os dados do sensor do tronco e da coxa esquerda.

Ao analisar os dados, podemos ver que os resultados mais divergentes, com o maior erro entre a classificação manual e a classificação gerada pelo DTW, são observados no movimento de sentar para a transição entre as fases I e II, de forma que para a segmentação gerada pelos dados dos sensores do tronco e da coxa esquerda esse erro foi um pouco mais

Erro Médio Para Transição (segundos)			
Movimento (Sensores)	Fase I/Fase II	Fase II/Fase III	Fase III/Fase IV
Sentar (Tronco e Coxa Direita)	0.4203 (0.2495)	0.0446 (0.0813)	0.2801 (0.3307)
Sentar (Tronco e Coxa Esquerda)	0.9069 (0.6959)	0.0443 (0.0814)	0.2801 (0.3307)
Levantar (Tronco e Coxa Direita)	0.2049 (0.1952)	0.1255 (0.1629)	0.3298 (0.2522)
Levantar (Tronco e Coxa Esquerda)	0.2049 (0.1952)	0.1255 (0.1629)	0.2911 (0.2765)

Tabela 2 – Análise de erro da segmentação automática *offline* das fases do movimento de sentar e levantar (média (desvio padrão)).

que o dobro aos dados gerados pelos sensores do tronco e coxa direita para o mesmo movimento.

Uma forma de entender esses resultados é pela forma na qual os movimentos foram obtidos, onde cada voluntário, ao realizar o movimento de sentar, muitas vezes começam a realização do movimento um pouco afastado do assento, de forma que é necessária uma correção no movimento de sentar para o mesmo alcançar o assento de forma correta e essa correção de movimento não obedece necessariamente um padrão, como ocorre ao realizar o movimento de sentar e levantar, dificultando o algoritmo de realizar as correlações corretas da referência com o alvo. Podemos observar também que a segmentação de maior sucesso ocorreu na transição da Fase II para a Fase III, justamente na fase em que ocorre a maior inclinação do tronco, que é realizado dentro de um padrão de movimento mais claro, facilitando essa detecção pelo algoritmo.

Além desses dados, também foram obtidos os dados de tempo das fases relacionadas ao movimento de sentar e levantar. Para deixar mais claro, durante a Fase I o voluntário está em pé, de forma que o movimento de sentar se inicia na transição da Fase I para a Fase II e finaliza na transição da Fase III para a Fase IV, onde o voluntário já está sentado, por esse motivo, os dados de duração de movimento que são de interesses são os obtidos nas fases II e III e estão apresentados na tabela 3.

Como observado anteriormente, a segmentação da transição entre as fases I e II do movimento de sentar obtiveram os maiores erros e da mesma forma, observando o tempo identificado para a Fase II do movimento de sentar (início do movimento até a inclinação máxima do tronco), nota-se as maiores diferenças entre a segmentação manual e a realizada de forma automática. A explicação para esse fato é justamente a citada anteriormente, que causou um erro maior na definição do momento de transição e conseqüentemente

Tempo Médio Para Fase (segundos)				
Movimento (Sensores)	Fase II - Manual	Fase II - DTW	Fase III - Manual	Fase III - DTW
Sentar (Tronco e Coxa Direita)	1.1000 (0.3310)	0.7580 (0.3076)	1.0563 (0.3775)	1.0795 (0.3965)
Sentar (Tronco e Coxa Esquerda)	1.0365 (0.3322)	1.8718 (0.6687)	1.0563 (0.3775)	1.0797 (0.3963)
Levantar (Tronco e Coxa Direita)	0.7769 (0.2248)	0.6825 (0.1818)	0.6710 (0.1846)	0.7283 (0.3599)
Levantar (Tronco e Coxa Esquerda)	0.7769 (0.2248)	0.6825 (0.1818)	0.6716 (0.1254)	0.7741 (0.3776)

Tabela 3 – Análise do tempo para das fases II e III do movimento de sentar e levantar comparando a segmentação manual com a segmentação automática *offline* (média (desvio padrão)).

ocasiona um tempo diferente entre as duas formas de segmentar o movimento.

Podemos também, observar que a Fase III para o movimento de sentar foi muito bem segmentada, de forma que a diferença no tempo de execução dessa etapa encontrada entre a segmentação manual e automática é de aproximadamente 25 centésimos de segundo.

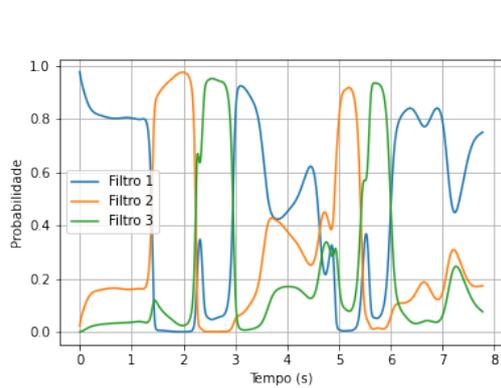
## 4.4 Aplicação do Algoritmo IMM

Para a aplicação do IMM, primeiramente é necessário gerar os modelos para cada modo do movimento, como apresentado em 3.5.2. Após a aplicação dos modelos foi necessário encontrar uma razão entre as covariâncias do ruído do processo e observação,  $Q_k$  e  $R_k$  respectivamente. Com base na tentativa e erro, chegou ao resultado dos modelos utilizados pelo algoritmo IMM para estimar as fases do movimento de sentar e levantar.

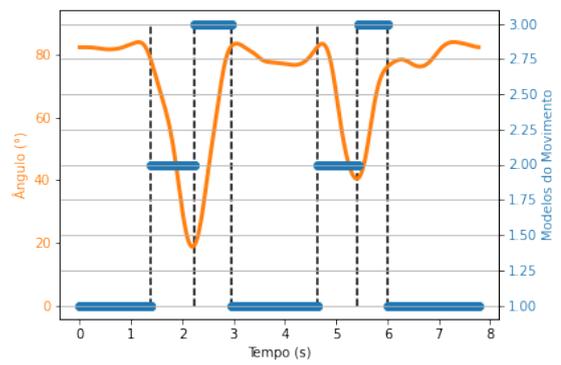
A partir do resultado das probabilidades para cada filtro, apresentado na figura 35a, pode-se definir o filtro com a maior probabilidade como o estado atual, dessa forma é possível gerar os resultados de modos para cada movimento. Para exemplificar, a figura 35b apresenta o resultado do algoritmo aplicado apenas para os dados do tronco durante o movimento de sentar e levantar.

Aplicando os mesmo passos, gerando os modelos e matrizes de covariância, mas dessa vez aplicando para os dados de uma das coxas, podemos observar que o algoritmo conseguiu realizar a segmentação dos modos, apresentado na figura 36.

Com esses resultados, é possível observar que os modelos foram definidos obtendo

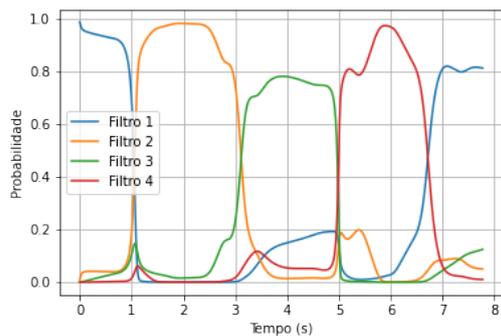


(a) Gráfico das probabilidades de cada modo para o movimento.

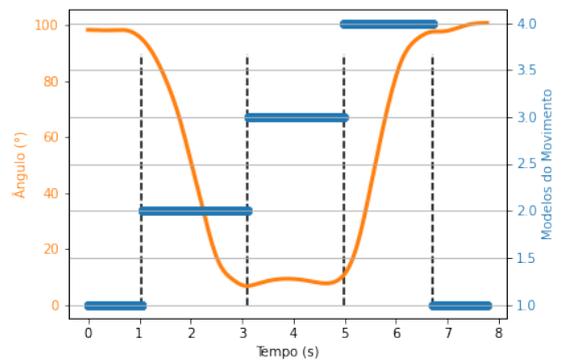


(b) Gráfico de comparação do sinal do movimento com os estados obtidos pelas probabilidades geradas pelo IMM.

Figura 35 – Resultado do IMM aplicado aos dados do tronco para o movimento de sentar e levantar.



(a) Gráfico das probabilidades de cada modo para o movimento.



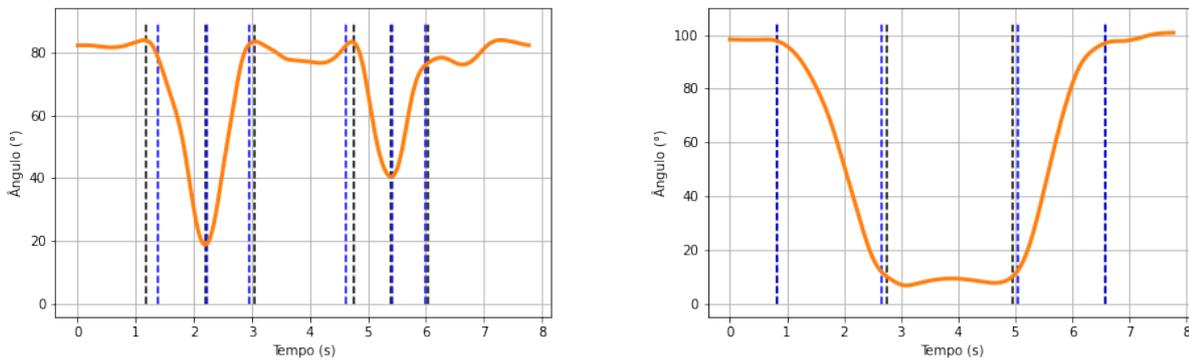
(b) Gráfico de comparação do sinal do movimento com os estados obtidos pelas probabilidades geradas pelo IMM.

Figura 36 – Resultado do IMM aplicado aos dados da coxa para o movimento de sentar e levantar.

uma boa resposta para as transições dos estados do movimento, tanto para os dados do tronco como para os dados da coxa. Como métrica, foi calculado o erro médio absoluto entre as transições de fases definidos manualmente e definidos pelo algoritmo, de forma que o erro médio para as estimações de transições do tronco foi de 0,083 segundos, ou 83 milésimos de segundos e para o erro médio das estimações da coxa foi de 0,042 segundos, ou 42 milésimos de segundos.

As figuras 37 são uma forma de representar o erro temporal dessa classificação em cada uma das fases, onde a linha tracejada na vertical apresenta os pontos de transição de modos, de forma que a linha preta representa o ponto de transição escolhido manualmente e a linha azul apresenta o ponto de transição encontrado pelo algoritmo IMM.

Analisando os gráfico, podemos observar que, para os dados da coxa, a primeira



(a) Gráfico de comparação do atraso na identificação das transições de fase do algoritmo IMM para os dados do tronco.

(b) Gráfico de comparação do atraso na identificação das transições de fase do algoritmo IMM para os dados da coxa.

Figura 37 – Resultado dos atrasos na identificação das transições de fases do movimento do tronco e da coxa para o voluntário 52.

e última transição estimadas pelo IMM foram as mesmas da selecionada manualmente. Além disso, para as transições intermediárias apresentam um erro aproximadamente igual para as duas transições (comprovando-se iguais ao calcular a média do erro), sendo um adiantado e o outro atrasado em relação à estimativa manual. Nesse ponto, vale ressaltar que as estimativas de pontos de transições encontradas manualmente foram realizadas olhando apenas os gráficos, de forma que as transições escolhidas manualmente também possuem algum erro, o que é válido para todas as transições.

Como os dados da coxa são mais simétricos e estáveis, foi possível gerar modelos que na aplicação do IMM apresentam uma excelente estimativa, sendo melhor do que o gerado para os dados do tronco, porém, quando esses modelos são utilizados para aplicar em dados de outro voluntário, a detecção das transições pode ser feita de forma errada a depender da forma do sinal do voluntário aplicado. Um exemplo recorrente encontrado no banco de dados é o fato de ao realizar o movimento de sentar, o voluntário começa a inclinação do tronco e coxa enquanto está se movimentando para o lugar do assento, interferindo diretamente na forma do sinal observado. Para exemplificar, foram obtidos os resultados da figura 38 para os dados de tronco e da coxa para o voluntário 21.

Observando a forma do sinal do voluntário 21, figura 38, podemos observar que no início do sinal ocorre justamente o movimento descrito anteriormente, onde o movimento se inicia, passa por uma transição onde o voluntário está se movimentando em direção ao assento (observado pelos vídeos) e em seguida dá-se o complemento do movimento de sentar e posteriormente de se levantar. Essa variação do movimento foi encontrada em vários outros exemplos, assim como também foi encontrada no final do movimento de levantar, de forma que o voluntário durante o final do movimento de se levantar acaba se afastando do assento, gerando um resultado similar ao apresentado no início do movimento do voluntário 21.

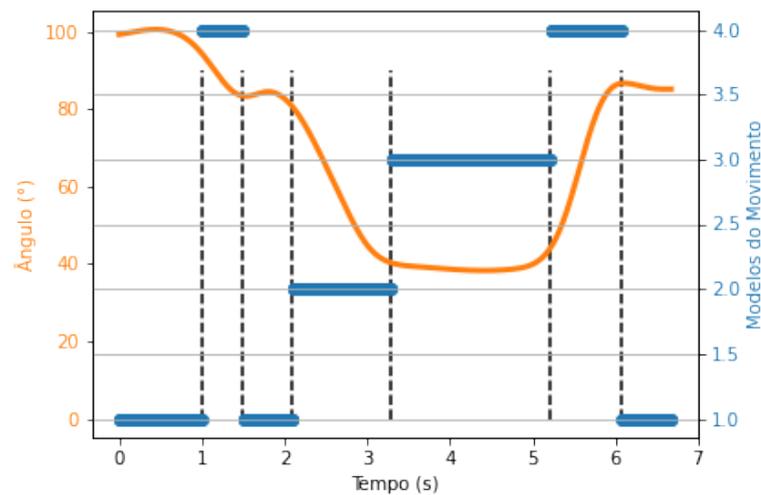


Figura 38 – Gráfico de comparação do sinal do movimento da coxa com os estados obtidos pelas probabilidades geradas pelo IMM para o voluntário 21.

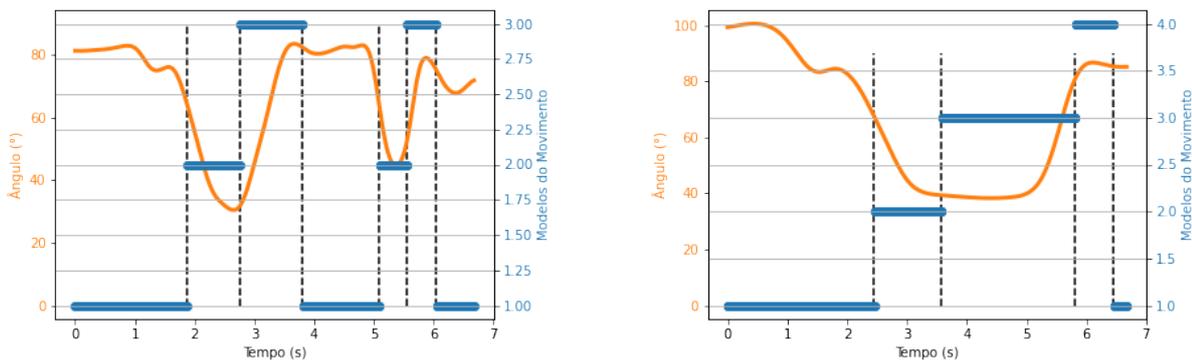
Com toda essa análise, podemos dizer que esses modelos apresentados são bons modelos para um sistema controlado, onde o movimento de sentar e levantar é exclusivamente o único movimento apresentado. Porém, o banco de dados utilizado não fornece esse movimento de forma controlada, sendo necessário gerar modelos mais genéricos, porém essa generalização acarreta em um custo, que é o atraso na identificação das transições de estados.

Analisando mais uma vez a figura 38, podemos observar que entre o tempo de aproximadamente 1 segundo até aproximadamente 2 segundos, o algoritmo modelado não consegue identificar corretamente o estado, de forma que somente após os 2 segundos que é possível dizer que o movimento pode ser identificado pelo modelo 2. Dessa forma, para desenvolver um sistema robusto o suficiente para ignorar essa transição, é necessário gerar modelos menos sensíveis, conseqüentemente, que demorem um pouco mais para gerar as transições e ocasionando um atraso na detecção.

Esse modelo mais genérico foi gerado e seus resultados são apresentados na figura 39, onde é possível comparar a identificação das transições com o sinal do movimento.

É possível observar que apesar do atraso, as identificações das fases ocorrem de forma correta, claro que com uma faixa de erro, mas é possível segmentar as etapas de cada movimento.

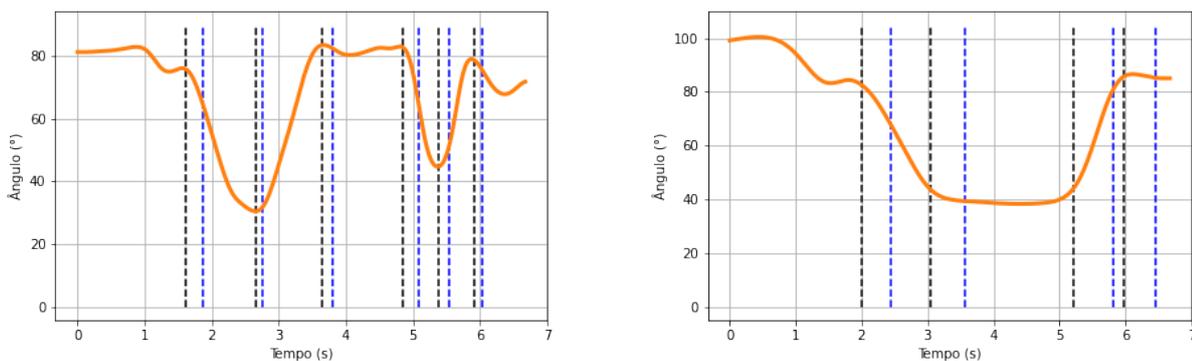
Foi calculado o a média do módulo do erro, para se ter uma ideia da quantidade do atraso para cada movimento, de forma que para o movimento do tronco foi encontrado um atraso médio de 0.167 segundos, sendo o maior erro no valor de 0.259 segundos. Para os dados da coxa, o atraso médio obtido foi de 0.509 segundos, sendo o maior erro de estimativa no valor de 0.601 segundos. Para ilustrar, a figura 40 apresenta, em linhas tracejadas verticais, os pontos de transição definidos manualmente e os pontos de transição



(a) Gráfico de identificação das transições de fase do algoritmo IMM genérico para os dados do tronco.

(b) Gráfico de identificação das transições de fase do algoritmo IMM genérico para os dados da coxa.

Figura 39 – Resultado da identificação das transições de fases do movimento do tronco e da coxa para o voluntário 52 gerados através de um modelo mais genérico.



(a) Gráfico de comparação do atraso na identificação das transições de fase do algoritmo IMM mais genérico, para os dados do tronco.

(b) Gráfico de comparação do atraso na identificação das transições de fase do algoritmo IMM mais genérico, para os dados da coxa.

Figura 40 – Resultado dos atrasos na identificação das transições de fases do movimento do tronco e da coxa para o voluntário 21, com um algoritmo mais genérico.

definidos pelo algoritmo IMM mais genérico, nas cores pretas e azuis, respectivamente.

Esses atrasos podem ser otimizados, porém não é possível evita-lo totalmente sem indicar transições inexistentes e isso é necessário para atender as especificidades desse banco de dados utilizado no estudo. Como dito anteriormente, um modelo mais específico e mais exato, pode ser aplicado, porém as condições do movimento deverá ser controlada.

Para obter um algoritmo com um atraso menor, é necessário gastar um certo tempo para conseguir otimizar a relação de covariância dos ruídos de cada modelo, porém, como o objetivo desse trabalho é apenas realizar a segmentação das fases, o próximo passo é gerar um algoritmo para unir as informações das transições de estados do tronco com as da coxa afim de gerar uma única e geral separação de fases.

## 4.5 Segmentação Automática *Online* das Fases do Movimento de Sentar e Levantar.

Para segmentar as fases de forma automática, assim como para a segmentação das fases realizadas pelo algoritmo DTW, utilizou-se as definições do movimento descritas em 3.2, de forma que o algoritmo foi aplicado na sequência completa do movimento, porém, para a apresentação dos resultados, os dados do movimento de sentar será separado do movimento de levantar, para facilitar a visualização e análise dos resultados.

A separação dos movimentos também foi realizada separando os dados entre o final do movimento de sentar e o início do movimento de levantar. A figura 41 apresenta o resultado da segmentação automática e *online* utilizando o IMM genérico, para gerar os pontos de transição do voluntário 52. Além disso é apresentado os resultados da segmentação manual, como forma de comparação.

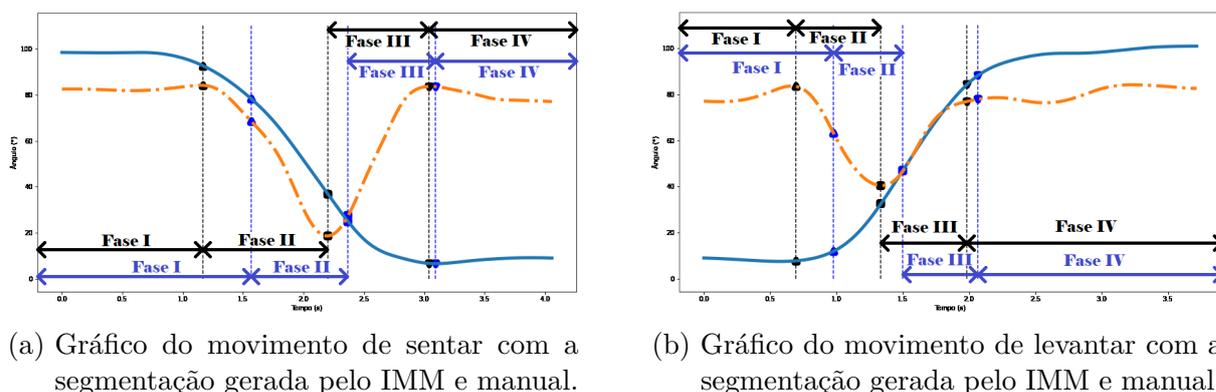


Figura 41 – Resultado da segmentação automática e *online* gerada pelo IMM (azul) em comparação com a segmentação manual (preto), para o voluntário 52.

Para a figura 41, temos que as transições das fases encontradas pelo algoritmo IMM, em azul, apresenta um atraso nas transições das fases, principalmente nas transições da Fase I para a Fase II. Esse atraso é obtido no processo de generalizar os modelos do movimento.

A partir do atraso temporal na detecção dos pontos de transição entre as fases, podemos observar um erro em outra informação de interesse, que é o ponto de máxima inclinação do tronco durante cada movimento. Como exemplo, temos na figura 42 um gráfico para o movimento de sentar demonstrando a relação do erro de atraso na detecção do ponto de transição com o erro de ângulo na detecção da máxima inclinação do tronco.

Com a generalização, apesar do atraso, podemos segmentar as fases do movimento de outro voluntário, mesmo que o voluntário tenha realizado alguma pequena movimentação extra além do movimento de sentar e levantar. Para exemplificar, utilizando o mesmo modelo genérico aplicado no voluntário 52, apresentado na figura 41, para aplica-lo no voluntário 21, obtendo os resultados da figura 43.

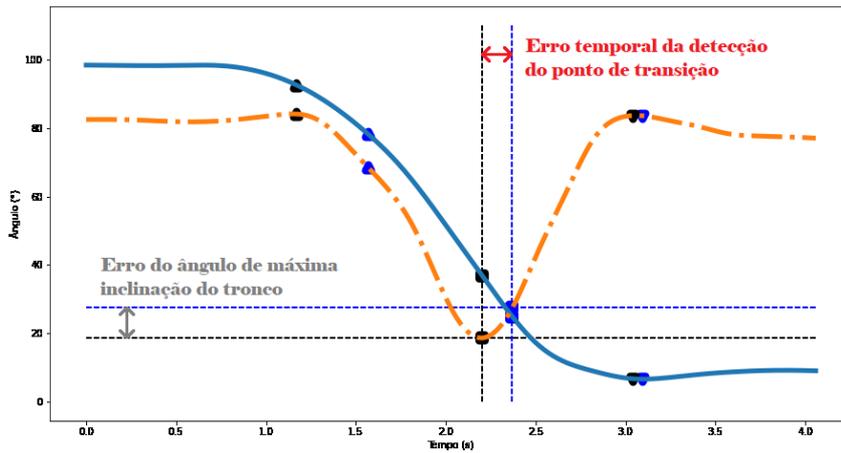
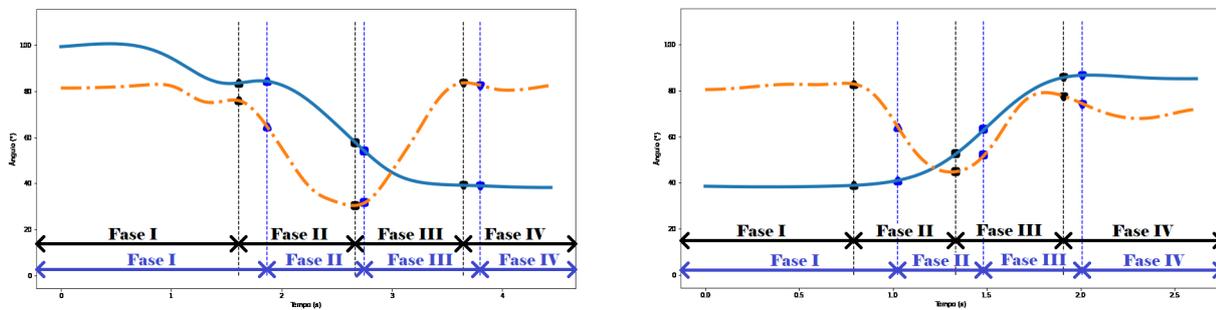


Figura 42 – Gráfico da relação entre o erro temporal com o erro do ângulo de máxima inclinação do tronco para o movimento de sentar.



(a) Gráfico do movimento de sentar com a segmentação gerada pelo IMM e manual.

(b) Gráfico do movimento de levantar com a segmentação gerada pelo IMM e manual.

Figura 43 – Resultado da segmentação automática e *online* gerada pelo IMM (azul) em comparação com a segmentação manual (preto), para o voluntário 21.

Podemos observar que nos dois exemplos, ao realizar a aplicação do algoritmo e segmentação das fases e compará-los com a segmentação feita manualmente, é apresentado um atraso na detecção do momento de transição das fases. Como parâmetro, aplicando o algoritmo em 20 exemplos, podemos calcular o erro médio dos momentos de transição das fases detectadas pelo algoritmo em comparação com as definidas manualmente. Os resultados são apresentados na tabela 4.

Analisando os dados obtidos, podemos verificar que a média de erro na determinação das transições ocorrem mantendo uma certa constância nos valores. Além disso, para os dados de sentar, podemos observar que a cada fase, em média, o erro diminuiu 2 décimos de segundo. Apesar de se aproximar lentamente do valor segmentado manualmente, é interessante que esses valores sejam próximos, de forma ser possível observar um tempo semelhante em cada fase do movimento, analisado posteriormente na tabela 5. Para o movimento de Levantar, os erros da transição das fases I/II e III/IV são próximos, porém para transição das fases II/III, esse erro é menor.

Agora comparando os dados obtidos com a coxa direita e esquerda, podemos ob-

Erro Médio Para Transição (segundos)			
Movimento (Sensores)	Fase I/Fase II	Fase II/Fase III	Fase III/Fase IV
Sentar (Tronco e Coxa Direita)	0.6202 (0.4253)	0.6093 (0.4415)	0.5830 (0.3943)
Sentar (Tronco e Coxa Esquerda)	0.6952 (0.534)	0.6093 (0.4415)	0.5830 (0.3943)
Levantar (Tronco e Coxa Direita)	0.7212 (0.3033)	0.5406 (0.2837)	0.7191 (0.3463)
Levantar (Tronco e Coxa Esquerda)	0.7212 (0.3033)	0.5406 (0.2837)	0.7746 (0.3176)

Tabela 4 – Análise de erro da segmentação automática *online* das fases do movimento de sentar e levantar (média (desvio padrão)).

servar que para coxa esquerda, tanto no início do movimento de sentar como no final do movimento de levantar, possuem um erro maior, reforçando que existe um movimento de ajuste ao se sentar e que no caso do movimento de se levantar, esse ajuste é para ficar na posição de frente para câmera central. Não é objeto de estudo, mas com esses dados é possível observar a maioria dos voluntários tendem a alterar o movimento com a coxa esquerda, apesar de que apenas 5 dos voluntários são canhotos.

Podemos entender esse resultado com base na discussão feita em 4.4, onde foi demonstrado que para obter um algoritmo versátil, é necessário criar um modelo mais genérico para aplicar no algoritmo e que o custo dessa maior generalização do modelo é um atraso na detecção das fases.

Além desses dados, também foram obtidos os dados referentes ao tempo de duração nas fases relacionadas ao movimento de sentar e levantar, que são as fases II e III, apresentados na tabela 5.

Como observado anteriormente, apesar do atraso na detecção das fases, como esse atraso, para o movimento de sentar, é similar em todas as detecções de transição, o tempo do movimento em cada uma das duas fases é similar entre o encontrado pela segmentação manual e pela segmentação automática *online*. Como o mesmo não ocorre na segmentação para o movimento de levantar, conseqüentemente o tempo em cada fase se difere quanto a comparação do algoritmo com a segmentação manual. Podemos observar que o algoritmo, para o movimento de levantar, detectou um tempo na Fase II menor que a realidade e um tempo na Fase III maior, de forma que a duração total, durante as fases II e III, são aproximadamente iguais para o movimento de levantar.

Uma outra observação interessante é quanto ao desvio padrão desses dados, é

Tempo Médio Para Fase (segundos)				
Movimento (Sensores)	Fase II - Manual	Fase II - IMM	Fase III - Manual	Fase III - IMM
Sentar (Tronco e Coxa Direita)	1.1570 (0.2747)	1.1094 (0.0022)	0.9222 (0.2136)	1.0427 (0.0022)
Sentar (Tronco e Coxa Esquerda)	0.9701 (0.2639)	1.1094 (0.0022)	0.9222 (0.2136)	1.0427 (0.0022)
Levantar (Tronco e Coxa Direita)	0.7495 (0.1608)	0.4338 (0.0012)	0.7082 (0.2266)	0.9259 (0.0023)
Levantar (Tronco e Coxa Esquerda)	0.7495 (0.1608)	0.4338 (0.0011)	0.6652 (0.1013)	0.9593 (0.0023)

Tabela 5 – Análise do tempo para das fases II e III do movimento de sentar e levantar comparando a segmentação manual com a segmentação automática *online* (média (desvio padrão)).

possível observar que os dados gerados pelo IMM possuem um desvio padrão menor do que o da segmentação manual, porém, isso não significa que o algoritmo entrega dados mais corretos, na verdade esse valor é encontrado pelo fato do algoritmo trabalhar com um modelo, gerando uma tendência para os valores obtidos.

## 5 Conclusão

A avaliação automática de movimentos tem se tornado uma área de estudo a cada dia mais explorada e desenvolvida, com cada vez mais pesquisas, auxiliando pacientes com debilidades motoras, na indústria, no treinamento esportivo entre outras áreas da ciência. Para alguns casos, realizar a análise em tempo real não é importante, entretanto, em alguns casos é uma vantagem muito grande.

Este trabalho propôs realizar a segmentação e análise do movimento de sentar e levantar usando duas abordagens, uma abordagem *offline* e uma abordagem *online*. Para cumprir esse objetivo, utilizou-se de duas ferramentas centrais, o DTW responsável pela segmentação após a realização do movimento e o IMM que é capaz de realizar a segmentação em tempo real. Além disso, utilizou-se de um banco de dados que contém 21 movimentos diferentes para cada um dos 90 voluntários, dessa forma, foi necessário criar um código para facilitar o corte dos dados apenas para o movimento de sentar e levantar.

Os métodos propostos foram capazes de produzir dados temporais necessários para classificar e analisar o movimento de sentar e levantar e, apesar de algumas restrições do banco de dados, foi possível realizar as duas análises com sucesso. Para análise *offline*, observou-se um pior desempenho do algoritmo DTW para segmentar o movimento que foi realizado de forma menos padronizada, por exemplo, o início do movimento de sentar, quando o voluntário pode ou não fazer um ajuste no movimento para se ajustar à direção do assento, de forma que esse ajuste também não é padronizado. O algoritmo apresentou um melhor desempenho para a fase final do movimento de sentar, se aproximando muito dos valores obtidos manualmente, justamente por se tratar de uma fase mais padronizada dentro do banco de dados.

Para a análise *online*, assim como para a análise *offline*, observou-se um melhor desempenho do algoritmo IMM para segmentar o movimento mais padronizado, inclusive realizando uma segmentação bastante próxima da segmentação manual nesses casos. Por ser mais complexo, esse algoritmo permite uma liberdade maior de ajustes, de forma que, para aumentar a generalização, foi necessário abrir mão da precisão temporal da definição das fases do movimento, ocasionando em um atraso na detecção das transições do movimento. Porém, por se tratar de um método possui muitos parâmetros de ajuste e pelo tempo de conclusão do trabalho, o algoritmo pode ser melhor explorado, podendo-se investigar melhor a elaboração de modelos e o ajustes das matrizes para melhorar a precisão dos resultados.

Além do processamento *online*, uma das vantagens de se utilizar o IMM é que ele é capaz de detectar o objeto de interesse em uma sequência aleatória, ou seja, em tese, ele

pode ser usado para detectar o movimento de sentar e levantar em uma sequência indeterminada de movimentos. Como trabalhos futuros, podemos utilizar o IMM para realizar o monitoramento em tempo real da atividade de um paciente e a avaliação automática quando o movimento de sentar ou levantar for detectado, podendo fornecer um *feedback* em relação ao movimento quase que instantaneamente.

# Referências

ABERNETHY B., M. L. T. N. R. J. K. V.; HANRAHAN, S. J. *Biophysical foundations of human movement*. 1st. ed. [S.l.]: Macmillan, 1996. ISBN 0732930480 9780732930486 0732930472 9780732930479. Citado na página 19.

ALMASI, M. Human movement analysis from the egocentric camera view. In: . [s.n.], 2020. p. 1026–1031. Cited By 0. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85090853207&doi=10.1109%2fICESC48915.2020.9155757&partnerID=40&md5=a653e0146bf8fbaa30a2aa5fee376afb>>. Citado na página 19.

BAPTISTA, R. de S.; Bó, A. P. L.; HAYASHIBE, M. Automatic human movement assessment with switching linear dynamic system: Motion segmentation and motor performance. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 25, n. 6, p. 628–640, 2017. Citado 5 vezes nas páginas 28, 44, 45, 46 e 53.

BLOM, H. A. An efficient filter for abruptly changing systems. In: IEEE. *The 23rd IEEE Conference on Decision and Control*. [S.l.], 1984. p. 656–658. Citado na página 31.

BLOM, H. A.; BAR-SHALOM, Y. The interacting multiple model algorithm for systems with markovian switching coefficients. *IEEE transactions on Automatic Control*, IEEE, v. 33, n. 8, p. 780–783, 1988. Citado 2 vezes nas páginas 31 e 51.

BURDACK, J. et al. Systematic comparison of the influence of different data preprocessing methods on the performance of gait classifications using machine learning. *Frontiers in Bioengineering and Biotechnology*, v. 8, 2020. Cited By 0. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85083979185&doi=10.3389%2ffbioe.2020.00260&partnerID=40&md5=ff50049a2d4acf259c3b6842b3d1142d>>. Citado na página 19.

BUTTERWORTH, S. et al. On the theory of filter amplifiers. *Wireless Engineer*, v. 7, n. 6, p. 536–541, 1930. Citado na página 24.

CAI, S. et al. Real-time detection of compensatory patterns in patients with stroke to reduce compensation during robotic rehabilitation therapy. *IEEE Journal of Biomedical and Health Informatics*, v. 24, n. 9, p. 2630–2638, 2020. Cited By 0. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85077364375&doi=10.1109%2fJBHI.2019.2963365&partnerID=40&md5=b2204b2cadf1609f6eca8c3e1d39a1ec>>. Citado na página 20.

FRYKBERG, G.; HAGER, C. Movement analysis of sit-to-stand – research informing clinical practice. *Physical Therapy Reviews*, v. 20, p. 156–167, 05 2015. Citado 2 vezes nas páginas 41 e 51.

GALLI, M. et al. Quantitative analysis of sit to stand movement: experimental set-up definition and application to healthy and hemiplegic adults. *Gait & Posture*, Elsevier, v. 28, n. 1, p. 80–85, 2008. Citado na página 20.

- GHORBANI, S. et al. *MoVi: A Large Multipurpose Motion and Video Dataset*. Scholars Portal Dataverse, 2020. Disponível em: <<https://doi.org/10.5683/SP2/JRHDRN>>. Citado 7 vezes nas páginas 9, 22, 37, 40, 43, 44 e 57.
- HAYKIN, S.; MOHER, M. *Introdução aos sistemas de comunicação*. [S.l.]: Bookman Editora, 2009. Citado 2 vezes nas páginas 23 e 24.
- JULIER, S. J.; UHLMANN, J. K. New extension of the kalman filter to nonlinear systems. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Signal processing, sensor fusion, and target recognition VI*. [S.l.], 1997. v. 3068, p. 182–193. Citado na página 28.
- KALMAN, R. E. A new approach to linear filtering and prediction problems. 1960. Citado na página 28.
- KASHI, S. et al. A machine-learning model for automatic detection of movement compensations in stroke patients. *IEEE Transactions on Emerging Topics in Computing*, 2020. Cited By 0. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85085096942&doi=10.1109%2fTETC.2020.2988945&partnerID=40&md5=140af878f9ee33c8f705b9d98856c38e>>. Citado na página 20.
- KEOGH, E. J.; PAZZANI, M. J. Derivative dynamic time warping. In: SIAM. *Proceedings of the 2001 SIAM international conference on data mining*. [S.l.], 2001. p. 1–11. Citado 6 vezes nas páginas 26, 27, 46, 48, 49 e 50.
- KIM, D.; KIM, D.-H.; KWAK, K.-C. Classification of k-pop dance movements based on skeleton information obtained by a kinect sensor. *Sensors (Switzerland)*, v. 17, n. 6, 2017. Cited By 18. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85020449954&doi=10.3390%2fs17061261&partnerID=40&md5=0fae05b6b19012d6ab11babacee024bf>>. Citado na página 19.
- KRASOULIS, A.; VIJAYAKUMAR, S.; NAZARPOUR, K. Multi-grip classification-based prosthesis control with two emg-imu sensors. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 28, n. 2, p. 508–518, 2020. Cited By 3. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85080846724&doi=10.1109%2fTNSRE.2019.2959243&partnerID=40&md5=19c9a6d21179cd1f984891b5244383b9>>. Citado na página 19.
- LABBE, R. Kalman and bayesian filters in python. *Chap*, v. 7, p. 246, 2014. Citado 5 vezes nas páginas 9, 30, 31, 32 e 35.
- LATOUCHE, G.; RAMASWAMI, V. *Introduction to matrix analytic methods in stochastic modeling*. [S.l.]: SIAM, 1999. Citado na página 32.
- LI, J. et al. An integrated approach for robotic sit-to-stand assistance: Control framework design and human intention recognition. *Control Engineering Practice*, v. 107, 2021. Cited By 0. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85096670909&doi=10.1016%2fj.conengprac.2020.104680&partnerID=40&md5=f0499ea1ec213558a9de946818bac7a7>>. Citado na página 21.
- LI, J. et al. Human motion law based design and control for sit-to-stand assisting devices. In: . [s.n.], 2019. p. 150–153. Cited By 0. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85082125345&doi=10.1109%2fICCCE48422>>.

- [2019.9010763&partnerID=40&md5=4e748b931526eafc23b86229eb4a4226>](#). Citado na página 21.
- MARDIA, K. V.; JUPP, P. E. *Directional statistics*. [S.l.]: John Wiley & Sons, 2009. v. 494. Citado na página 45.
- MARTINEZ-HERNANDEZ, U.; DEHGhani-SANIJ, A. A. Probabilistic identification of sit-to-stand and stand-to-sit with a wearable sensor. *Pattern Recognition Letters*, v. 118, p. 32 – 41, 2019. ISSN 0167-8655. Cooperative and Social Robots: Understanding Human Activities and Intentions. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865518300990>>. Citado na página 21.
- MILLOR, N. et al. Kinematic parameters to evaluate functional performance of sit-to-stand and stand-to-sit transitions using motion sensor devices: a systematic review. *IEEE transactions on neural systems and rehabilitation engineering*, IEEE, v. 22, n. 5, p. 926–936, 2014. Citado na página 20.
- MUDA, L.; BEGAM, M.; ELAMVAZUTHI, I. Voice recognition algorithms using mel frequency cepstral coefficient (mfcc) and dynamic time warping (dtw) techniques. *arXiv preprint arXiv:1003.4083*, 2010. Citado na página 26.
- ODDING, E. et al. Determinants of locomotor disability in people aged 55 years and over: The rotterdam study. *European Journal of Epidemiology*, v. 17, p. 1033–1041, 2001. ISSN 1573-7284. Citado na página 21.
- P.C. HAJRA M., G. M. S. *Supervised Classification Algorithms in Machine Learning: A Survey and Review*. [S.l.]: pringer, Singapore, 2020. v. 937. ISSN 2194-5365. ISBN 978-981-13-7402-9 9978-981-13-7403-6. Citado na página 19.
- SALVADOR, S.; CHAN, P. Toward accurate dynamic time warping in linear time and space. *Intelligent Data Analysis*, IOS Press, v. 11, n. 5, p. 561–580, 2007. Citado 3 vezes nas páginas 9, 26 e 27.
- SCHENKMAN, M. et al. Whole-body movements during rising to standing from sitting. *Physical therapy*, v. 70 10, p. 638–48; discussion 648–51, 1990. Citado 7 vezes nas páginas 9, 40, 41, 42, 44, 45 e 51.
- SIDDIQUI, N.; CHAN, R. Multimodal hand gesture recognition using single imu and acoustic measurements at wrist. *PLoS ONE*, v. 15, n. 1, 2020. Cited By 3. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85077765701&doi=10.1371%2fjournal.pone.0227039&partnerID=40&md5=d9b1f545fa567266d8e08cf77ce59922>>. Citado na página 19.
- SILVA, P. F. d. S. et al. Trunk kinematics related to generation and transfer of the trunk flexor momentum are associated with sit-to-stand performance in chronic stroke survivors. *NeuroRehabilitation*, v. 40, n. 1, p. 57–67, 2017. ISSN 1878-6448. Citado na página 21.
- SUDA, E. et al. Recognition of foot-ankle movement patterns in long-distance runners with different experience levels using support vector machines. *Frontiers in Bioengineering and Biotechnology*, v. 8, 2020. Cited By 0. Disponível em: <[https://www.scopus.com/inward/record.uri?eid=2-s2.0-85087020208&doi=10.3389%](https://www.scopus.com/inward/record.uri?eid=2-s2.0-85087020208&doi=10.3389%2f)

2ffbioe.2020.00576&partnerID=40&md5=1862d1842f3e8676a7777f0e9b5af065>. Citado na página 19.

TCHUENTE, F.; BADDOUR, N.; LEMAIRE, E. Classification of aggressive movements using smartwatches. *Sensors (Switzerland)*, v. 20, n. 21, p. 1–12, 2020. Cited By 0. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85095815286&doi=10.3390%2fs20216377&partnerID=40&md5=b02835c907547a7b341bc24bb9352ee4>>. Citado na página 19.

TULLY, E. A.; FOTOHABADI, M. R.; GALEA, M. P. Sagittal spine and lower limb movement during sit-to-stand in healthy young subjects. *Gait & posture*, Elsevier, v. 22, n. 4, p. 338–345, 2005. Citado na página 21.

WENG, S.-K.; KUO, C.-M.; TU, S.-K. Video object tracking using adaptive kalman filter. *Journal of Visual Communication and Image Representation*, Elsevier, v. 17, n. 6, p. 1190–1208, 2006. Citado na página 28.

YOSHIKAWA, T.; LOSING, V.; DEMIRCAN, E. Machine learning for human movement understanding. *Advanced Robotics*, Taylor Francis, v. 34, n. 13, p. 828–844, 2020. Disponível em: <<https://doi.org/10.1080/01691864.2020.1786724>>. Citado na página 20.

ZHUO, S. et al. Real-time smartphone activity classification using inertial sensors—recognition of scrolling, typing, and watching videos while sitting or walking. *Sensors (Switzerland)*, v. 20, n. 3, 2020. Cited By 2. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85078688480&doi=10.3390%2fs20030655&partnerID=40&md5=52dd5a64cae8d1576babc19e3c2a4c7b>>. Citado na página 19.