

João Oscar Mesquita Silva Oda

**Classificação e agrupamento de atividades motoras a partir da sequência de ativações articulares monotônicas**

Brasil

2016



João Oscar Mesquita Silva Oda

**Classificação e agrupamento de atividades motoras a partir da sequência de ativações articulares monotônicas**

Dissertação de mestrado apresentada ao Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas para obtenção do título de mestre em engenharia Biomédica.

Universidade Federal do ABC – UFABC  
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas  
Programa de Pós-Graduação

Orientador: Marcos Duarte

Brasil  
2016



# Resumo

Atualmente os dispositivos de instrumentação biomecânica, sobretudo os sistemas de captura de movimento, são capazes de fornecer um grande número de dados. Seja para extrair informações para análise de diferenças entre grupos, para semi-automatização de procedimentos clínicos típicos de laboratórios de marcha ou para o desenvolvimento de sistemas inteligentes que fazem uso da informação do movimento, o reconhecimento de padrões de movimento é uma necessidade. Estes dados podem ser reduzidos a séries temporais, sendo assim estamos diante de um problema de mineração de dados de séries temporais. No entanto enquanto a maior parte das pesquisas se concentram em tarefas de mineração, o problema fundamental de como representar uma série temporal ainda não foi plenamente abordado até agora.

Este projeto objetiva estudar representações simbólicas para séries temporais provenientes de dados de captura de movimentos, uma abordagem ainda muito pouco explorada. Propondo a elaboração de um algoritmo que realiza o mapeamento entre um conjunto de séries temporais e uma sequência de símbolos, levando em consideração informações do domínio da biomecânica e controle motor.

Um conjunto de movimentos discretos foram convertidos em uma representação simbólica, a partir da qual foi realizado um agrupamento hierárquico e classificação em 10 atividades rotuladas, com uma exatidão de 84.72% e um padrão sequencial foi detectado no andar. Estes resultados foram obtidos em um tempo de processamento relativamente baixo e a partir de apenas 3 ângulos no plano sagital do membro inferior direito.

Com este trabalho atingimos o objetivo proposto e estabelecemos uma representação simbólica do movimento, denominada *palavras do movimento*, com boa parte das características almejadas. É uma representação simples e prática, a partir da qual foi possível estabelecer uma métrica que quantifica a similaridade entre movimentos.

**Palavras chave:** Análise do Movimento Humano, Cinesiologia, Biomecânica, Mineração de Dados, Reconhecimento de Padrões, Séries Temporais,



# Abstract

Currently biomechanical instrumentation devices, especially motion capture systems, are able to provide a large amount of data. Be it for extract information to compare differences among different groups, for semi-automation of typical clinical gait analysis procedures or for developing intelligent systems that make use of motion information, recognition of motion patterns is a need. These data can be reduced to time series, so we are facing a problem of mining time series data. However, while most of the research communities have concentrated on the mining tasks, the fundamental problem on how to represent a time series has not yet been fully addressed so far.

This project aims to study symbolic representation for time series data from motion capture, an approach still not much explored. The development of the algorithm that performs the mapping between a set of time series and a sequence of symbols, taking into account information from the field of biomechanics and motor control.

A set of discrete motions were converted to a symbolic representation, from which we performed a hierarchical clustering and classified in 10 labeled activities, with an accuracy of 84.72% and a sequential pattern was detected in gait. These results were obtained at a relatively low processing time and from only 3 angles in the sagittal plane of the right lower limb.

We achieved our objective and established a symbolic representation of the movement, called motion words, with most of it desired characteristics. It is a simple and practical representation, from which it was possible establish a metric that quantifies the similarity between movements.

**Keywords:** Human Motion Analysis, Kinesiology, Biomechanics, Data Mining, Pattern Recognition, Time Series



# Lista de ilustrações

Figura 1 – Sistema de captura tridimensional, óptico com marcadores. . . . .	20
Figura 2 – Sistema de captura de movimento, baseado em sensores inerciais(empresa Xsens) . . . . .	21
Figura 3 – Séries temporais dos ângulos articulares durante o ciclo do andar. . . . .	23
Figura 4 – Modelo antropométricos adotado . . . . .	24
Figura 5 – Processo para obter a representação simbólica de uma movimento . . . . .	32
Figura 6 – Exemplo de particionamento do intervalo do movimento em subintervalos, IAAM. . . . .	36
Figura 7 – Diagrama da lógica função <i>genIAAM</i> . . . . .	38
Figura 8 – Exemplo de símbolos associados aos IAAMs . . . . .	41
Figura 9 – Exemplo de séries temporais, palavras do movimento e distância de Levenshtein . . . . .	44
Figura 10 – Estrutura de um dendrograma . . . . .	46
Figura 11 – Exemplo de dendrograma ideal . . . . .	47
Figura 12 – Exemplo de sinais de duração diferente . . . . .	53
Figura 13 – Matriz de distâncias entre os sinais X e Y . . . . .	54
Figura 14 – Matriz D de custos acumulados calculados . . . . .	55
Figura 15 – Dendrograma para os movimentos <i>walk2StepsRstart</i> e <i>skier1RepsLstart</i> . . . . .	60
Figura 16 – Dendrograma para os movimentos <i>walk2StepsRstart</i> e <i>skier1RepsLstart</i> . . . . .	61
Figura 17 – Visão geral do dendrograma para os 10 movimentos . . . . .	63
Figura 18 – Visão geral do dendrograma para os 10 movimentos, utilizando 4 DOF . . . . .	64
Figura 19 – Visão geral do dendrograma para os 10 movimentos, a partir da distância MD-DTW, . . . . .	65
Figura 20 – Amostra do movimento <i>walk2StepsLstart</i> com destaque para o intervalo correspondente ao padrão recorrente $\langle 17, 16, 13 \rangle$ . . . . .	66
Figura 21 – Posições das pernas durante o clique da marcha . . . . .	69
Figura 22 – Parte superior do dendrograma para os 10 movimentos . . . . .	79
Figura 23 – Parte central do dendrograma para os 10 movimentos . . . . .	80
Figura 24 – Parte inferior do dendrograma para os 10 movimentos . . . . .	81
Figura 25 – Parte superior do dendrograma para os 10 movimentos . . . . .	82
Figura 26 – Parte central do dendrograma para os 10 movimentos . . . . .	83
Figura 27 – Parte inferior do dendrograma para os 10 movimentos . . . . .	84
Figura 28 – Parte superior do dendrograma para os 10 movimentos, a partir da distância MD-DTW . . . . .	85
Figura 29 – Parte central do dendrograma para os 10 movimentos, a partir da distância MD-DTW . . . . .	86

Figura 30 – Parte inferior do dendrograma para os 10 movimentos, a partir da  
distância MD-DTW . . . . . 87

# Lista de tabelas

Tabela 1 – Quantidade de atividades realizadas por cada um dos atores . . . . .	57
Tabela 2 – Exatidão por classes . . . . .	62



# Lista de abreviaturas e siglas

NWS	Non-Wearable System, sensores não-vestíveis
WS	Wearable System, sensores vestíveis
DOF	Degree of Freedom, grau de liberdade
IAAM	Intervalo de Ativação Articular Monotônica
SAAM	Sequência de Ativação Articular Monotônica
KNN	K-nearest neighbors, k-vizinhos mais próximos
DTW	Dynamic Time Warp
MD-DTW	Multidimensional Dynamic Time Warp
LOSOCV	Leave-one-subject-out Cross-validation



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>17</b>
	<b>Introdução</b>	<b>17</b>
<b>1.1</b>	<b>Porque estudar o movimento humano</b>	<b>17</b>
<b>1.2</b>	<b>Capturando e descrevendo o Movimento</b>	<b>18</b>
1.2.1	Descrevendo o Movimento por meio da linguagem natural	18
1.2.2	Sistemas de Captura de Movimento	19
1.2.2.0.1	Sensores não-vestíveis (Non-Wearable system NWS)	19
1.2.2.1	Sensores vestíveis (Wearable system WS)	20
1.2.3	Modelos	22
<b>1.3</b>	<b>Motivações</b>	<b>22</b>
<b>2</b>	<b>TRABALHOS RELACIONADOS</b>	<b>27</b>
<b>2.1</b>	<b>Técnicas analíticas em geral</b>	<b>27</b>
<b>2.2</b>	<b>Abordagens simbólicas para representação do movimento</b>	<b>28</b>
<b>3</b>	<b>PROPOSTA DE TRABALHO</b>	<b>31</b>
<b>3.1</b>	<b>Objetivo</b>	<b>31</b>
<b>3.2</b>	<b>Justificativa</b>	<b>31</b>
<b>3.3</b>	<b>Trabalho requerido</b>	<b>32</b>
<b>3.4</b>	<b>Fonte de dados</b>	<b>33</b>
<b>4</b>	<b>PALAVRAS DO MOVIMENTO</b>	<b>35</b>
<b>4.1</b>	<b>O que é uma palavra</b>	<b>35</b>
<b>4.2</b>	<b>Intervalos de ativação articular monotônica</b>	<b>35</b>
4.2.1	Detecção de picos e vales	36
4.2.2	Remoção de pontos correspondentes a variações de amplitudes muito pequenas em sequência	37
4.2.3	União dos pontos dos múltiplos sinais e simultaneidade	37
<b>4.3</b>	<b>Atribuindo símbolos aos IAAMs</b>	<b>39</b>
4.3.1	Os estados de um IAAM	39
4.3.2	Determinando o símbolo associado aos sinais presentes em um IAAM	39
4.3.3	Implementação e exemplo	39
<b>4.4</b>	<b>Parâmetros</b>	<b>40</b>
<b>4.5</b>	<b>Considerações sobre a representação simbólica adotada</b>	<b>41</b>
<b>5</b>	<b>O QUE PODE SER FEITO COM PALAVRAS DO MOVIMENTO</b>	<b>43</b>

<b>5.1</b>	<b>Similaridades entre movimentos</b>	<b>43</b>
5.1.1	Métricas e distâncias	43
5.1.2	Distância de Edição/Levenshtein	43
5.1.3	Implementação Utilizada e Exemplos	44
5.1.4	Matriz de distâncias	45
5.1.5	Considerações sobre nossa escolha de similaridade	45
<b>5.2</b>	<b>Agrupamento Hierárquico</b>	<b>45</b>
5.2.1	Construindo um Dendrograma	46
5.2.2	Aplicação Ideal	47
5.2.3	Implementação	47
<b>5.3</b>	<b>Classificação por meio dos k vizinhos mais próximos</b>	<b>47</b>
5.3.1	Aprendizado supervisionado	48
5.3.2	K vizinhos mais próximos KNN	48
5.3.3	Exatidão de um classificador	48
5.3.4	Validação cruzada de K-folds	48
5.3.5	Leave-one-subject-out Cross-validation	49
5.3.6	Aplicações	49
5.3.7	Implementação	49
<b>5.4</b>	<b>Padrões Sequenciais</b>	<b>49</b>
5.4.1	Notação e Exemplos	50
5.4.2	Subsequências	50
5.4.3	Exemplo de Mineração de Padrão Sequencial	50
5.4.4	Solução	51
5.4.5	Aplicações	51
<b>5.5</b>	<b>Métrica alternativa</b>	<b>52</b>
5.5.1	Dynamic time warp	52
5.5.2	Multi-Dimensional Dynamic time warp	55
5.5.2.1	O algoritmo	55
<b>6</b>	<b>EXPERIMENTOS COMPUTACIONAIS</b>	<b>57</b>
<b>6.1</b>	<b>Métodos e Procedimentos</b>	<b>57</b>
6.1.1	Dados	57
6.1.2	Pré-processamento	58
6.1.3	Limpeza dos Dados	58
6.1.4	Principais procedimentos	58
6.1.5	SO e Hardware Utilizados	59
<b>6.2</b>	<b>Resultados</b>	<b>59</b>
6.2.1	Caso Simples - 2 movimentos - palavras do movimento	59
6.2.2	Conjunto de 10 movimentos - 3DOF	59
6.2.3	Conjunto de 10 movimentos - 4DOF	59

6.2.4	Conjunto de 10 movimentos - MD-DTW . . . . .	62
6.2.5	Padrão sequencial - walk2StepsLstart . . . . .	62
<b>6.3</b>	<b>Discussão . . . . .</b>	<b>67</b>
6.3.1	Caso simples . . . . .	67
6.3.2	Conjunto de 10 movimentos - 3DOF . . . . .	67
6.3.3	Conjunto de 10 movimentos - 4DOF . . . . .	67
6.3.4	Conjunto de 10 movimentos - MD-DTW . . . . .	68
6.3.5	Padrão sequencial - walk2StepsLstart . . . . .	68
6.3.6	Considerações Gerais . . . . .	68
<b>7</b>	<b>CONCLUSÃO . . . . .</b>	<b>71</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>73</b>
	<b>APÊNDICES . . . . .</b>	<b>77</b>
	<b>APÊNDICE A – DENDOGRAMAS DETALHADOS . . . . .</b>	<b>79</b>



# 1 Introdução

## 1.1 Porque estudar o movimento humano

A capacidade de se movimentar é uma dádiva que os seres humanos compartilham com outros animais, uma vez que o movimento humano é resultado de uma complexa e altamente coordenada interação entre ossos, músculos, ligamentos e articulações, no âmbito do sistema músculo esquelético, sob o controle do sistema nervoso (WATKINS, 2010). O conhecimento, proveniente do estudo do movimento humano, possibilita prevenir, identificar, avaliar e corrigir disfunções do movimento (OATIS, 2009), sendo também possível aprimorar a técnica de movimento em funcionalidades específicas, obtendo um ganho de performance (BARTLETT, 2006).

Qualquer lesão de qualquer elemento individual do sistema musculoesquelético irá alterar a interação mecânica e causar degradação, instabilidade ou incapacidade de movimento. Por outro lado, modificações adequadas, manipulação e controle do ambiente mecânico podem ajudar a prevenir lesões, corrigir anomalias e acelerar os processos de cura e reabilitação (LU; CHANG, 2012).

Desta forma, alterações no movimento podem ser resultado de alterações tanto no sistema musculoesquelético quanto no sistema nervoso. Esta associação justifica o estudo e caracterização do movimento, tarefa da análise do movimento.

No escopo da biomecânica, a análise do movimento humano objetiva reunir informações quantitativas sobre a mecânica do sistema músculo-esquelético durante a execução de uma tarefa motora (CAPPOZZO et al., 2005). Deste ponto de vista é uma ferramenta útil na medicina, fisioterapia, ergonomia e ciência dos esportes. O tratamento de paralisia cerebral, acidente vascular cerebral, osteoartrite, diabetes mellitus e lesões da medula espinhal são patologias que podem se beneficiar da análise do movimento humano, sendo esta utilizada para avaliações clínicas, acompanhamento dos tratamentos e planejamento de intervenções. Temos ainda a área de reabilitação e tecnologia assistiva, além da ciência dos esportes onde a análise do movimento pode ser utilizada para aprimorar a performance dos atletas e identificar mecanismos de lesões. Veja (LU; CHANG, 2012) para uma breve revisão destas aplicações.

Uma das principais fontes de informações para a análise do movimento humano são os dados cinemáticos. Atualmente estes dados podem ser obtidos por meio de técnicas de captura de movimento. Podemos tomar como exemplo a marcha, uma das tarefas motoras mais estudadas nesta área. Por meio de sensores, dados de deslocamento, velocidade e aceleração de diversos pontos do corpo são obtidos enquanto o indivíduo se desloca.

Este trabalho tem por objetivo estabelecer uma representação simbólica do movimento humano a partir de séries temporais dos ângulos articulares, obtidos por meio de captura de movimento e explorar algumas possibilidades que esta representação proporciona.

Este trabalho está dividido da seguinte forma: O capítulo 2 aborda a questão da captura do movimento, descrevendo as principais tecnologias utilizadas e a representação por meio de séries temporais. O potencial dos dados, obtidos a partir do sistema de captura de movimento, o desafio de sua manipulação e extração de informações é abordado e discutido no capítulo 3. O capítulo 4 menciona técnicas existentes, utilizadas para extrair informações a partir destes dados e aplicações onde são utilizadas. O capítulo 5 apresenta nosso objetivo, sua justificativa e como pretendemos alcançá-lo. O capítulo 6 descreve nosso método para obter uma representação simbólica do movimento, denominada *Palavras do Movimento*. O capítulo 7 explica algumas possibilidades do que podemos fazer com esta representação. O capítulo 8 apresenta e discute experimentos computacionais com dados reais de captura de movimento, utilizando “Palavras do Movimento”. O capítulo 9 menciona diversos pontos que ainda podem ser trabalhados.

## 1.2 Capturando e descrevendo o Movimento

### 1.2.1 Descrevendo o Movimento por meio da linguagem natural

Um movimento pode ser descrito por meio de sequência de palavras, faladas ou escritas em um texto. Esta é a forma mais comum e que utilizamos no dia a dia para nos comunicar: “*João pulou*”. A essência da ação, porém é uma descrição subjetiva e carece de detalhes. Com o intuito de descrever melhor o movimento podemos enriquecer o texto:

*“João pulou, agachou e saltou verticalmente com ambas pernas, acompanhando o movimento de impulsão com os braços.”*

Os anatomistas possuem uma terminologia específica para descrever os movimentos, considerando o que acontece com uma determinada articulação em relação a planos/eixos de referência. Uma possível descrição, utilizando esta terminologia seria:

*“João saltou, partindo de uma posição com o quadril flexionado em 30 graus, abduzido de 15 graus e os joelhos flexionados em 90 graus. Estendeu seus joelhos abruptamente, de forma que ao sair do chão seu joelho se encontrava em flexão de 10 graus.”*

No entanto essa abordagem, onde se utiliza a linguagem natural para descrição de um movimento, não possui a riqueza de detalhes que podemos obter ao fotografar cenas da

ação, realizando este processo diversas vezes em um intervalo de tempo, estamos fazendo nada mais do que gravando um vídeo.

Além disso, existe muita redundância na descrição de um movimento por meio de linguagem natural, a quantidade de caracteres utilizados é excessiva, apesar de natural para um ser humano, iremos abordar neste trabalho uma representação simbólica que será na maior parte do tempo processada por computadores. Contexto onde uma representação concisa economiza memória e pode facilitar o processamento.

## 1.2.2 Sistemas de Captura de Movimento

Os sistemas de captura de movimento consistem de uma tecnologia que permite o registro de dados cinemáticos (posição, velocidade, aceleração ...) de pontos ao longo do corpo do indivíduo enquanto esse realiza um movimento. Estes dispositivos de captura de movimento podem ser classificados de acordo com duas abordagens: baseados em sensores não-vestíveis (Non-Wearable System - NWS) ou em sensores vestíveis (Wearable System - WS), sendo que para cada classe ainda temos variações de tecnologia, influenciando a precisão e conveniência da medida. A seguir descrevemos um pouco cada abordagem. Para maiores detalhes veja ([HERRAN](#); [GARCIA-ZAPIRAIN](#); [MENDEZ-ZORRILLA](#), 2014).

### 1.2.2.0.1 Sensores não-vestíveis (Non-Wearable system NWS)

A captura de movimento utilizando a abordagem NWS é usualmente conduzida por meio de câmeras de vídeo. Com apenas uma câmera, os registros são confinados em um plano único e pré-definido, o plano de movimento. Utilizando-se múltiplas câmeras é possível fazer uma reconstrução tridimensional possibilitando o estudo de movimentos espaciais, mais próximos da realidade. A figura 1.2.2.0.1 mostra um sistema de captura tridimensional, óptico com marcadores.

O vídeo em si, pode ser processado por meio de técnicas de visão computacional (realiza-se por exemplo a segmentação do contorno/silhueta do corpo por meio de software), algo que faz sentido no contexto de vigilância/segurança, quando se analisa por exemplo o reconhecimento de movimentos suspeitos que podem ser associados a um crime. Porém o cenário típico no contexto da biomecânica e análise do movimento é o estudo de um indivíduo que se dispõe a participar de um experimento/avaliação com o propósito de ter seu movimento capturado com detalhes suficientemente necessários. Para isso comumente faz-se o uso de marcadores fixados (usualmente nas protuberâncias ósseas) ao longo do corpo do sujeito para indicar a posição e orientação no espaço destes pontos. Esses marcadores podem ser passivos ou ativos. Os marcadores passivos são feitos de um material reflexivo e refletem a luz, destacando tais pontos na imagem. Os marcadores ativos emitem

Figura 1 – Sistema de captura tridimensional, óptico com marcadores.



Fonte: (MÜLLER et al., 2007)

luz, tipicamente por meio de LEDs, é possível que cada marcador pisque em uma frequência diferente facilitando o processo de distinção de diferentes marcadores.

Para propósitos clínicos como por exemplo a análise da marcha, a captura é conduzida em laboratórios ou ambientes controlados com as câmeras posicionadas em uma configuração apropriada. Em tais laboratórios costuma-se ter além do sistema de câmeras, outros instrumentos, tais como a plataforma de força, que fornece a força de reação do solo, utilizada para cálculos da cinética do movimento e dispositivos de eletromiografia, que medem sinais elétricos associados a ativação muscular.

Os métodos NWS são usualmente mais caros devido ao estabelecimento de um ambiente controlado onde se realiza a medida. No entanto, novos sistemas de baixo custo, portáteis e que não requerem marcadores estão ganhando popularidade. Um exemplo é o sensor Kinect da Microsoft (MENTIPLAY et al., 2015).

#### 1.2.2.1 Sensores vestíveis (Wearable system WS)

Em sua história, os sistemas de captura de movimento que utilizam sensores vestíveis já fizeram uso de dispositivos mecânicos atrelados ao corpo humano, semelhantes a goniômetros e que lembram um exoesqueleto. Porém atualmente os baseados em sensores inerciais são os vestíveis de maior popularidade e que possuem maior praticidade. Os sensores inerciais compreendem:

- Acelerômetros: capazes de registrar a aceleração linear ao longo de três eixos.
- Giroscópios: capazes de registrar a velocidade angular em torno de três eixos.

- Magnetômetros: capazes de registrar a orientação do dispositivo com relação ao eixo de rotação da terra. Na realidade estes sensores não são considerados inerciais, uma vez que não são baseados em propriedades inerciais, porém recentemente estão sendo disponibilizados juntamente com os sensores inerciais pois provem informações que facilitam os cálculos para se obter as variáveis cinemáticas.

A figura 1.2.2.1 mostra um sistema baseado em sensores inerciais.

Figura 2 – Sistema de captura de movimento, baseado em sensores inerciais(empresa Xsens)



Fonte: (HERRAN; GARCIA-ZAPIRAIN; MENDEZ-ZORRILLA, 2014)

Os sensores inerciais tem como vantagem a possibilidade de capturar movimentos em um ambiente fora dos laboratórios, mais próximos das tarefas do dia dia que o indivíduo executa. No entanto é possível que os sensores interfiram na execução de certos movimentos, pois geralmente possuem uma dimensão e massa superior aos marcadores utilizados nos sistemas baseados em câmeras de vídeos. Além disso para se obter as informações de deslocamento, a partir da velocidade e aceleração, é necessário utilizar um procedimento computacional de integração numérica que pode introduzir erros acumulativos nas medidas.

### 1.2.3 Modelos

Considerando que utilizamos um sistema de captura de movimentos, independente da tecnologia utilizada para captura, os dados de movimentos podem ser abstraídos em modelos mais gerais. Uma das formas mais utilizadas para descrever o movimento é descrevê-lo como um conjunto de séries temporais, mapeando as variações dos ângulos das articulações. Uma articulação pode possuir mais de um grau de liberdade, *degree of freedom* (DOF), correspondentes as rotações em diferentes planos. A figura 1.2.3 mostra as séries temporais dos ângulos articulares, correspondentes a rotação no plano sagital, durante o ciclo do andar. Para obter as séries temporais a partir dos deslocamentos dos marcadores capturados por um sistema de câmeras de vídeos, é necessário um modelo antropométrico do indivíduo. A figura 1.2.3 mostra um esqueleto construído a partir do modelo antropométrico de um indivíduo. As séries temporais correspondem a rotações relativas entre os sistemas de coordenadas locais, apresentados na articulação proximal de cada osso. A convenção de sistemas de coordenadas utilizados neste trabalho é a mesma que é apresentada nesta figura. Este modelo está associado ao formato de arquivo ASF/AMC utilizado na área de captura de movimento, desenvolvido pela produtora de jogos Acclaim. Com a saída do mercado da Acclaim em 2004, este formato foi descontinuado. No entanto existem diversas fontes online de dados que o utilizam, por exemplo o HDM05(MÜLLER et al., 2007) fonte de dados deste projeto.

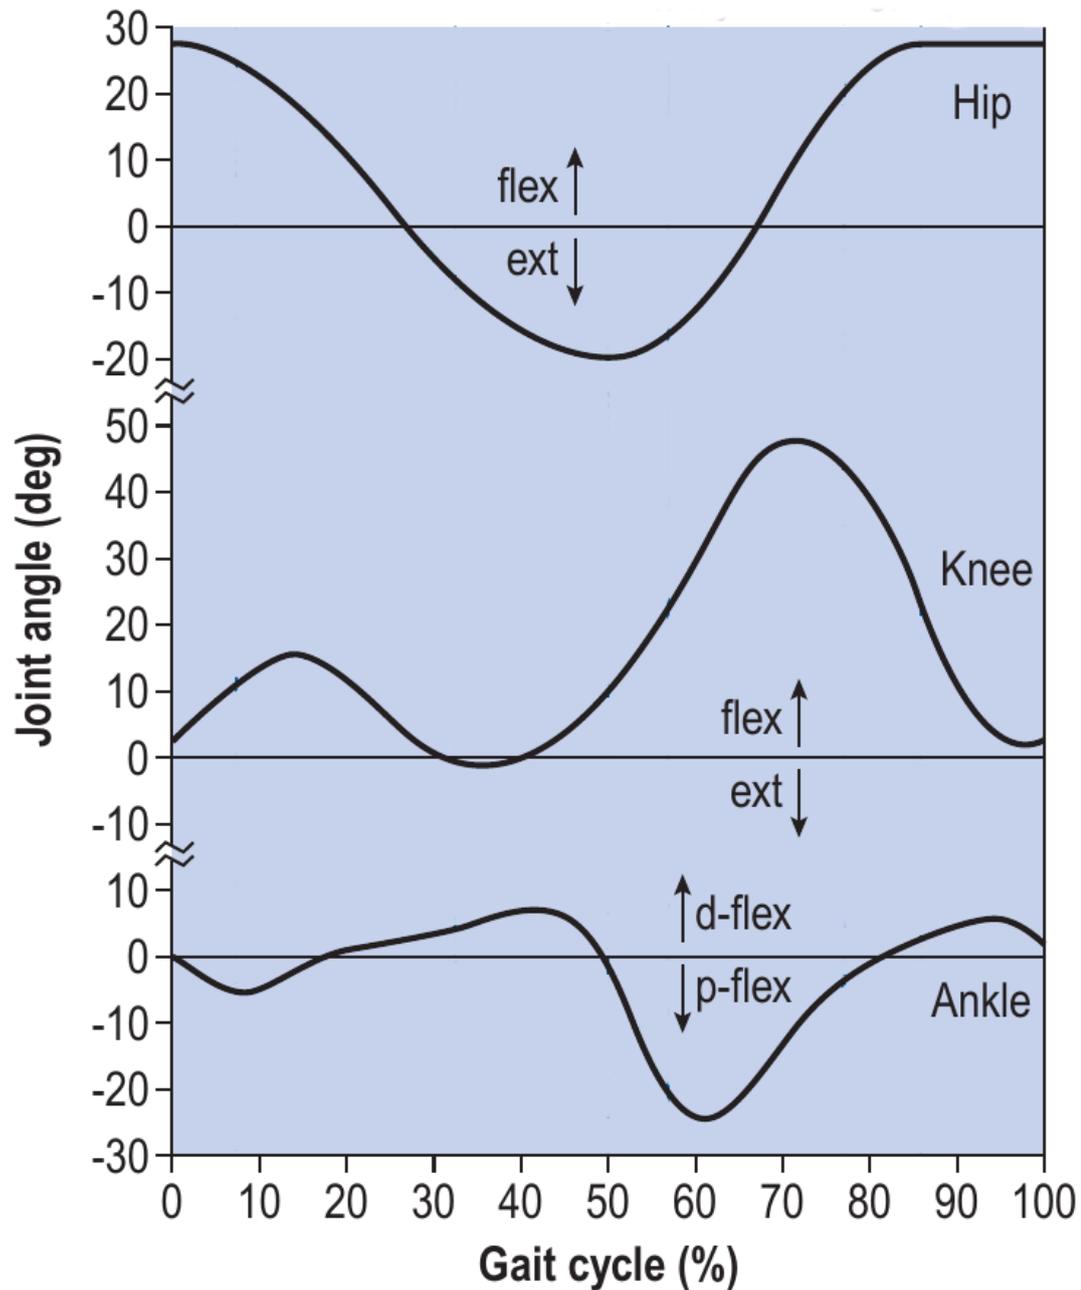
## 1.3 Motivações

Os sistemas de captura de movimento são capazes de fornecer um grande número de dados, acreditamos no potencial destes dados e que uma vez que os métodos de extração de informações a partir dos mesmos sejam aprimorados novas aplicações serão desenvolvidas.

Nos laboratórios de marcha, o desenvolvimento de um software de interpretação de marcha não só permitiria a rápida produção de uma interpretação preliminar e um relatório para o clínico revisar, mas também eliminaria muito da subjetividade presente nos relatórios de marcha atuais e permitiria o desenvolvimento de normas para interpretações dos dados de análise de marcha (SIMON, 2004). Para que isso seja possível, uma das necessidades é que os métodos analíticos aplicados aos dados de marcha sejam capazes de reconhecer padrões normais e anormais da marcha.

No contexto de atividades esportivas, tecnologias de computação ubíqua são aplicadas para implementar sistemas que fornecem informações ao atleta, como *feedback* sobre a qualidade do movimento que este acabou de realizar. A fim de dar automaticamente conselhos sobre como realizar os exercícios e / ou para ajustes do equipamento esportivo, dispositivos inteligentes são obrigatórios. Esses dispositivos têm como pré-requisito modelos para o reconhecimento e classificação de padrões do movimento realizado (ARNOLD,

Figura 3 – Séries temporais dos ângulos articulares durante o ciclo do andar.

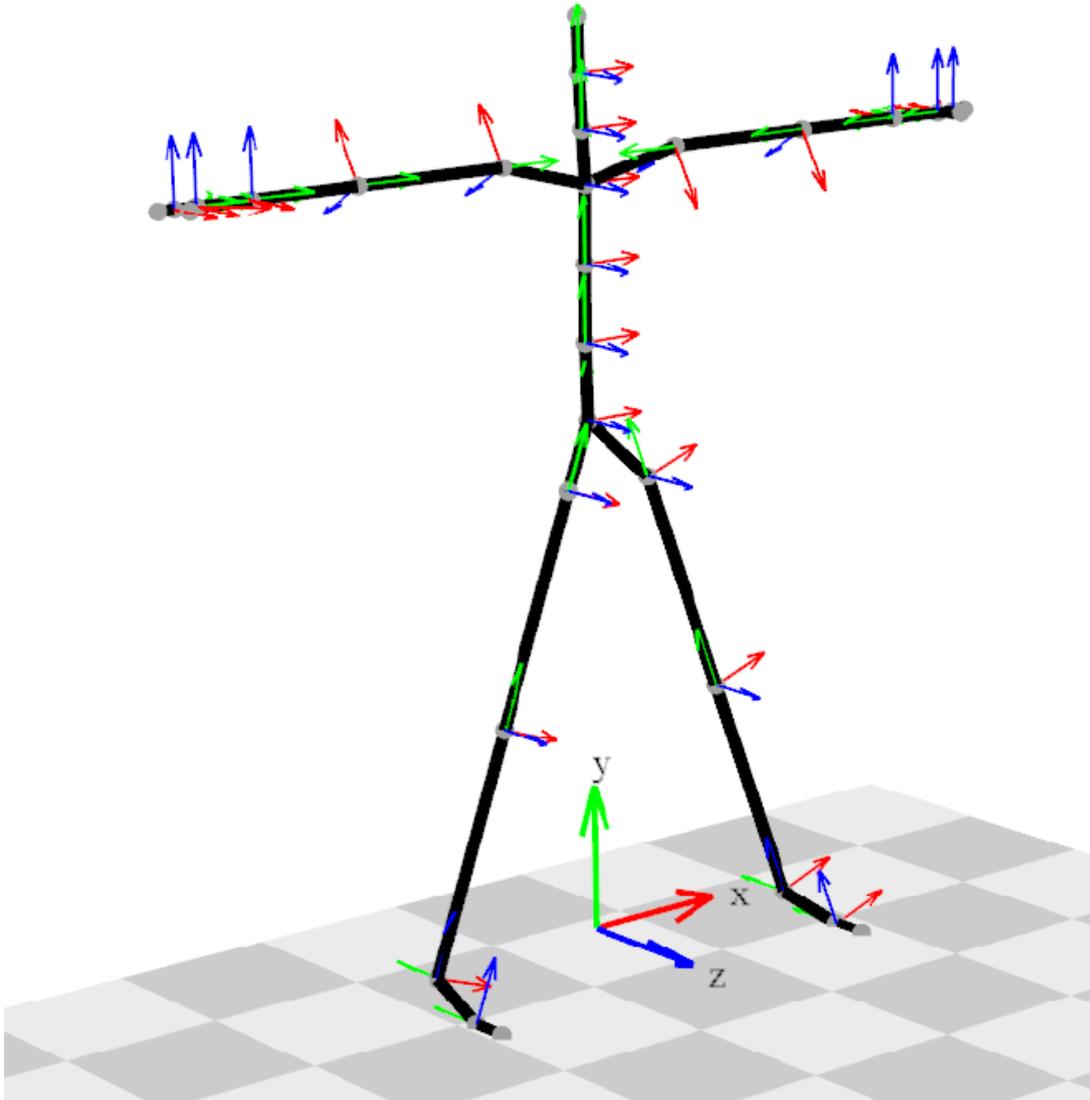


Tornozelo, joelho e quadril no plano sagital. Adaptado de: (WHITTLE, 2007)

2012).

De forma semelhante às atividades esportivas, sistemas inteligentes podem ser aplicados a exercícios de fisioterapia e fazer uso das informações de movimentos capturados por sensores, auxiliando no acompanhamento e supervisão dos exercícios. Em (BLESER et al., 2013), temos um exemplo de um sistema que auxilia idosos na execução de exercícios. Utilizando um sistema de captura de movimentos baseado em sensores inerciais, inicial-

Figura 4 – Modelo antropométricos adotado



Pose neutra de um esqueleto, obtido a partir de dados antropométricos do indivíduo. Os sistemas de coordenadas locais são exibidos em cada articulação proximal de cada osso. Os eixos seguem o código de cor: setas vermelho, verde e azul, para os eixos x, y e z respectivamente. Esta é convenção adotada neste trabalho. Fonte: (MüLLER et al., 2007)

mente com a supervisão de um especialista, o sistema constrói um modelo do movimento correspondente ao exercício ideal. Em um segundo momento este modelo é utilizado para supervisão e fornecimento de *feedback* dos exercícios aos idosos em suas casas.

Seja para extrair informações de um conjunto de dados para análise de diferenças entre grupos, para semi-automatização de procedimentos clínicos típicos de laboratórios de marcha ou para o desenvolvimento de sistemas inteligentes que fazem uso da informação

---

do movimento, o reconhecimento de padrões de movimento é uma necessidade. Como mencionado na seção 1.2.3, os dados de captura de movimento podem ser reduzidos a séries temporais, sendo assim estamos diante de um problema de mineração de dados de séries temporais, considerado um dos 10 desafios na área (YANG et al., 2006). No entanto, enquanto a maior parte das pesquisas se concentram em tarefas de mineração, o problema fundamental de como representar uma série temporal ainda não foi plenamente abordado até agora. Uma representação aproximada de uma série temporal é essencial, pois os dados em sua forma original são de difícil manipulação. A alta dimensionalidade das séries temporais dificulta a aplicação direta das técnicas de mineração de dados. Portanto, a definição de uma representação de séries temporais mais eficaz e eficiente é de fundamental importância(FU, 2011).



## 2 Trabalhos Relacionados

Este capítulo cita diversas técnicas analíticas utilizadas para extrair informações dos dados de análise do movimento. Neste documento não explicamos o funcionamento de cada uma delas, apenas mencionamos sua existência, contexto de aplicação e/ou ideia por trás e deixamos uma referência a ser consultada caso o leitor queira mais detalhes.

### 2.1 Técnicas analíticas em geral

Em termos gerais diversas técnicas analíticas tem sido aplicadas à análise do movimento. Inicialmente podemos mencionar agrupamento fuzzy, análise de componentes principais(PCA), análise de fatores(FA), análise de correspondência múltipla(MCA), “detrended fluctuation analysis”(DFA), “relative dispersion”(RD), redes neurais artificiais(arquitetura “feed forward”) e transformada wavelet(WT). Veja (CHAU, 2001a) e (CHAU, 2001b) para uma revisão destes métodos, aplicações na análise da marcha e suas limitações.

A técnica descrita em (PERL, 2004) consiste de uma rede neural com uma arquitetura diferente da “feed forward”, neste caso um SOM(self organization map) denominado rede DyCoN, que mapeia um espaço de dimensões maiores no plano. Assim o movimento é representado como uma trajetória em um mapa gerado pela rede, faz se necessário uma fase de treinamento para que a rede se auto-organize. Entradas semelhantes são mapeadas em regiões próximas, formando-se assim agrupamentos correspondentes a fases do movimento. Em (SCHMIDT, 2012) este método é utilizado para analisar os lances livres do basquetebol.

Em (PARK et al., 2005) tarefas orientadas a um alvo tem seu movimento analisado de forma que se obtém um vetor(JCV) com valores associados às contribuições de cada articulação para o movimento. Neste caso leva-se em consideração a influência que uma articulação tem na trajetória “efetiva”(na maioria das vezes. a trajetória da mão da pessoa). A ideia é estendida analisando-se as contribuições para a trajetória do centro de massa em (PARK et al., 2008), com o propósito de analisar o equilíbrio do indivíduo.

O movimento é considerado como uma série de posturas que variam ao longo do tempo, em (ADAMS; CERNEY, 2007). Sendo cada postura um conjunto de pontos de referência, cujas coordenadas são registradas e métodos de morfometria geométrica são utilizados para quantificar o movimento.

Uma aplicação onde um treinador virtual monitora um conjunto de movimentos de reabilitação para idosos, foi desenvolvida utilizando-se “Hidden Markov Models”(HMM)

(WEBER et al., 2011; WEBER et al., 2012; BLESER et al., 2013). Durante uma fase de treinamento, onde um especialista da área supervisiona a execução dos movimentos, modelos são construídos pelo sistema e futuramente utilizados para avaliar automaticamente a execução do movimento dos idosos. Em uma análise do sistema com 7 participantes, observou-se que nos casos em que o treinador de referência considerava a execução dos movimentos corretos, 81% foram também classificados como corretos pelo sistema, enquanto 19% foram classificados incorretamente. Destes 19%, 1% devido ao número de repetições, 6% devido a amplitude do movimento, 8% devido a desvios no eixo de rotação das articulações e 4% devido a fluidez do movimento (a matriz de confusão completa se encontra em (BLESER et al., 2013)).

Em (FUKUCHI et al., 2011), com base nos dados cinemáticos do membro inferior capturados, corredores foram classificados entre jovens e idosos. Utilizou-se a técnica de “Support Vector Machine”(SVM) para realizar a classificação e obteve-se uma exatidão de 100%(utilizando um algoritmo de seleção de características) para um grupo de 17 idosos e 17 adultos jovens.

## 2.2 Abordagens simbólicas para representação do movimento

Um particular sistema de notações para movimento denominado “Labanotation” tem suas origens no trabalho de Rudolf Laban e seus colegas que teve início em 1928, sendo possivelmente uma das mais antigas representações do movimento que obteve certa popularidade no meio acadêmico. O movimento é descrito em termos de modelos espaço-temporais, que por meio de um diagrama com símbolos específicos, descrevem as trajetórias das articulações e extremidades. Sua principal aplicação é no campo das artes cênicas, em particular a dança. Foi também utilizada como uma linguagem para geração de simulações de movimentos com uso do computador (BADLER; SMOLIAR, 1979). Entretanto possui limitações na precisão que representa o movimento, dificultando uma caracterização mais fina.

Uma linguagem visual-motora denominada HAL(Human Active Language) é apresentada em (GUERRA-FILHO; FERMULLER; ALOIMONOS, 2005; GUERRA-FILHO; ALOIMONOS, 2007) . Sua abordagem segue uma especificação linguística, onde temos: “kinetology”, morfologia e sintaxe. A “Kinetology” se encarrega em achar as primitivas básicas dos movimentos e associá-las com símbolos. Morfologia é relacionada à inferência gramatical das partes essenciais do movimento e sua estrutura. A sintaxe paralela se preocupa com conjuntos de “morphemes” representando ações simultâneas. A sintaxe sequencial é relacionada a concatenação de atividades.

Temos em (ZHANG; SAWCHUK, 2012) uma abordagem para reconhecimento de atividades utilizando o conceito de “Bag-of-Features”, onde modelos de atividades são

construídos utilizando histogramas para os símbolos associados a primitivas de movimento. Porém são utilizados apenas dados provenientes de um sensor inercial (6 graus de liberdade, acelerômetro e giroscópio), o que restringe o detalhamento das atividades.

Utilizando uma representação simbólica para séries temporais denominada “Symbolic Aggregate approximation”, o problema de reconhecimento de atividades foi abordado em (JUNEJO; AGHBARI, 2012). Porém no contexto de visão computacional, limitando-se a informações 2D do movimento, provenientes de vídeos ou projeções de capturas tridimensionais no plano.



## 3 Proposta de Trabalho

### 3.1 Objetivo

Este trabalho tem como objetivo estabelecer uma representação simbólica do movimento humano a partir das séries temporais provenientes dos ângulos articulares, de acordo com o contexto da biomecânica, bem como explorar algumas possibilidades que esta representação proporciona.

### 3.2 Justificativa

A representação simbólica é uma abordagem para representar séries temporais que permite a utilização de técnicas computacionais tais como: “hashing”, construção de árvores de sufixo, modelos de markov e a utilização de algoritmos/ideias das áreas de processamento de texto e bioinformática.

Na área de mineração de dados e aprendizado de máquina existe um ditado/teorema denominado “no free lunch theorem” (WOLPERT, 1996). Este, em sua essência, afirma que não existe um modelo ótimo que funcione para todos os problemas. Assim consideramos válido explorar as representações simbólicas de séries temporais provenientes de captura de movimentos, bem como tentar elaborar uma representação que considere em sua formulação características do domínio, em nosso caso a biomecânica e o controle motor.

Acreditamos que nossa proposta de representação do movimento e abordagem de análise fazendo uso da mesma, terá vantagens em certos aspectos quando comparada a outras técnicas analíticas, mencionadas no capítulo 2. Podemos mencionar algumas características almejadas:

- simplicidade
- praticidade
- capacidade de classificar diferentes atividades
- capacidade de identificar diferentes técnicas de execução de movimento na execução de uma atividade
- identificação de similaridades e diferenças entre movimentos, sendo capaz de fornecer um feedback sobre um movimento realizado e um desejado
- capacidade de lidar com movimentos discretos e cíclicos.

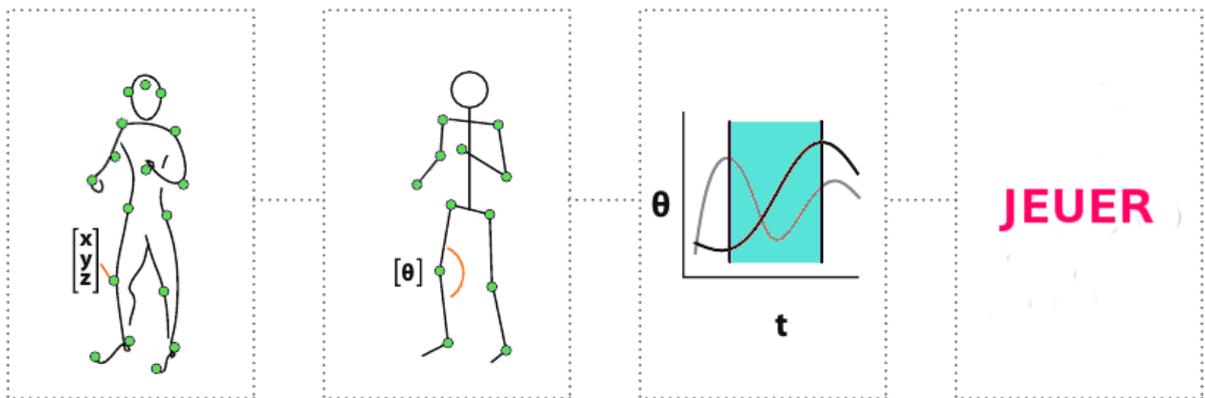
- uma técnica “white box” que permita uma interpretação e análise da tomada de decisão do algoritmo diferente de um sistema “black box” que somente lhe fornece uma resposta. Exemplo: uma rede neural artificial capaz de realizar uma classificação, que no entanto possui uma matriz de pesos sinápticos de difícil interpretação.

Os resultados a serem obtidos podem extrapolar o escopo tradicional da biomecânica e ter utilidade em outros campos, tais como: aplicações no desenvolvimento de robôs humanóides (KULIC et al., 2011), desenvolvimento de sistemas de interação homem-computador e animações geradas por computador. Não podemos deixar de mencionar que o próprio controle motor e o desafio de desvendar os detalhes do planejamento motor podem vir a se beneficiar deste trabalho.

### 3.3 Trabalho requerido

A figura 3.3 é um diagrama ilustrando o processo desde a captura do movimento até sua representação simbólica.

Figura 5 – Processo para obter a representação simbólica de uma movimento



O sistema de captura de movimento obtêm as coordenadas de pontos ao longo do corpo da pessoa, durante a execução do movimento, a partir destas são obtidos os ângulos das articulações que variam com o tempo, formando uma série temporal, esta pode ser representada por uma cadeia de símbolos. Nesta ilustração são utilizados caracteres do alfabeto para representar os símbolos.

Uma vez que temos a correspondência de um movimento para uma cadeia de símbolos, buscamos uma métrica de similaridade. A partir de uma métrica definida exploramos possibilidades, por exemplo aplicar algoritmos de aprendizado não supervisionado, para realizar um agrupamento (“Clustering”) das cadeias.

O capítulo 5 detalha o que podemos fazer a partir de nossa representação simbólica.

No entanto para que isto se concretize é necessário definir o método que constrói a sequência de símbolos a partir das séries temporais do movimento, isto inclui os intervalos de tempo correspondentes a cada símbolo e o alfabeto de símbolos. A elaboração do algoritmo que realiza o mapeamento entre um conjunto de séries temporais e uma sequência de símbolos, levando em consideração informações do domínio da biomecânica e controle motor, é a principal tarefa desta proposta.

## 3.4 Fonte de dados

A principal fonte de dados deste trabalho é uma base de dados disponível online, HDM05 ([MÜLLER et al., 2007](#)). Maiores detalhes dos dados, provenientes desta base, utilizados em nossos experimentos computacionais se encontram na seção [6.1.1](#).



## 4 Palavras do Movimento

Neste capítulo vamos descrever o procedimento para obter uma *palavra do movimento* a partir de um conjunto de séries temporais provenientes dos ângulos articulares. A implementação dos algoritmos mencionados neste capítulo foi realizada em Python e está disponível em [https://github.com/ojon/MotionMsc/blob/master/gen\\_motion\\_word.ipynb](https://github.com/ojon/MotionMsc/blob/master/gen_motion_word.ipynb)

### 4.1 O que é uma palavra

Em nosso contexto uma palavra é uma sequência de símbolos e um símbolo é um elemento de um conjunto denominado alfabeto. Dado um alfabeto  $\Sigma$ ,  $\Sigma^*$  é um conjunto de todas as palavras formadas por este alfabeto. Exemplo de alfabetos:

- alfabeto binário  $\Sigma = \{0, 1\}$   
 $\Sigma^* = \{0, 1, 00, 01, 10, 11, 000, \dots\}$
- alfabeto compreendido pelas bases nitrogenadas presentes no DNA.  
 $\Sigma = \{C, G, A, T\}$   
 $\Sigma^* = \{C, G, A, T, CC, CG, CA, CT, \dots\}$

Assim uma *palavra do movimento* será uma sequência de símbolos que irá descrever um movimento.

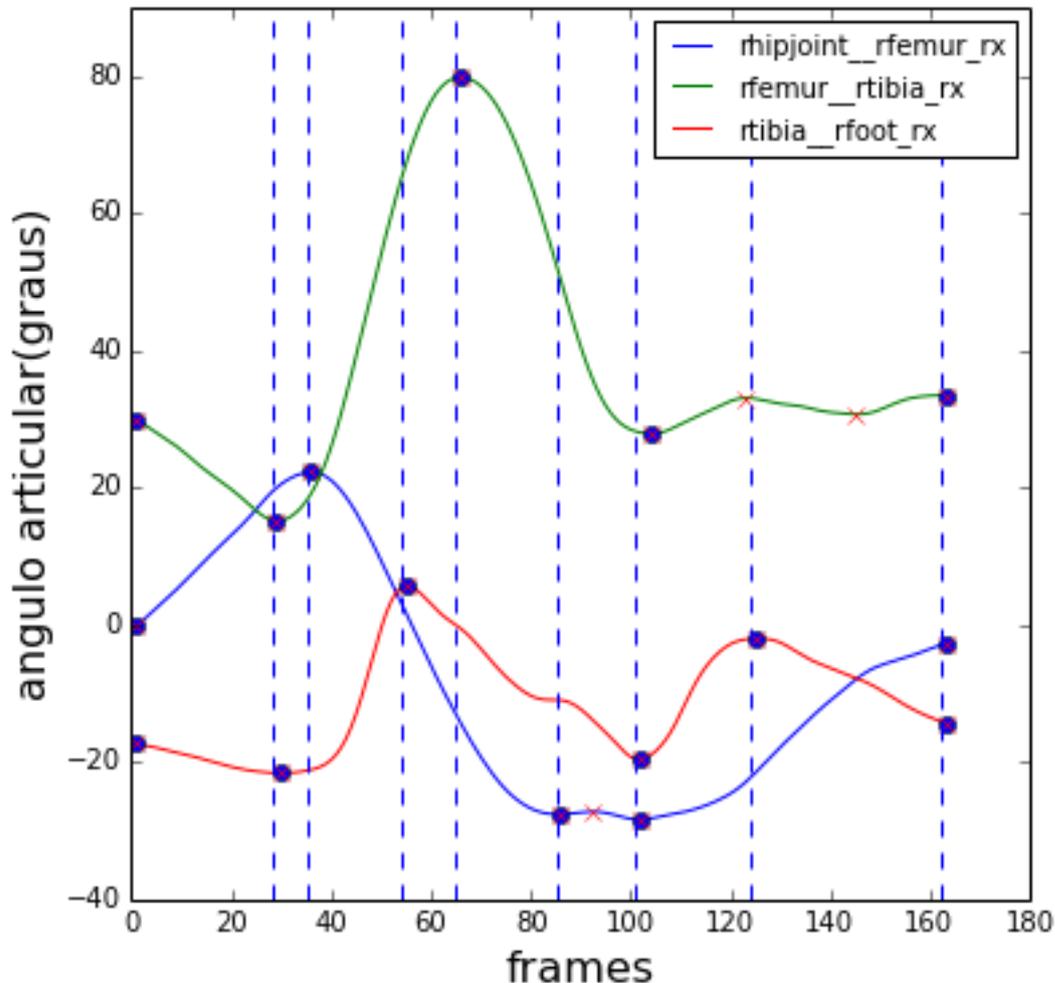
Em geral um alfabeto possui uma representação gráfica de seus símbolos, por meio de letras do alfabeto romano ou algarismo indo-arábicos. No entanto isso não será sempre o caso, o importante é que o alfabeto se trata de um conjunto enumerável, possuindo uma correspondência com números inteiros. Assim podemos abstrair sua representação gráfica quando necessário.

### 4.2 Intervalos de ativação articular monotônica

O primeiro passo para obter uma *palavra do movimento* é particionar o intervalo de tempo onde o movimento ocorre em subintervalos denominados intervalos de ativação articular monotônica (IAAM). A figura 4.2 apresenta um exemplo, para o movimento do andar. Sendo que idealmente em cada IAAM, temos que cada um dos sinais é crescente, decrescente ou constante. A função `gen_iaam()` realiza esta tarefa e um notebook com sua implementação está disponibilizado em <https://github.com/ojon/MotionMsc/blob/>

`master/gen_motion_word.ipynb`>. Um diagrama que descreve a lógica do algoritmo é apresentado na figura 4.2. As próximas subseções descrevem as etapas do processo.

Figura 6 – Exemplo de particionamento do intervalo do movimento em subintervalos, IAAM.



O pontos tracejados indicam instantes nos qual o intervalo foi particionado. O movimento consiste do andar(1 passada), e são observados os ângulos do quadril, joelho e tornozelo em torno do eixo x de acordo com a convenção da figura 1.2.3. As bolinhas azuis correspondem a máximos e mínimos locais que foram considerados, o  $x$  vermelho corresponde a um máximo ou mínimo que foi desconsiderado devido a uma diferença de amplitude superior a  $ampLimJoint$  em relação aos máximos e mínimos vizinhos.

#### 4.2.1 Detecção de picos e vales

Inicialmente detectamos os picos e vales de cada sinal. Para isso utilizamos a função `detect_peaks` (autor: Marcos Duarte). Um ipython-notebook com sua implementação está disponibilizado em [https://github.com/demotu/BMC/blob/master/functions/detect\\_peaks.py](https://github.com/demotu/BMC/blob/master/functions/detect_peaks.py)>. Esta função recebe como parâmetros extras  $mph$  e  $mpd$ , correspondentes a

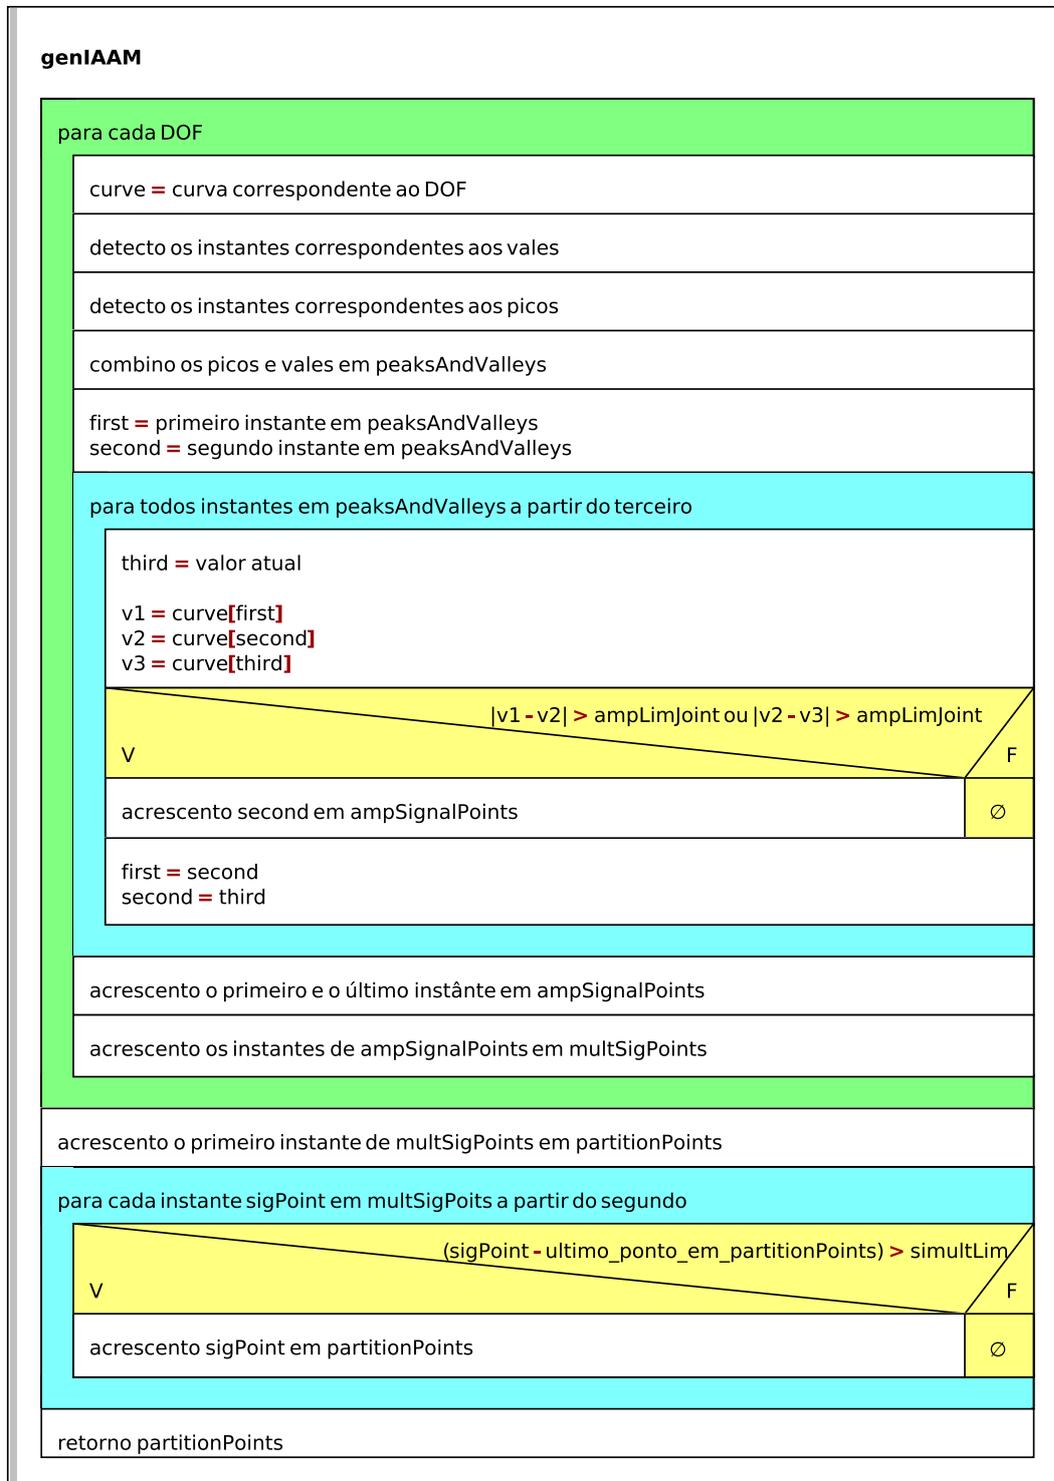
valores mínimos de altura e distância respectivamente dos pontos que são considerados picos ou vales. No entanto esta função é capaz de detectar apenas picos ou vales, mas não picos e vales simultaneamente. Assim os picos e vales são combinados no array *peaksAndValleys*.

#### 4.2.2 Remoção de pontos correspondentes a variações de amplitudes muito pequenas em sequência

De posse dos instantes onde ocorrem os picos e vales do sinal, percorremos estes instantes por meio de uma janela móvel de tamanho 3, sendo que o instante do meio é considerado e acrescentado à lista *ampSignalPoints* se seu valor correspondente tem uma diferença de amplitude superior ao parâmetro *ampLimJoint* em relação a pelo menos um dos seus valores vizinhos.

#### 4.2.3 União dos pontos dos múltiplos sinais e simultaneidade

Os procedimentos descritos nas seções 4.2.1 e 4.2.2 são realizados para cada grau de liberdade e o resultado unido no array *multSigPoints*. Pontos que ocorrem em instantes a menos de uma quantidade *simultLim* de frames de diferença são considerados simultâneos e somente o primeiro é considerado. O resultado final então se encontra no array *partitionPoints*.

Figura 7 – Diagrama da lógica função *genIAAM*

**entrada:** dados (uma coluna para cada DOF, uma linha para cada frame) *jointdofset*: uma lista com os labels dos DOF de interesse), *amplimjoint* (entre dois pontos de partição a diferença de amplitude é de pelo menos *amplimjoint*), *simult\_lim* (pontos que ocorrem em instantes a menos de 3 frames de diferença são considerados simultâneos e somente o primeiro é considerado) **saida:** índices dos pontos de partição do intervalo

## 4.3 Atribuindo símbolos aos IAAMs

Uma vez que temos a duração do movimento particionada em intervalos associamos um símbolo para cada intervalo.

### 4.3.1 Os estados de um IAAM

Consideramos que dentro de um IAAM, cada sinal pode se encontrar em um dos 3 estados: *crescente*, *decrecente* ou *estável*. Para determinar o estado de um sinal presente em um IAAM, calculamos a velocidade angular média no intervalo. Para o  $i$ -ésimo intervalo e sinal  $\theta$  temos:

$$\omega_i = \frac{\theta_i - \theta_{i-1}}{t_i - t_{i-1}} \quad (4.1)$$

Comparamos a magnitude de  $\omega_i$  com o parâmetro  $varLevel_i$ . Caso seja menor consideramos o estado *estável*. Caso seja maior e  $\omega_i$  de valor positivo, consideramos que se encontra em estado *crescente*. Caso seja maior e  $\omega_i$  de valor negativo, consideramos que se encontra em estado *decrecente*. Associamos um número inteiro a cada estado:

<i>crescente</i>	2
<i>decrecente</i>	1
<i>estável</i>	0

### 4.3.2 Determinando o símbolo associado aos sinais presentes em um IAAM

Sendo assim para um conjunto de  $N$  sinais, são possíveis  $3^N$  combinações de estados entre os sinais. Associamos a cada combinação um símbolo. Uma maneira de se obter um inteiro correspondente ao símbolo é por meio de uma representação em base 3:

$$WordInt = \sum_{i=1}^N s_i \times 3^i \quad (4.2)$$

Sendo  $s_i$  o inteiro correspondente ao estado do  $i$ -ésimo sinal presente no IAAM.

Para os experimentos computacionais que consideram apenas 3 DOF, assim temos um número de 27 combinações possíveis e podemos utilizar as 26 letras do alfabeto(maiúsculas) e o caractere '@' como nosso alfabeto.

### 4.3.3 Implementação e exemplo

A função *genMotionWordInt* obtêm uma *palavra do movimento* a partir das séries temporais dos ângulos articulares. Um notebook com sua implementação está

disponibilizado em [https://github.com/ojon/MotionMsc/blob/master/gen\\_motion\\_word.ipynb](https://github.com/ojon/MotionMsc/blob/master/gen_motion_word.ipynb).

A figura 4.3.3 mostra um exemplo, onde os intervalos IAAMs são apresentados e associados aos seus respectivos símbolos. A representação da *palavra do movimento* como uma sequência de números em base 3 obtida é::

211 220 122 121 111 011 222 201

Corresponde a sequência de inteiros:

22 24 17 16 13 4 26 19

E sua representação por meio letras do alfabeto romano:

VXQPM DZS

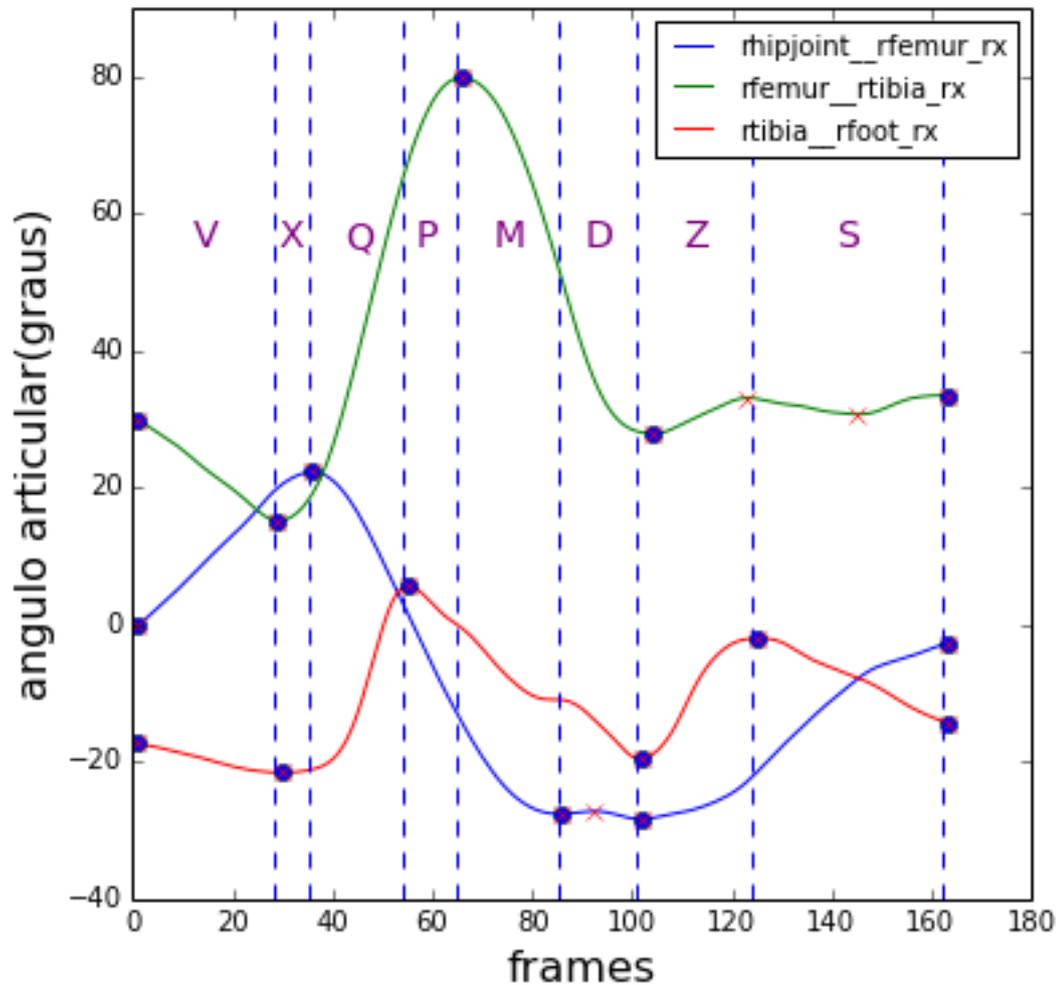
## 4.4 Parâmetros

Neste trabalho utilizamos os seguintes valores para os parâmetros:

- $mph = -180$
- $mpd = 5$
- $ampLimJoint = 5$
- $simultLim = 3$
- $varLevel_{hip} = 30$
- $varLevel_{knee} = 25$
- $varLevel_{ankle} = 10$

Do nosso ponto de vista os parâmetros não devem ser otimizados exaustivamente em busca de melhores resultados para os experimentos apresentados no capítulo 6, pelo menos não utilizando apenas os dados disponíveis atualmente. Pois isso pode levar a uma superespecialização (“overfitting”) dos dados. Consideramos que escolhas baseadas no domínio da aplicação fazem mais sentido.

Figura 8 – Exemplo de símbolos associados aos IAAMs



O pontos tracejados indicam instântes nos qual o intervalo foi particionado. O movimento consiste do andar(1 passada), e são observados os ângulos do quadril, joelho e tornozelo em torno do eixo x de acordo com a convenção da figura 1.2.3. As bolinhas azuis correspondem a máximos e mínimos locais que foram considerados, o  $x$  vermelho corresponde a um máximo ou mínimo que foi desconsiderado devido a uma diferença de amplitude superior a  $ampLimJoint$  em relação aos máximos e mínimos vizinhos.

## 4.5 Considerações sobre a representação simbólica adotada

Agora que o algoritmo que obtém uma *palavra do movimento* foi descrito, podemos refletir um pouco sobre esta representação. Dado um conjunto de séries temporais que representa o movimento podemos obter apenas uma *palavra do movimento*, mas a recíproca não é verdadeira, a partir de uma *palavra do movimento*, não podemos reconstruir o conjunto de séries temporais que a originou. Isso se deve ao fato de que as séries temporais possuem uma quantidade muito maior de informações do que uma “palavra do movimento”.

Tomando o exemplo apresentado na seção 4.3.3, originalmente temos 3 sinais de

aproximadamente 160 pontos cada, o que corresponde a um ponto em um espaço de  $3 \times 160 = 480$  dimensões.

Já a representação simbólica correspondente, uma *palavra do movimento* de 8 símbolos de um alfabeto de cardinalidade 27, nos fornece um número finito de  $8 \times 27 = 216$  possibilidades de movimento.

Por um momento podemos pensar que estamos “desperdiçando informação”, no entanto vale lembrar que o que buscamos é uma representação aproximada de uma série temporal, de menor dimensionalidade e que possa ser manipulada mais facilmente. Além disso, podemos pensar na *palavra do movimento* como uma representação que facilite a busca de informações em um primeiro momento, nada impede que após uma “triagem” utilizando *palavras do movimento* as séries temporais originais sejam consultadas.

Assim voltamos novamente para nossa representação simbólica, e nos perguntamos:

Qual informação estamos filtrando e colocando em evidência por meio de uma *palavra do movimento*?

Por meio de uma *palavra do movimento* nós informamos qual a *sequência de ativações articulares monotônicas*(SAAM) ao longo do movimento, o que nada mais é que a sequência dos estados dos IAAMs. Uma justificativa do ponto de vista biomecânico é o fato da SAAM por sua natureza estar relacionada com o acoplamento articular, coordenação do movimento entre articulações. O acoplamento articular é estudado, por exemplo, durante a corrida e alterações na sincronia das articulações durante o movimento podem resultar em lesões(LELEO et al., 2004).

Uma descrição em linguagem natural de um movimento que explicita a SAAM, seria algo semelhante a:

*“O movimento consiste de uma fase de abdução do ombro simultânea a extensão do cotovelo, seguida de uma fase de adução do ombro com o ângulo da articulação do cotovelo mantido constante.”*

O tempo de cada fase, a amplitude do movimento e diversas outras informações não são consideradas. A ideia foi começar com algo simples e essencial, mas nada impede que ocorram futuros refinamentos. No entanto consideramos a SAAM uma peça fundamental na coordenação do movimento e exploramos o potencial desta informação. Os capítulos 5 e 6 mostram que apenas com essa representação minimalista, pode-se obter alguns resultados interessantes.

## 5 O que pode ser feito com Palavras do Movimento

Neste capítulo exploramos algumas das possibilidades que a representação simbólica de um movimento nos proporciona.

### 5.1 Similaridades entre movimentos

#### 5.1.1 Métricas e distâncias

Inicialmente queremos comparar dois movimentos e dizer se estes movimentos são similares. Para isso definimos uma métrica, i.e. uma forma de medir a distância entre dois movimentos no espaço dos movimentos possíveis. De uma forma geral temos:

**Definição:** Sejam  $A$  e  $B$  dois objetos de um universo de possíveis objetos. A distância (dissimilaridade) entre  $A$  e  $B$  é um número real denotado por  $D(A,B)$

Uma métrica deve satisfazer as propriedades:

$D(A, B) = D(B, A)$	Simetria
$D(A, A) = 0$	Constância de Auto-simetria
$D(A, B) = 0 \iff A = B$	Positividade
$D(A, B) \leq D(A, C) + D(B, C)$	Desigualdade Triangular

Estamos interessados na distância entre dois movimentos representados por *palavras do movimento*, que em nosso caso são cadeias de caracteres, também conhecidas como *strings*. Convenientemente existe uma métrica entre strings conhecida, denominada distância de Levenshtein ([LEVENSHTEIN, 1966](#)), que iremos adotar e nos será útil.

#### 5.1.2 Distância de Edição/Levenshtein

Uma técnica geral para medir a similaridade entre dois objetos, consiste em quantificar o esforço necessário para transformar um dos objetos no outro. Essa é a ideia por trás da distância de Levenshtein, também conhecida como distância de edição.

É possível transformar qualquer string  $Q$  em uma string  $C$ , usando somente operações substituição, inserção e remoção de caracteres. Associamos a cada operação um custo de 1 por definição, assim temos:

**Definição:** A *distância de Levenshtein* entre duas strings,  $D(Q, C)$ , é definida como o menor custo para transformar Q em C, utilizando apenas operações de substituição, inserção e remoção.

### 5.1.3 Implementação Utilizada e Exemplos

Para calcular a *distância de Levenshtein* utilizamos o pacote python-Levenshtein (versão 0.12.0) cujo código fonte está disponível em <https://github.com/zane/python-Levenshtein>.

Esta biblioteca possui uma função que calcula a distância e também outra que nos fornece as operações que levam a transformação de uma string em outra.

A figura 5.1.3 mostra as séries temporais, correspondentes a dois movimentos e as *palavras do movimento* correspondentes:

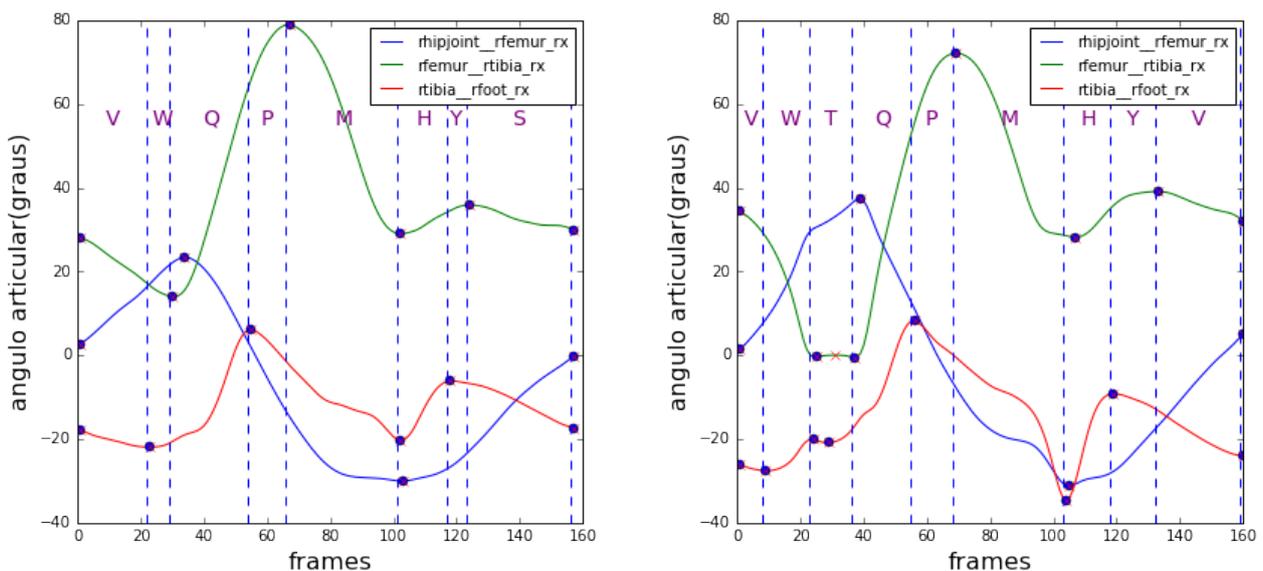
VWQPMHYS

VWTQPMHYV

A distância de Levenshtein entre elas é 2. Podemos obter VWTQPMHYV a partir de VWQPMHYS por meio das operações:

- insira o caracter T entre W e Q
- substitua o S na oit posição por Vava

Figura 9 – Exemplo de séries temporais, palavras do movimento e distância de Levenshtein



As séries temporais e as *palavra do movimento*, VWQPMHYS VWTQPMHYV, correspondentes a dois movimentos. A distância de Levenshtein entre elas é 2

Um ipython notebook com o código correspondente a este exemplo está disponível em [https://github.com/ojon/MotionMsc/blob/master/gen\\_motion\\_word.ipynb](https://github.com/ojon/MotionMsc/blob/master/gen_motion_word.ipynb).

#### 5.1.4 Matriz de distâncias

Para uso futuro no ambiente Matlab, a matriz de distâncias entre as amostras foi calculada e exportada como uma variável “distM” em um arquivo no formato binário .mat, em Python, a implementação está disponível em [https://github.com/ojon/MotionMsc/blob/master/gen\\_motion\\_word.ipynb](https://github.com/ojon/MotionMsc/blob/master/gen_motion_word.ipynb)

#### 5.1.5 Considerações sobre nossa escolha de similaridade

Com a métrica adotada e os recursos da biblioteca utilizada, temos não apenas a informação de que dois movimentos são diferentes, i.e. de diferentes classes, mas também o quanto são diferentes e quais suas diferenças (em termos de SAAMs), além disso a informação de como obter um movimento a partir de outro, pode ser útil para fornecer um biofeedback durante um processo de reabilitação ou treinamento esportivo. Uma característica desejada, por razões já mencionadas no capítulo 1.3.

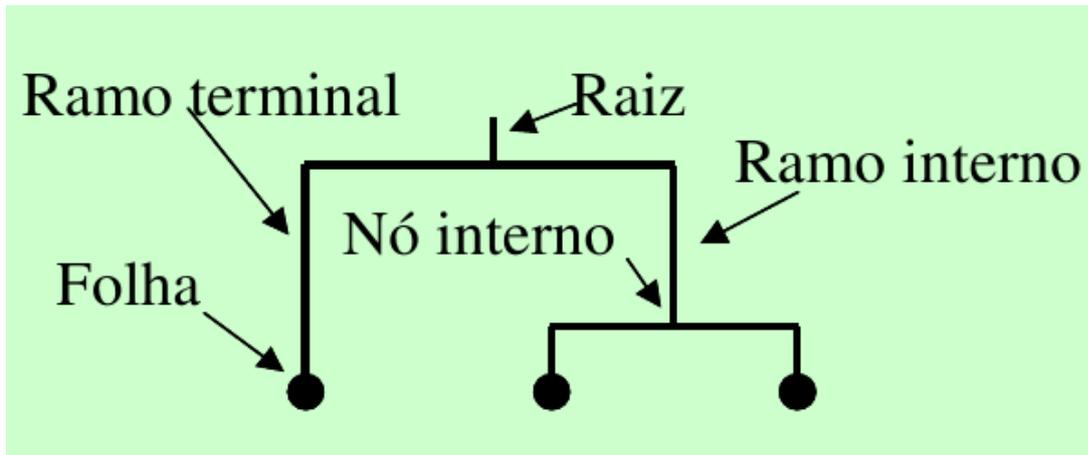
## 5.2 Agrupamento Hierárquico

O agrupamento é uma tarefa de aprendizado de máquina não supervisionado. Mesmo sem classes rotuladas a priori podemos extrair informações dos dados e dividir o conjunto de dados em “clusters”, subconjuntos que apresentem similaridades. Para isso faz-se necessário estabelecer uma métrica entre os objetos em questão, tarefa que já foi realizada na seção 5.1.2.

O agrupamento hierárquico estrutura os dados em uma hierarquia, esta pode ser melhor visualizada por meio de um diagrama denominado dendrograma. A figura 5.2 apresenta a estrutura de um dendrograma.

Em um dendrograma a geometria fornece informações além da topologia. A similaridade entre dois objetos em um dendrograma é representada pela altura do nó interno mais baixo que eles compartilham.

Figura 10 – Estrutura de um dendrograma



Estrutura de um dendrograma, semelhante a uma árvore binária. A similaridade entre dois objetos em um dendrograma é representada pela altura do nó interno mais baixo que eles compartilham.

### 5.2.1 Construindo um Dendrograma

Vamos descrever aqui a abordagem bottom-up para realizar um agrupamento hierárquico e a construção de seu dendrograma correspondente.

1. Começamos com cada item correspondendo a um *cluster*.
2. Encontramos o melhor par de *clusters* para aglomerar, i.e. aquele que possui a menor distância entre si.
3. Agrupamos este par e a partir de agora no lugar dos dois clusters correspondentes ao par, temos um novo *cluster* único correspondente ao par.
4. Repete-se o passo 2, até que todos os *clusters* tenham sido aglomerados.

No passo 2 mencionamos a distância entre dois *clusters*, porém até o momento somente estabelecemos uma métrica para dois objetos. Existem várias formas de se medir a distância de dois grupos, neste trabalho adotamos:

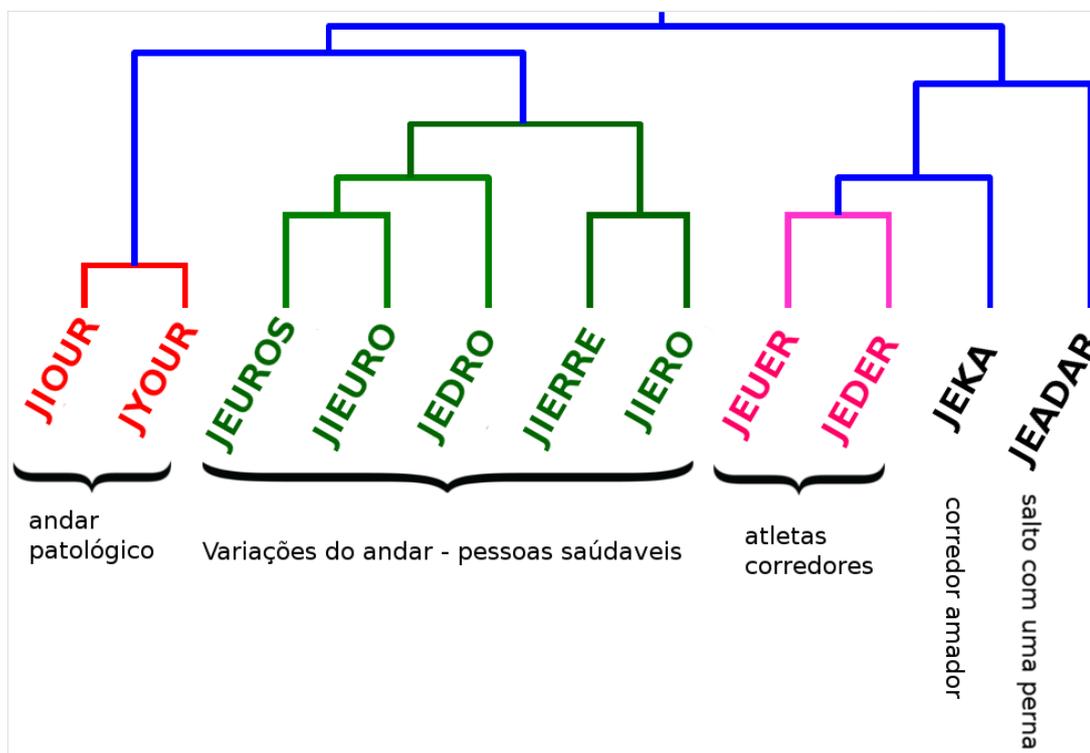
**Ligação média de grupos:** Neste método, a distância entre dois *clusters*  $r$  e  $s$ , de respectivamente  $n_r$  e  $n_s$  elementos, é calculada pela distância média entre todos os pares de objetos nos diferentes *clusters*:

$$d(r, s) = \frac{1}{n_r n_s} \sum_{i=1}^{n_r} \sum_{j=1}^{n_s} \text{dist}(x_{ri}, x_{sj}) \quad (5.1)$$

## 5.2.2 Aplicação Ideal

Em nosso contexto, no melhor cenário esperamos que o agrupamento hierárquico nos forneça um dendrograma semelhante ao apresentado na figura 5.2.2:

Figura 11 – Exemplo de dendrograma ideal



Os movimentos de diferentes classes são naturalmente agrupados de acordo com suas *palavras do movimento*. Este é um exemplo ilustrativo e não corresponde a dados reais.

Na seção 6.2 apresentamos resultados obtidos a partir de dados reais.

## 5.2.3 Implementação

A implementação do agrupamento hierárquico, foi realizada no Matlab, com o auxílio de funções do toolbox “Statistics and Machine Learning”. Utilizou-se a matriz de distância previamente calculada, como descrito na seção 5.1.4. O código fonte do script em matlab que realiza o agrupamento e desenha o dendrograma disponível em <https://github.com/ojon/MotionMsc/blob/master/hierarqClust.m>

## 5.3 Classificação por meio dos $k$ vizinhos mais próximos

Vamos passar por alguns conceitos de classificação e aprendizado supervisionado e ver que o que temos, i.e. uma representação do movimento atrelada a uma métrica, já é o suficiente para se fazer uso de uma destas ferramentas, possibilitando várias aplicações.

### 5.3.1 Aprendizado supervisionado

Na área de aprendizado de máquina, um classificador, que faz uso de aprendizado supervisionado, classifica as amostras que lhe são fornecidas baseadas em um conjunto de dados de exemplo ao qual foi previamente submetido. Os exemplos são pares compostos por uma amostra e o rótulo da classe a qual pertence, este conjunto de exemplos é também denominado conjunto de treinamento.

Neste trabalho fazemos o uso do classificador baseado no K vizinhos mais próximos (KNN), um classificador com base em aprendizado supervisionado, que faz uso de uma ideia simples e em sua essência somente necessita da definição de uma métrica entre as amostras.

### 5.3.2 K vizinhos mais próximos KNN

O KNN é um classificador que infere a classe da amostra que lhe é apresentada com base nas classes dos k exemplos mais próximos, segundo uma métrica (em nosso caso definida na seção 5.1.2). Uma “votação” ocorre entre os k exemplos mais próximos, a classe mais comum entre eles é atribuída a amostra, usualmente escolhemos um k como sendo um número ímpar para que não ocorra empate.

### 5.3.3 Exatidão de um classificador

Um classificador baseado em aprendizado de máquina é uma ferramenta estatística, i.e. nem sempre ele acerta a classe que atribuí a uma amostra. A taxa de acerto ou exatidão de um classificador é dada por:

$$\frac{\textit{acertos}}{\textit{acertos} + \textit{erros}} \quad (5.2)$$

### 5.3.4 Validação cruzada de K-folds

Dado um conjunto de amostras rotuladas, a validação cruzada de K-folds é uma metodologia para avaliar um algoritmo que faz uso de aprendizado supervisionado. Particionamos o conjunto de dados em k partes (subconjuntos disjuntos) de tamanhos iguais. O algoritmo é testado k vezes e a cada iteração deixa-se uma das k partes de fora da construção do classificador, a parte deixada de fora é utilizada para testar o classificador. O classificador não faz uso dos rótulos dos dados utilizados para testá-lo, sendo estes apenas utilizados no cálculo dos acertos que ele cometeu naquele teste.

### 5.3.5 Leave-one-subject-out Cross-validation

Leave-one-subject-out Cross-validation(LOSOCV) é uma metodologia alternativa de validação. A diferença é que neste caso ao treinarmos o classificador, excluimos amostras que pertencem ao mesmo indivíduo cuja a classe está sendo prevista.

### 5.3.6 Aplicações

Podemos utilizar um classificador para classificar movimentos, fazendo a distinção de diferentes grupos ou atividades, exemplos:

- Determinar se o andar é de um jovem ou idoso.
- Determinar se um movimento atlético é de um atleta amador ou profissional.
- Determinar se um movimento é de um indivíduo normal ou um indivíduo portador de uma patologia.
- Determinar a atividade (saltar, agachar, correr, arremessar) correspondente a um movimento.
- Determinar se uma técnica utilizada em um movimento está associada a um tipo de lesão.

Na seção 6.2 são apresentados resultados obtidos a partir de experimentos computacionais para classificação de atividades.

### 5.3.7 Implementação

A validação cruzada de K-folds do KNN foi implementada em Matlab, com o auxílio da função "crossvalind", do toolbox "Bioinformatics", para o particionamento do conjunto de dados. Devido a natureza da métrica, fez-se necessária uma implementação própria da avaliação do KNN, realizada a partir da matriz de distâncias previamente calculada e exportada, como descrito na seção 5.1.4. O código fonte do script em matlab está disponível em <<https://github.com/ojon/MotionMsc/blob/master/kNNxValid.m>>

## 5.4 Padrões Sequenciais

Uma *palavra do movimento* pode ser vista como uma seqüências de símbolos. Dado um conjunto de *palavra do movimento* podemos aplicar técnicas de mineração de seqüências para observar padrões recorrentes.

Primeiramente consideramos o problema de mineração de padrões sequenciais, introduzido por Agrawal e Srikant (AGRAWAL; SRIKANT, 1994):

Dado um conjunto de sequências, onde cada sequência consiste de uma lista de elementos e cada elemento consiste de um conjunto de itens, e dado um limiar de suporte-mínimo, mineração de padrões sequenciais é encontrar todas as subsequências frequentes, i.e., as subsequências cuja ocorrência no conjunto de sequências é maior que o suporte mínimo.

### 5.4.1 Notação e Exemplos

$\langle a(abc)(ac)d(cf) \rangle$  5 elementos, 9 itens

$\langle a(abc)(ac)d(cf) \rangle \neq \langle a(ac)(abc)d(cf) \rangle$

### 5.4.2 Subsequências

Dadas duas sequências  $\alpha = \langle a_1 a_2 \dots a_n \rangle$  e  $\beta = \langle b_1 b_2 \dots b_m \rangle$ :

$\alpha$  é denominada uma subsequência de  $\beta$ ,  $\alpha \subseteq \beta$ , se existe  $n$  inteiros  $1 \leq j_1 \leq j_2 \dots \leq j_n$  tais que  $a_1 \subseteq b_{j_1}, a_2 \subseteq b_{j_2}, \dots, a_n \subseteq b_{j_n}$

Exemplos:

$\beta = \langle a(abc)(ac)d(cf) \rangle$

$\alpha_1 = \langle aa(ac)d(e) \rangle \quad \alpha_1 \subseteq \beta$

$\alpha_2 = \langle (ac)(ac)d(cf) \rangle \quad \alpha_2 \subseteq \beta$

$\alpha_3 = \langle ac \rangle \quad \alpha_3 \subseteq \beta$

$\alpha_4 = \langle df(cf) \rangle \quad \alpha_4 \not\subseteq \beta$

$\alpha_5 = \langle (cf)d \rangle \quad \alpha_5 \not\subseteq \beta$

$\alpha_6 = \langle (abc)dcf \rangle \quad \alpha_6 \not\subseteq \beta$

### 5.4.3 Exemplo de Mineração de Padrão Sequencial

Dado o conjunto de sequências abaixo:

$\langle a(abc)(ac)d(cf) \rangle$

$\langle (ad)c(bc)(ae) \rangle$

$\langle (ef)(ab)(df)cb \rangle$

$\langle eg(af)cbc \rangle$

As subsequências com frequência maior ou igual ao  $min\_support = 2$  são:

$\langle a \rangle \langle aa \rangle \langle ab \rangle \langle a(bc) \rangle$

$\langle a(bc)a \rangle \langle aba \rangle \langle abc \rangle$   
 $\langle (ab) \rangle \langle (ab)c \rangle \langle (ab)d \rangle$   
 $\langle (ab)f \rangle \langle (ab)dc \rangle \langle ac \rangle$   
 $\langle aca \rangle \langle acb \rangle \langle acc \rangle \langle ad \rangle$   
 $\langle adc \rangle \langle af \rangle$   
 $\langle b \rangle \langle ba \rangle \langle bc \rangle \langle (bc) \rangle$   
 $\langle (bc)a \rangle \langle bd \rangle \langle bdc \rangle \langle bf \rangle$   
 $\langle c \rangle \langle ca \rangle \langle cb \rangle \langle cc \rangle$   
 $\langle d \rangle \langle db \rangle \langle dc \rangle \langle dcb \rangle$   
 $\langle e \rangle \langle ea \rangle \langle eab \rangle \langle eac \rangle$   
 $\langle each \rangle \langle eb \rangle \langle ebc \rangle \langle ec \rangle$   
 $\langle ecb \rangle \langle ef \rangle \langle efb \rangle \langle efc \rangle$   
 $\langle efc \rangle$   
 $\langle f \rangle \langle fb \rangle \langle fbc \rangle \langle fc \rangle \langle fcb \rangle$

#### 5.4.4 Solução

Para resolver o problema de mineração de sequências utilizamos o algoritmo PrefixSpan (PEI et al., 2001). A implementação utilizada esta disponível em [https://github.com/ojon/MotionMsc/blob/master/MotionSeqPattern\\_PrefixSpan.ipynb](https://github.com/ojon/MotionMsc/blob/master/MotionSeqPattern_PrefixSpan.ipynb)

#### 5.4.5 Aplicações

Contextualizando, em nosso caso temos listas de apenas um item correspondente a um símbolo da *palavra do movimento*. Dado um conjunto de movimentos que pertencem a uma classe estabelecida a priori, a busca por padrões recorrentes, é uma forma de obter uma caracterização objetiva da classe em questão, seja esta classe os movimentos correspondentes a uma atividade, movimentos de um grupo patológico, atletas etc ...

## 5.5 Métrica alternativa

O agrupamento hierárquico e classificação por meio dos  $K$  vizinhos mais próximos, necessitam de uma métrica, estabelecemos uma na seção 5.1.2, porém é possível utilizar uma métrica alternativa. O propósito é estabelecer um parâmetro de comparação para a distância de Levenshtein aplicada a representação simbólica proposta.

Uma métrica típica que é utilizada em muitas aplicações é a distância euclidiana. Porém em nosso caso os movimentos comparados não possuem necessariamente a mesma duração, o que resulta em séries temporais de tamanhos diferentes, impedindo sua comparação em sua forma original. Além disso, a distância euclidiana é suscetível a defasagens do sinal.

### 5.5.1 Dynamic time warp

Dynamic time warp (DTW) é uma técnica conhecida (MULLER, 2007) para encontrar o alinhamento ótimo entre duas sequências (que não necessariamente possuem o mesmo tamanho) com dependência temporal. É estabelecido um custo de alinhamento local entre todos os possíveis pares de elementos, sendo cada elemento proveniente de uma das sequências, resultando em uma matrix de custos. Um caminho por essa matrix, saindo do alinhamento dos primeiros elementos de cada sequência e chegando no alinhamento dos últimos elementos, respeitando a monotonicidade das sequências, corresponde a um alinhamento global das sequências. O custo desse alinhamento global é igual a soma dos custos de alinhamentos locais. O custo do caminho de menor custo para alinhar as sequências é a distância DTW entre as sequências. Vamos explicar a técnica com mais detalhes a partir de um exemplo.

Considere duas sequências  $X$  e  $Y$ , representadas na figura 5.5.1.

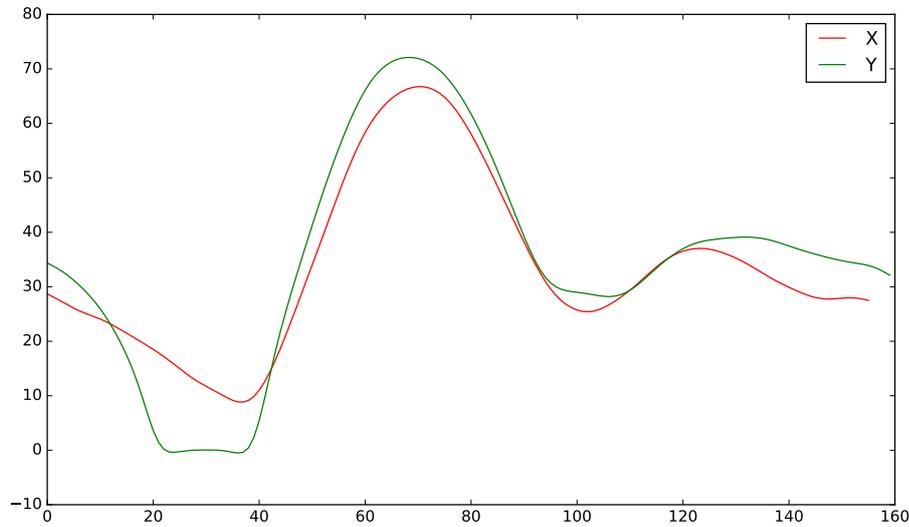
O custo de alinhamento local será igual a distância euclidiana dos pares de pontos, dessa forma temos uma matriz, representada na figura 5.5.1, cujos elementos satisfazem:

$$c(i, j) = (x_j - y_i)^2 \quad (5.3)$$

Para obter um alinhamento das duas sequências, precisamos criar um caminho na matriz representada na figura 5.5.1. O caminho deve começar em  $(0,0)$  e alcançar  $(M,N)$  onde  $M$  e  $N$  corresponde ao comprimento das sequências. Desejamos encontrar o caminho de menor custo, para isso construímos uma matriz  $D$  semelhante, porém de custos acumulados, que contém o menor custo para chegar a um ponto. Impomos algumas restrições que os caminhos devem satisfazer:

1. O caminho deve começar em  $(0,0)$

Figura 12 – Exemplo de sinais de duração diferente



Dois sinais X e Y correspondentes ao ângulo de flexão do joelho durante um movimento, apesar do movimento ser o mesmo, cada amostra é uma sequência de tamanho diferente

2. Não podemos “voltar no tempo”, o caminho sempre flui adiante, o que significa que a partir do ponto  $(i, j)$  somente podemos alcançar  $(i + 1, j)$  ou  $(i, j + 1)$  ou  $(i + 1, j + 1)$

Estas restrições permitem que o problema seja resolvido por meio de programação dinâmica, com uma complexidade computacional de  $O(MN)$ . A matriz D de custos acumulados satisfaz as identidades (teorema 4.3 em (MULLER, 2007)):

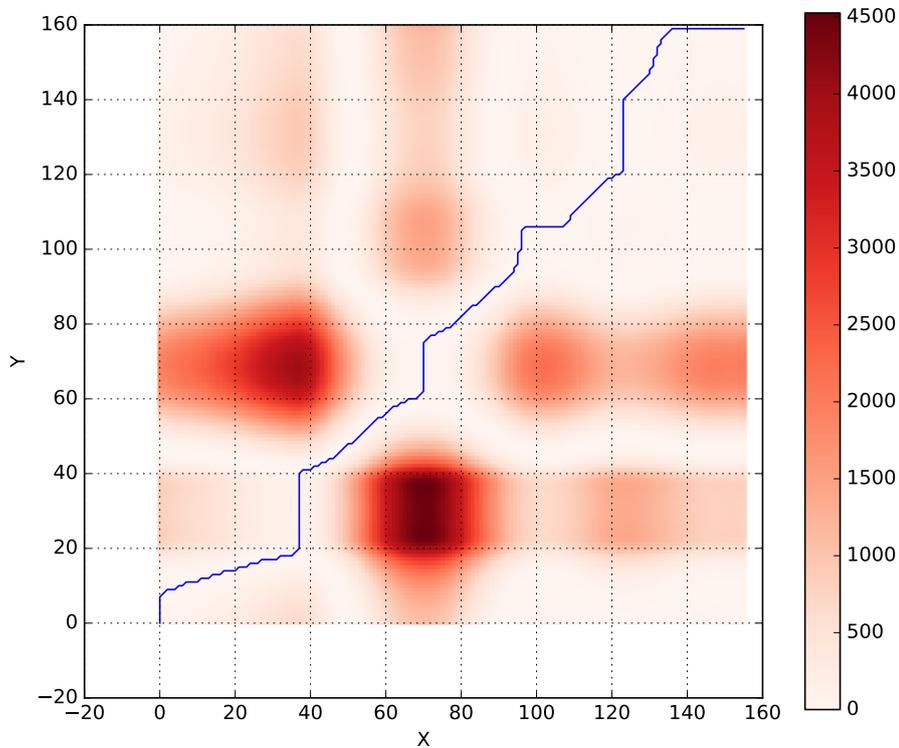
- $D(n, 1) = \sum_{k=1}^n c(x_k, y_1)$  para todo  $n \in [1 : N]$
- $D(1, m) = \sum_{k=1}^m c(x_1, y_k)$  para todo  $n \in [1 : M]$
- $D(n, m) = \min \{D(n - 1, m - 1), D(n - 1, m), D(n, m - 1)\} + c(x_k, y_k)$

A figura 5.5.1 apresenta a matriz de custos acumulados correspondentes ao exemplo em questão.

Para obter o caminho de menor custo realiza-se então “backtracking”, que consiste em a partir do ponto  $(M, N)$  determinar o ponto anterior do caminho, minimizando os custos. Assim a partir do ponto  $p_l = (m, n)$  determinamos:

$$p_{l-1} = \begin{cases} (1, n - 1) & \text{se } m = 1 \\ (m - 1, 1) & \text{se } n = 1 \\ \operatorname{argmin}\{D(m - 1, n), D(m, n - 1), D(m - 1, n - 1)\} & \text{demais casos} \end{cases}$$

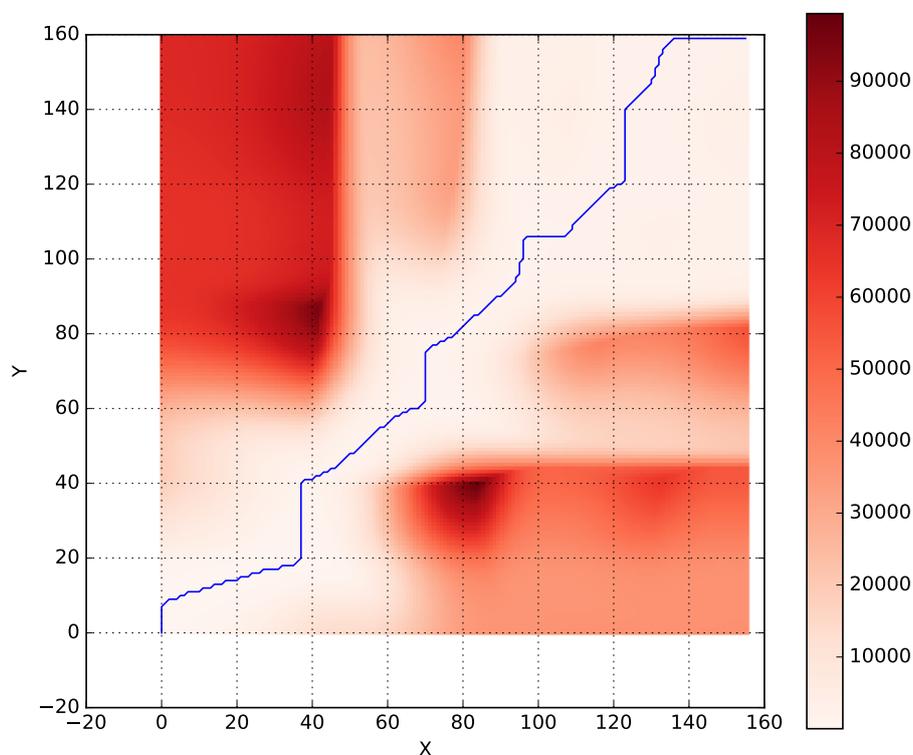
Figura 13 – Matriz de distâncias entre os sinais X e Y



A distância é calculada de acordo com a equação  $c(i, j) = (x_j - y_i)^2$  e representada por uma escala de cores indicada à direita da figura. Em azul temos o caminho correspondente a um alinhamento de menor custo.

No entanto esta técnica se aplica a um par de sequências, em nosso caso lidamos com um número maior de sequências, sendo cada uma correspondente a um DOF de uma articulação.

Figura 14 – Matriz D de custos acumulados calculados



De acordo com a identidade apresentada na seção 5.5.1, os valores dos custos acumulados são representados por uma escala de cores indicada a direita da figura. Em azul temos o caminho correspondente a um alinhamento de menor custo.

## 5.5.2 Multi-Dimensional Dynamic time warp

Multi-dimensional dynamic time warp (MD-DTW) é uma extensão da técnica DTW para lidar com séries temporais multidimensionais (HOLT; REINDERS; HENDRIKS, 2007).

### 5.5.2.1 O algoritmo

Consideremos duas séries temporais multidimensionais ( $K$  dimensões)  $A$  e  $B$ , representadas na forma de matrizes, onde as linhas correspondentes aos instantes temporais e colunas às dimensões.

Inicialmente normalizamos cada dimensão de  $A$  e  $B$ , de forma a se obter média 0 e variância 1.

Um elemento da matriz de custos entre as instâncias temporais é obtido de acordo

com:

$$D(i, j) = \sum_{k=1}^K |A(i, k) - B(j, k)| \quad (5.4)$$

A partir desta matriz, encontra-se um alinhamento de forma semelhante ao DTW clássico. Este algoritmo foi implementado para ser utilizado como métrica alternativa, o código fonte se encontra disponível em h. <[https://github.com/ojon/MotionMsc/blob/master/MD\\_DTW.ipynb](https://github.com/ojon/MotionMsc/blob/master/MD_DTW.ipynb)>

## 6 Experimentos computacionais

No capítulo 4 apresentamos uma representação simbólica do movimento. No capítulo 5 vimos algumas possibilidades do que pode ser feito a partir desta representação. Neste capítulo seguimos uma abordagem prática e apresentamos alguns experimentos computacionais e seus resultados.

### 6.1 Métodos e Procedimentos

#### 6.1.1 Dados

Neste trabalho utilizamos dados de captura de movimento obtidos a partir de um sistema óptico com marcadores, Vicon MX. Os indivíduos utilizaram uma roupa com cerca de 40-50 marcadores, que foram rastreados por 12 câmeras de alta resolução, seis operando na faixa do vermelho visível e 6 operando no infravermelho. Todas capturas ocorreram com uma amostragem de 120Hz. As câmeras foram dispostas para compreenderem um volume de diâmetro em torno de 5 metros.

Um grupo de 5 atores (**bd**, **bk**, **dg**, **mm** e **tr**) realizaram movimentos discretos (no contexto da biomecânica refere-se a movimentos que apresentam instantes de início e término bem definidos), atribuídos a 10 classes de atividades rotuladas. A tabela 1 apresenta a quantidade de atividades realizadas por cada ator.

Tabela 1 – Quantidade de atividades realizadas por cada um dos atores

Rótulo da classe	quantidade de amostras	Atores				
		tr	bk	mm	bd	dg
elbowToKnee1RepsLelbowStart	27	7	6	2	6	6
jogOnPlaceStartAir2StepsLStart	14	3	3	3	3	2
shuffle2StepsRStart	16	3	0	3	3	4
sitDownKneelTieShoes	14	0	6	2	3	3
sitDownTable	20	2	6	4	4	4
skier1RepsLstart	30	0	8	4	9	9
squat1Reps	32	12	4	4	8	4
standUpSitChair	20	2	6	4	4	4
walk2StepsRstart	31	5	6	6	6	8
walkBackwards2StepsRstart	15	2	3	3	3	4
Número total	219					

Atores: **bd**, **bk**, **dg**, **mm** e **tr**.

Todos os dados foram provenientes da base HDM05 disponível publicamente na internet, para maiores informações consulte o relatório técnico (MÜLLER et al., 2007).

### 6.1.2 Pré-processamento

As curvas dos ângulos articulares foram filtradas utilizando-se um filtro butterworth passa baixa de segunda ordem, com a frequência de corte ótima determinada por meio de análise de resíduos. A implementação desta etapa foi realizada por meio de scripts em Python, utilizou-se a biblioteca *scipy* para realizar a filtragem e para determinar a função de corte ótima, a função *residual \_ analysis* (autor: Marcos Duarte). Para maiores informações sobre análise de resíduos e a implementação da função *residual \_ analysis*, um Ipython Notebook está disponível em <<https://github.com/demotu/BMC/blob/master/notebooks/ResidualAnalysis.ipynb>>. Os dados filtrados são salvos no formato binário .npy, permitindo acesso mais rápido posteriormente. O Script utilizado para filtrar e salvar os dados está disponível em <<https://github.com/ojon/MotionMsc/blob/master/DataFilter.ipynb>>.

### 6.1.3 Limpeza dos Dados

Foi realizado um procedimento automatizado de limpeza dos dados, que exclui amostras com valores discrepantes. De acordo com a posição neutra do esqueleto (figura 1.2.3), onde todos os ângulos assumem valor nulo, ângulos com magnitude superior a  $180^\circ$  ou uma variação de magnitude superior a  $10^\circ$  entre dois frames consecutivos (corresponde a uma velocidade angular de  $1200^\circ/s$ ) durante a execução de um movimento, foram os critérios utilizados para desconsiderar amostras.

### 6.1.4 Principais procedimentos

As curvas dos ângulos articulares foram transformadas em *palavras do movimentos*, de acordo com a metodologia descrita no capítulo 4. Um agrupamento hierárquico, como descrito na seção 5.2 foi realizado. As atividades também foram classificadas por meio dos  $k=3$  vizinhos mais próximos, como descrito na seção 5.3.

Inicialmente os procedimentos foram aplicados a um caso simples de 2 atividades, *walk2StepsRstart* e *skier1RepsLstart*. Posteriormente todas as 10 atividades foram utilizadas, considerando 3 DOFs (articulações do membro inferior direito, as rotações quadril, joelho e tornozelo no plano sagital) e 4DOFs (os mesmos 3 DOFs com o acrescimo da flexão e extensão do ombro no plano sagital).

O agrupamento e classificação também foram realizados utilizando-se a distância MD-DTW (seção 5.5.2) como métrica alternativa para comparação.

O tempo de processamento utilizado para gerar a matriz de distâncias foi registrado por meio do comando *time* disponível nos sistemas UNIX .

As palavras de movimento correspondentes a um movimento *walk2StepsLstart* foram submetidas a mineração de padrões sequenciais, como descrito na seção 5.4. Um

suporte mínimo de 90% foi estabelecido.

### 6.1.5 SO e Hardware Utilizados

Os cálculos das matrizes de distância e a mineração de padrões sequenciais, foram executadas no ambiente Linux (kernel:4.2.0-23-generic x86\_64, dist:Ubuntu 15.10). Uma descrição do Hardware utilizado para o processamento se encontra em <[https://github.com/ojon/MotionMsc/blob/master/hardware\\_used\\_desc.txt](https://github.com/ojon/MotionMsc/blob/master/hardware_used_desc.txt)>.

## 6.2 Resultados

Os resultados dos agrupamentos hierárquicos podem ser visualizados na forma de dendrogramas como mencionado na seção 5.2. Clusters específicos foram coloridos manualmente nas figuras para facilitar a discussão. Neste capítulo uma visão geral dos dendrograma é apresentada, estes com maiores detalhes estão disponíveis no apêndice A.

### 6.2.1 Caso Simples - 2 movimentos - palavras do movimento

A figura 6.2.1 mostra o dendrograma gerado a partir das distâncias entre as *palavras do movimentos*, para os movimentos *walk2StepsRstart* e *skier1RepsLstart*, com os rótulos das atividades e um identificador(*tr*, *bk*, *mm*, *dg*, *bd*) corresponde ao ator que realizou a atividade. A figura 16 mostra o mesmo diagrama com as *palavras do movimento*.

Foram considerados 3 DOFs.

Para este caso, o classificador dos 3 vizinhos mais próximos, obteve exatidão de 100%.

### 6.2.2 Conjunto de 10 movimentos - 3DOF

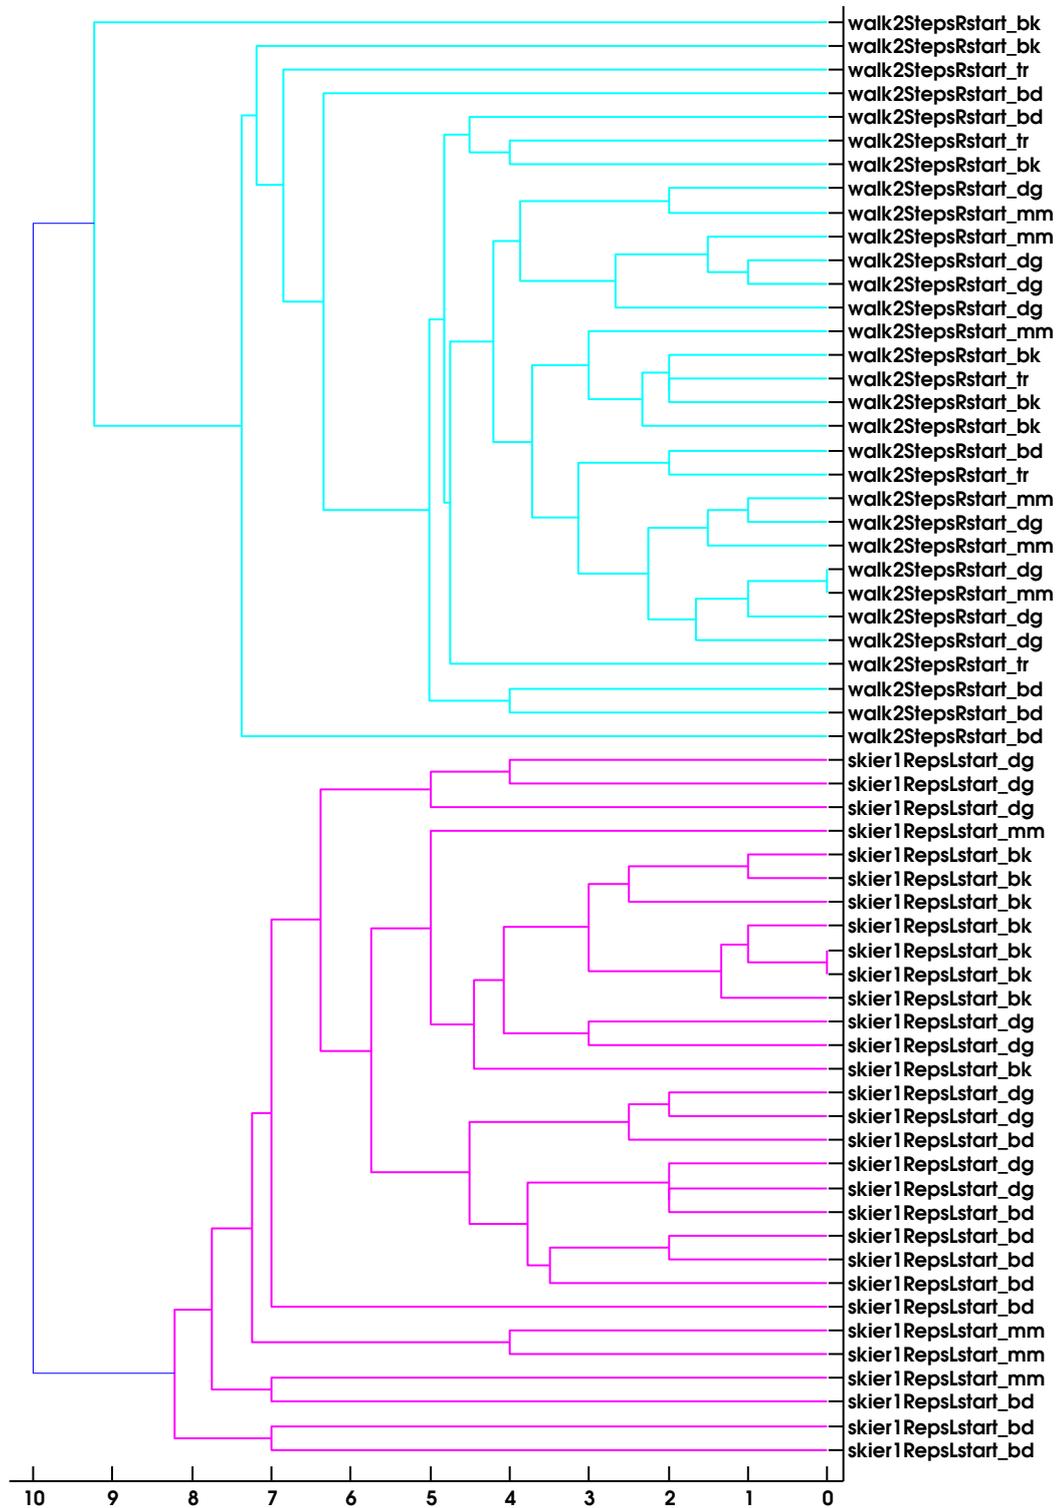
A figura 17 mostra uma visão geral do agrupamento para os 10 movimentos, gerado a partir das distâncias entre as *palavras do movimentos*, sem os rótulos das atividades. Para uma melhor visualização o dendrograma da figura 17 foi dividido em 3 partes e exibido nas figuras 22, 23 e 24.

Obteve-se uma exatidão de 84.72% para 10-fold CV e 72.22% para LOSOCV.

A matriz de distâncias foi gerada em  $0m2.176s$ (*user time*).

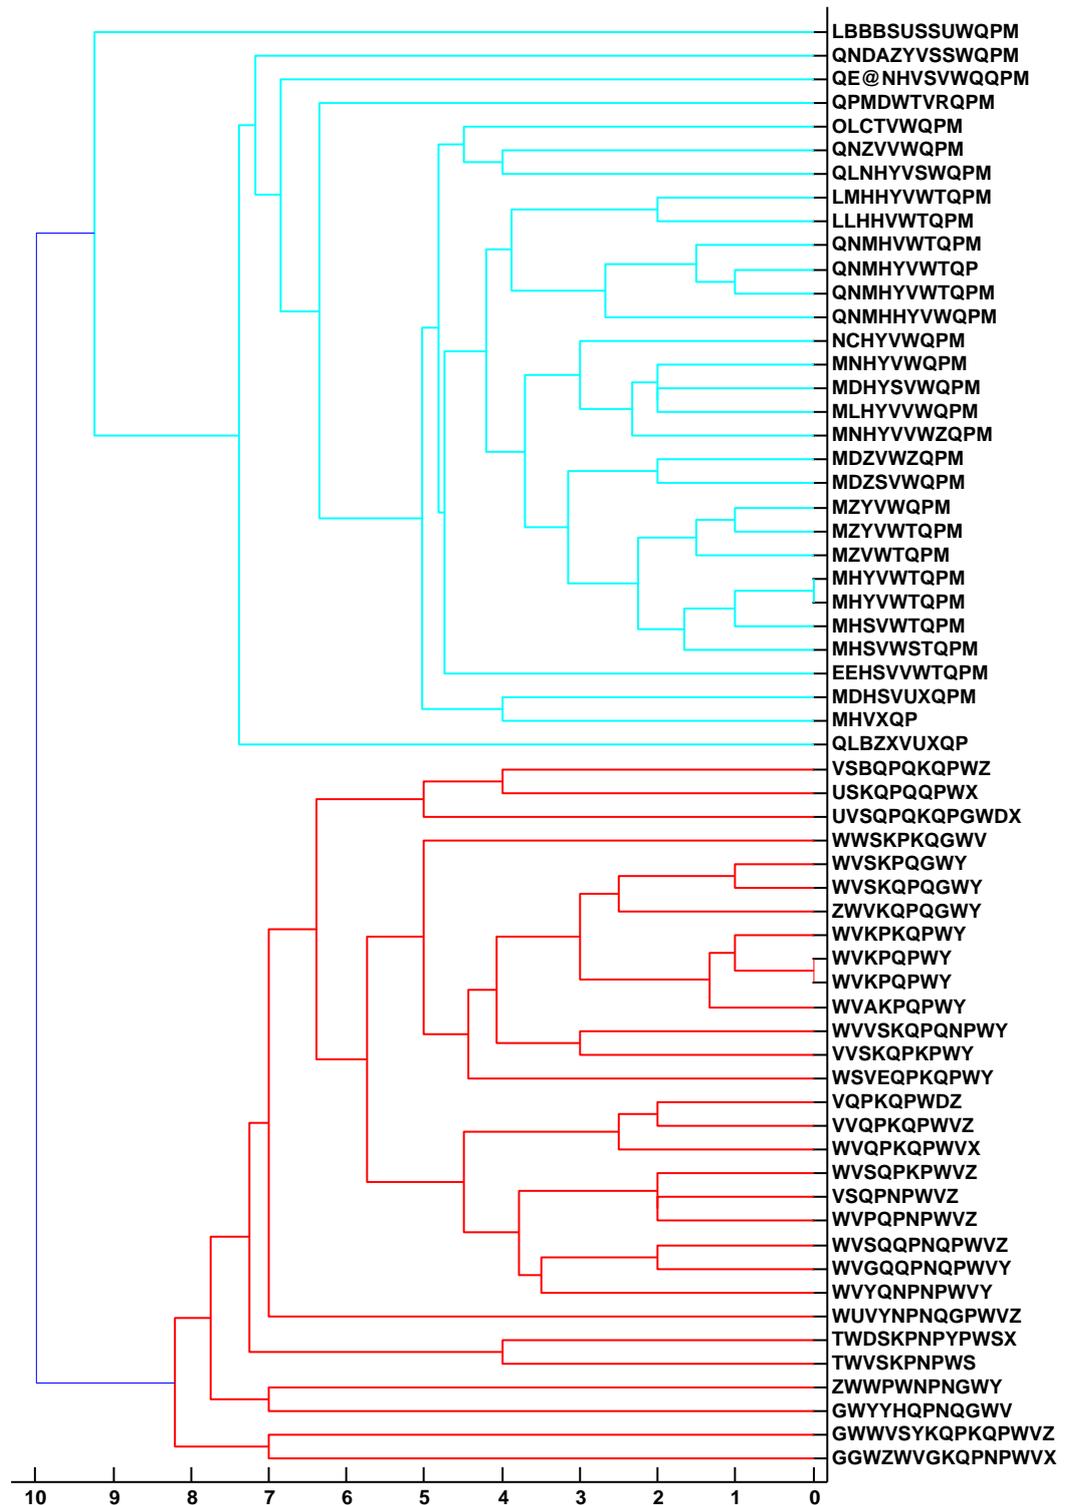
### 6.2.3 Conjunto de 10 movimentos - 4DOF

De forma semelhante a seção anterior, porém com 4 DOF. A figura 18 mostra uma visão geral do agrupamento para os 10 movimentos, exibida com maiores detalhes nas figuras 25, 26 e 27.

Figura 15 – Dendrograma para os movimentos *walk2StepsRstart* e *skier1RepsLstart*

Com os rótulos das atividades e o marcador correspondente ao ator que realizou a atividade

Obteve-se uma exatidão de 83.33% para 10-fold CV e 73.15% para LOSOCV.

Figura 16 – Dendrograma para os movimentos *walk2StepsRstart* e *skier1RepsLstart*

Com as *palavras do movimento* correspondentes. Em ciano um cluster associado ao andar, em vermelho um cluster associado ao “skier”

A matriz de distâncias foi gerada em  $0m2.828(user\ time)$ .

### 6.2.4 Conjunto de 10 movimentos - MD-DTW

Agora utilizando a distância MD-DTW como métrica alternativa. A figura 19 mostra uma visão geral do agrupamento para os 10 movimentos, exibido com maiores detalhes nas figuras 28, 29 e 30.

Obeve-se uma exatidão de 95.37% para 10-fold CV e 84.72% para LOSOCV.

A matriz de distâncias foi gerada em 240m4.648s(*user time*).

A exatidão por classe para o conjunto de 10 movimentos para cada uma das abordagens é apresentada na tabela 2.

Tabela 2 – Exatidão por classes

Rótulo da classe	Exatidão por classe		
	3DOF	4DOF	MD-DTW
elbowToKnee1RepsLelbowStart	96,30%	100,00%	100,00%
jogOnPlaceStartAir2StepsLstart	85,71%	78,57%	100,00%
shuffle2StepsRstart	69,23%	38,46%	91,67%
sitDownKneelTieShoes	78,57%	71,43%	86,67%
sitDownTable	90,00%	90,00%	93,33%
skier1RepsLstart	96,67%	93,33%	100,00%
squat1Reps	59,38%	93,75%	100,00%
standUpSitChair	90,00%	65,00%	100,00%
walk2StepsRstart	93,55%	93,55%	100,00%
walkBackwards2StepsRstart	80,00%	60,00%	93,33%

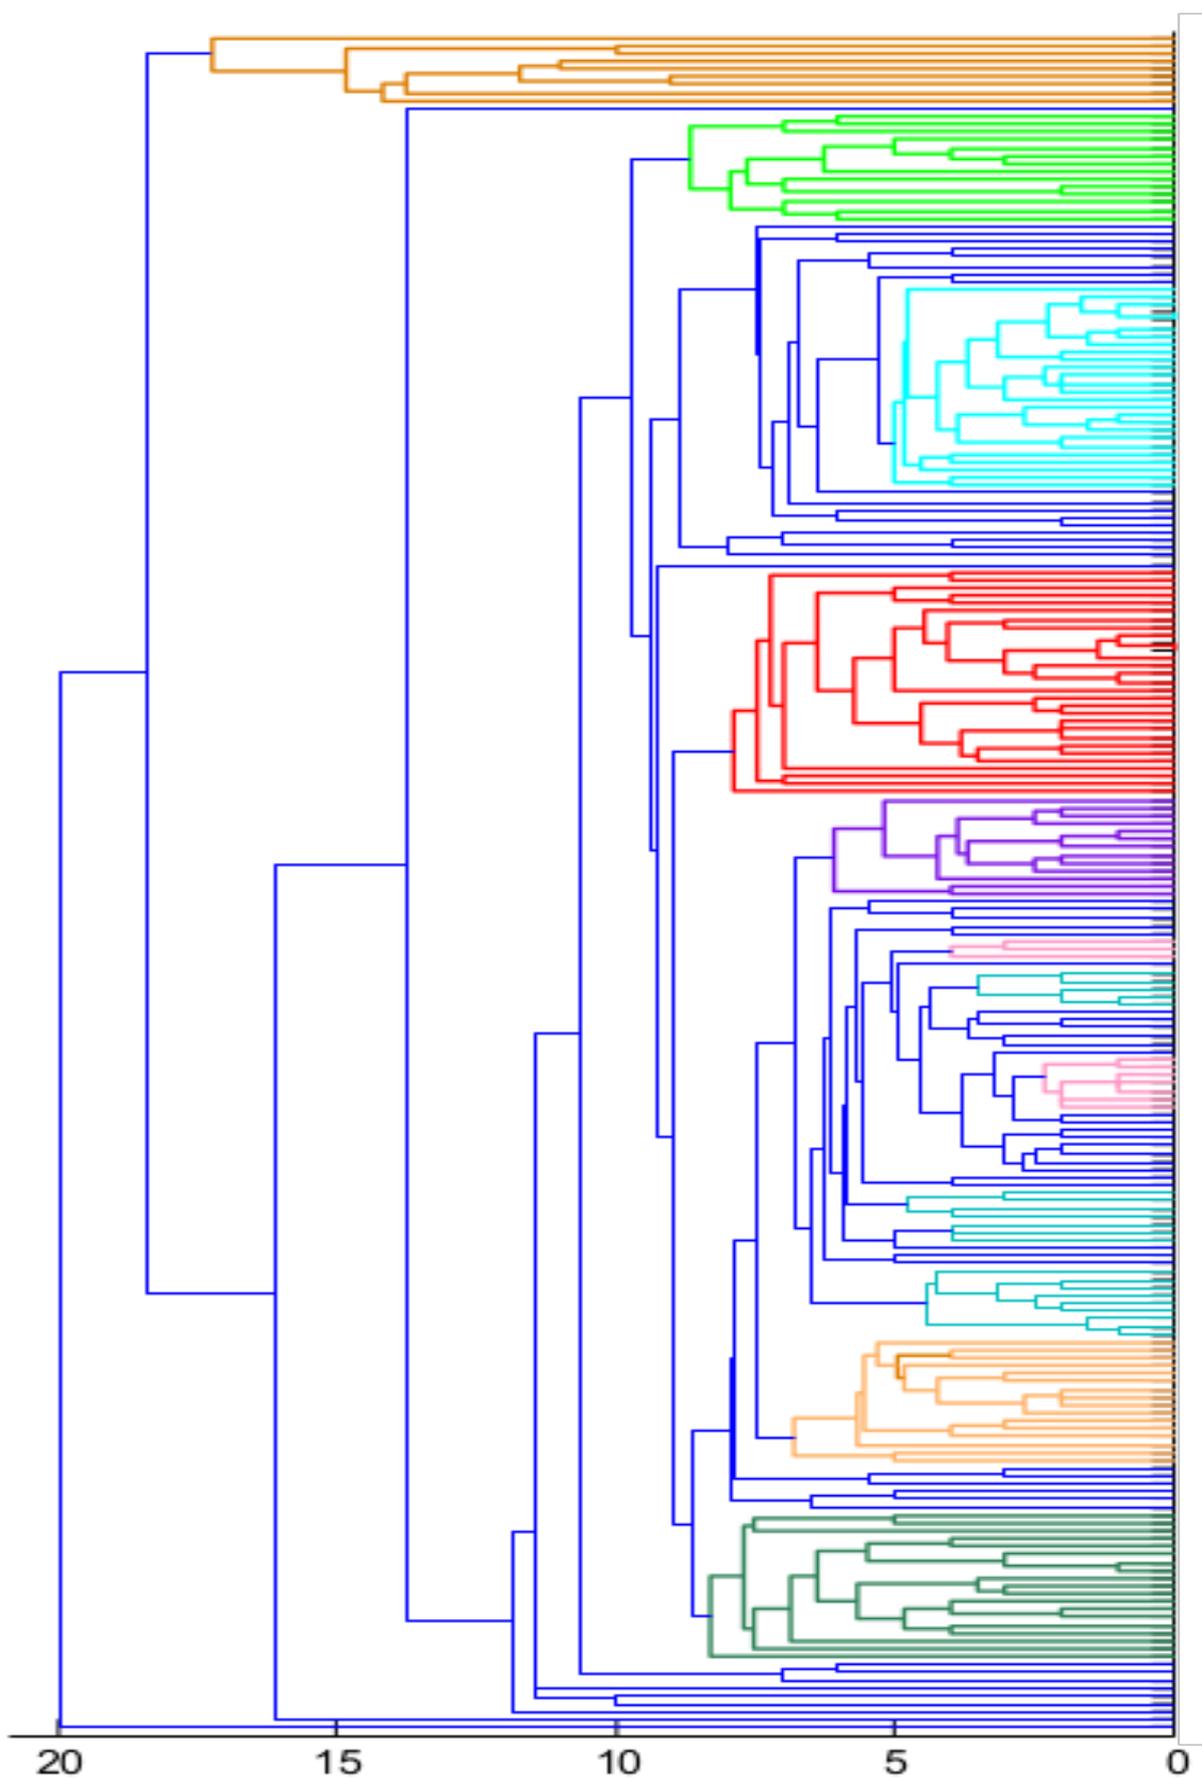
10 atividades

### 6.2.5 Padrão sequencial - walk2StepsLstart

Utilizando a representação por meio de sequencias de inteiros das *palavras dos movimentos*, descobrimos um padrão recorrente.  $\langle 17, 16, 13 \rangle$  que ocorre em 100% dos casos em um conjunto de 31 amostras.

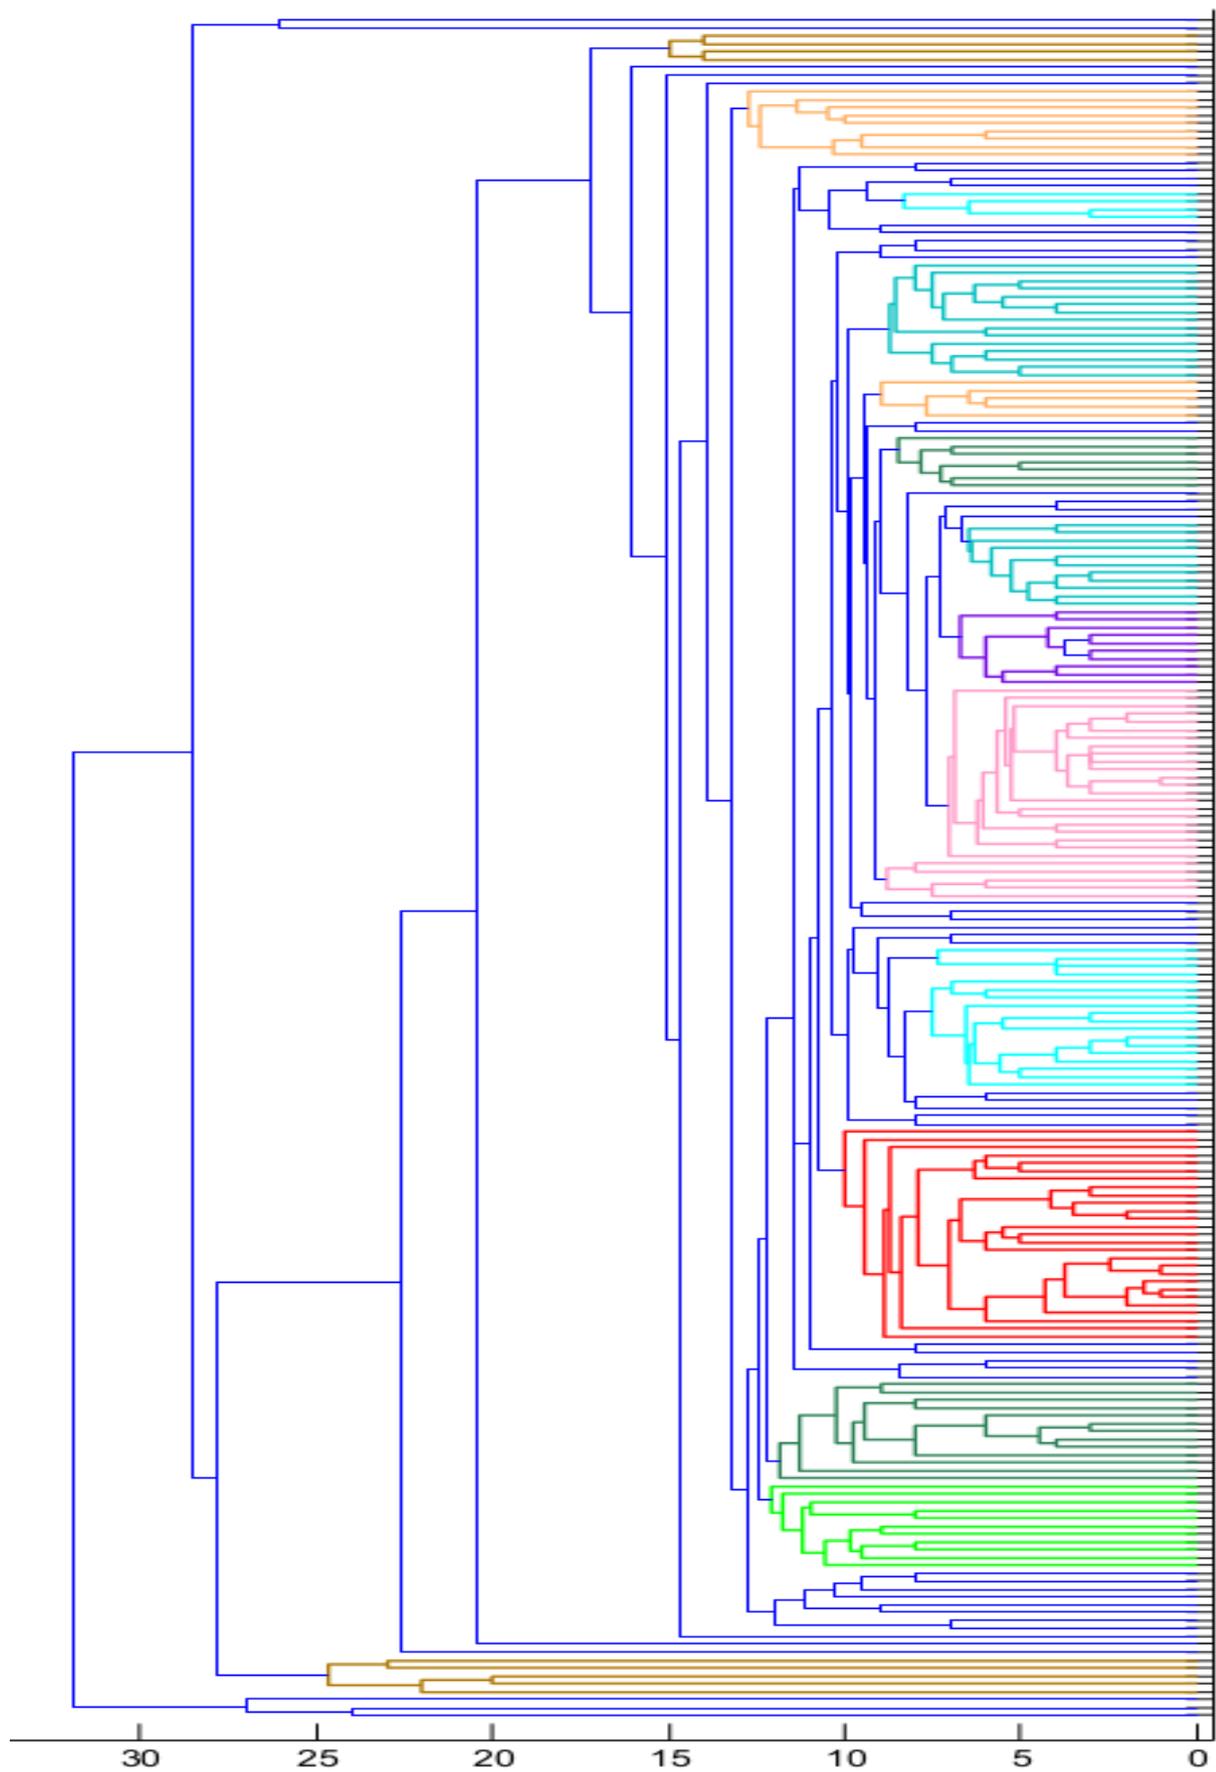
A figura 20 exhibe uma amostra com destaque para o intervalo correspondente ao padrão recorrente.

Figura 17 – Visão geral do dendrograma para os 10 movimentos



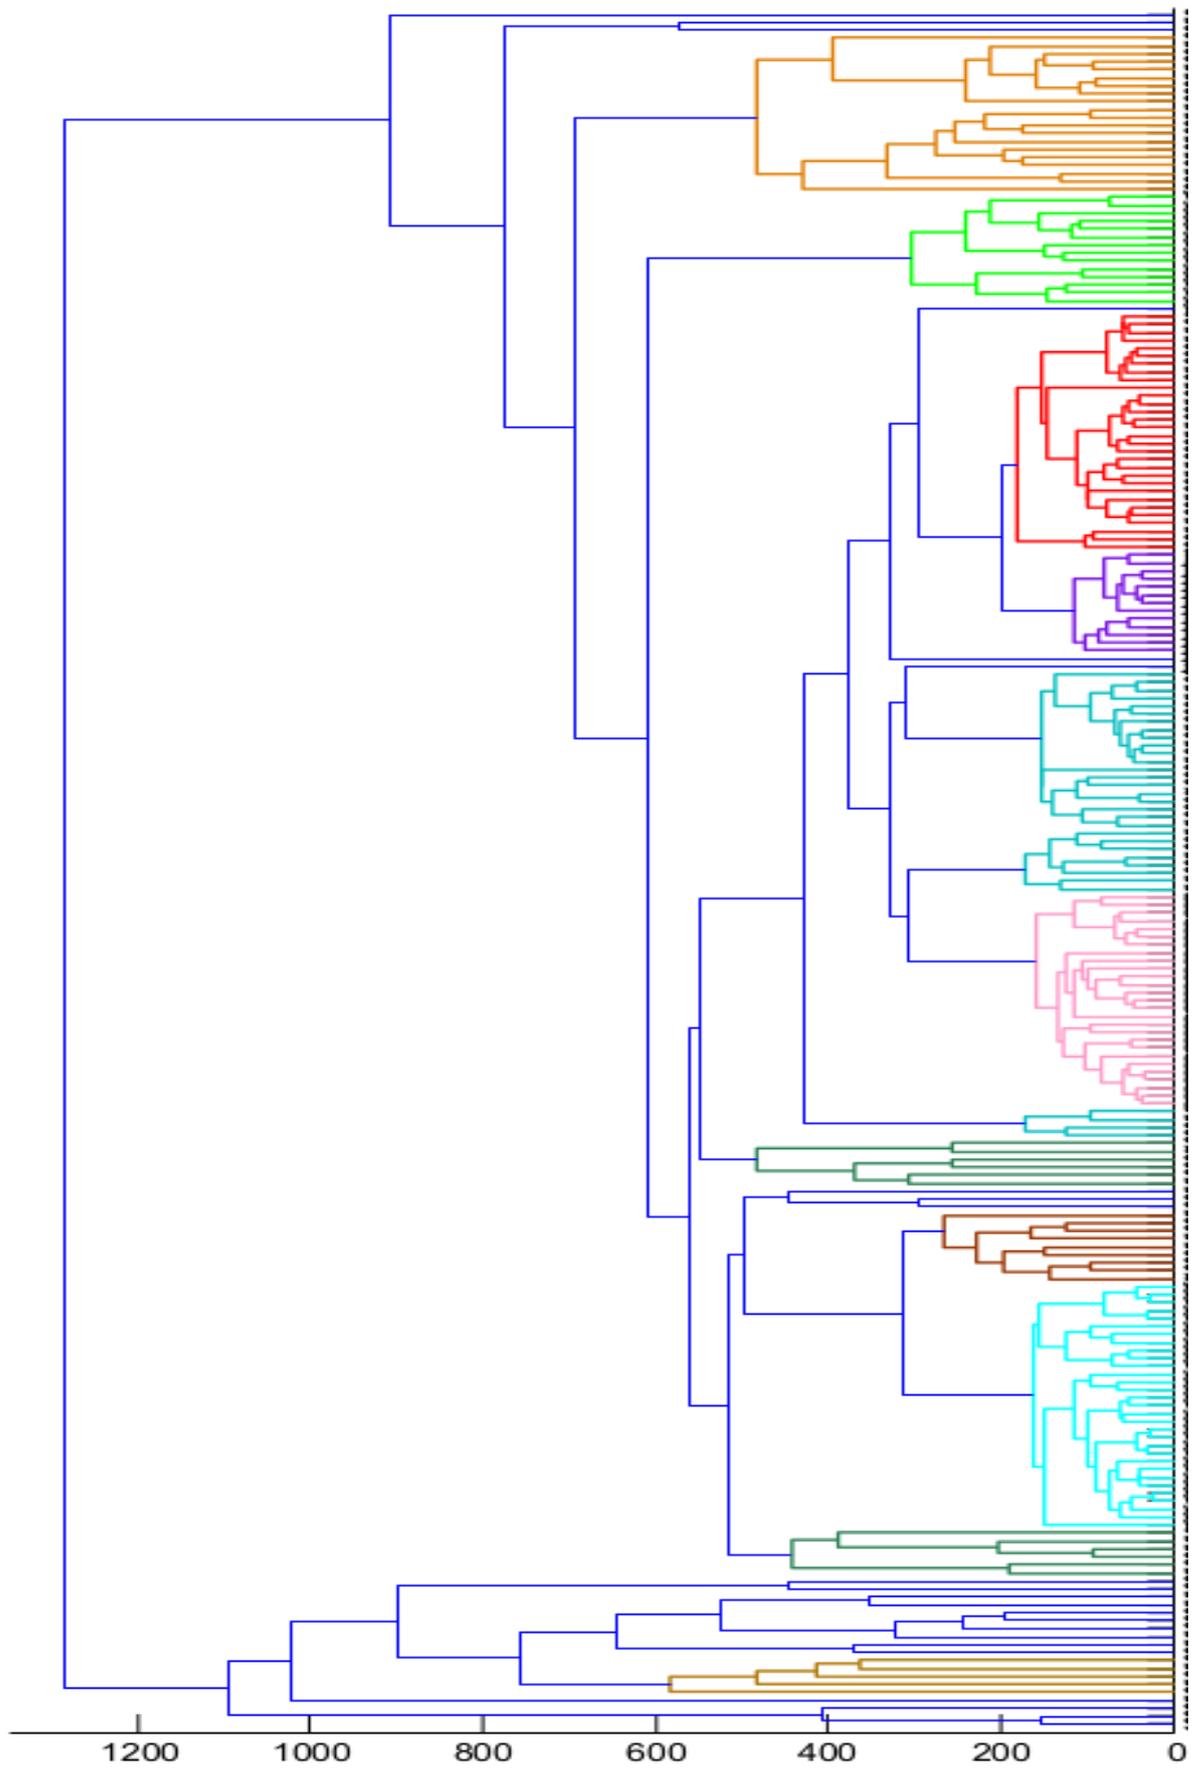
sem os rótulos das atividades, cada cor corresponde a uma atividade

Figura 18 – Visão geral do dendrograma para os 10 movimentos, utilizando 4 DOF



sem os rótulos das atividades

Figura 19 – Visão geral do dendrograma para os 10 movimentos, a partir da distância MD-DTW,



sem os rótulos das atividades

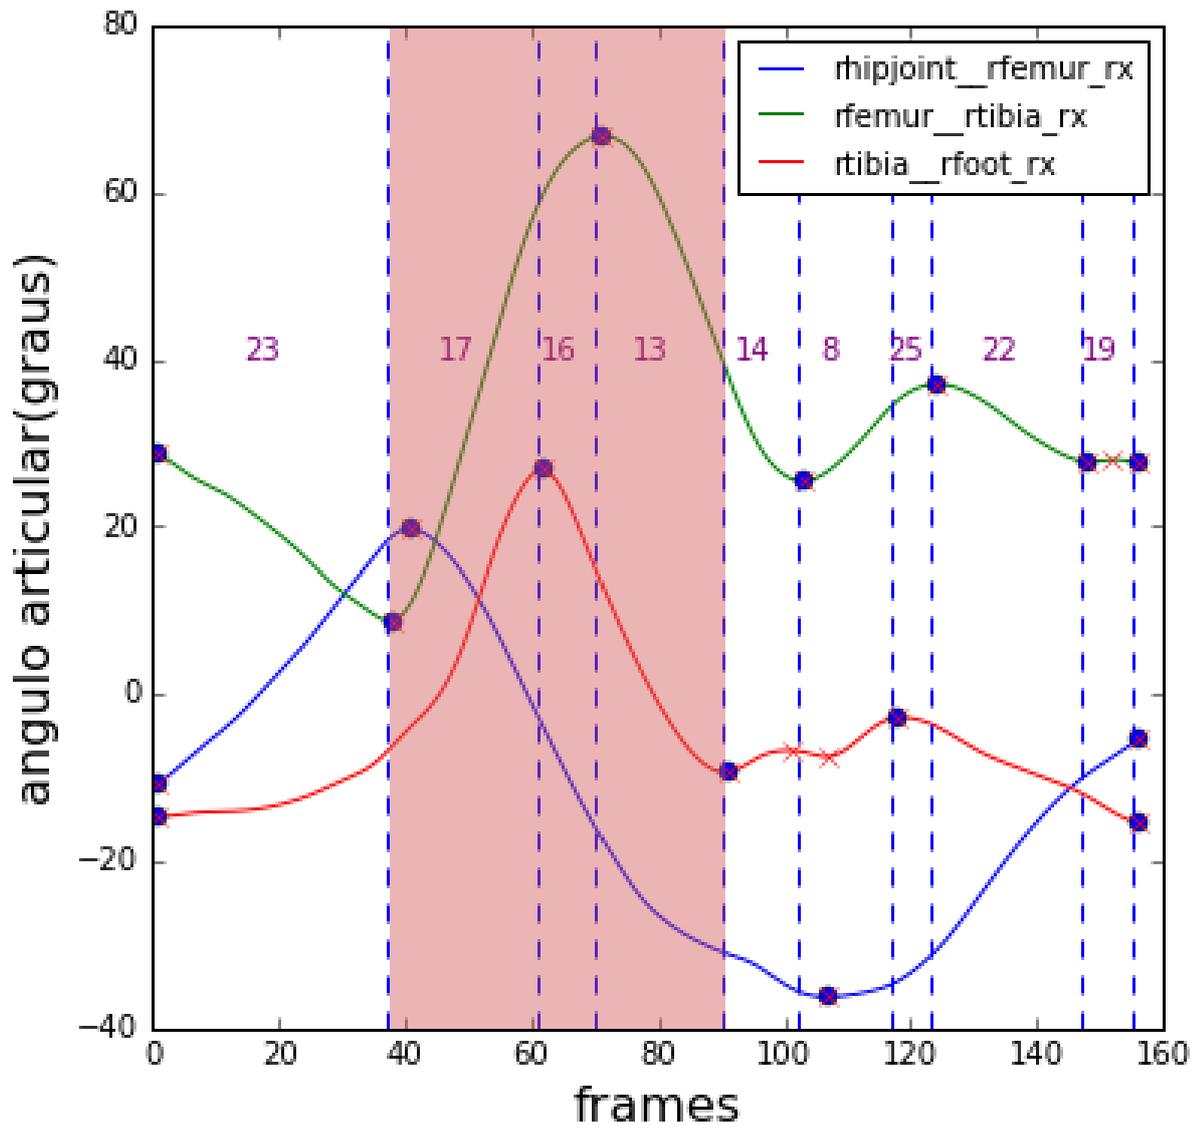


Figura 20 – Amostra do movimento *walk2StepsLstart* com destaque para o intervalo correspondente ao padrão recorrente  $\langle 17, 16, 13 \rangle$

## 6.3 Discussão

### 6.3.1 Caso simples

No caso simples apresentado na figura 16 nossa ideia funciona de forma excelente, as atividades ficam associadas a clusters completamente distintos. Não é surpresa que o classificador obtem um resultado de 100% de exatidão. Na figura 6.2.1 podemos observar que muitas vezes, dada uma amostra, a mais próxima é uma amostra que além de ser do mesmo movimento é também realiza pelo mesmo ator. Podemos observar em destaque o caso do ator *bk* no movimento *skier1RepsLstart*, onde as amostras realizadas por este ator formam um cluster. Podemos considerar tal fato como um indício que esta técnica seja capaz de identificar diferentes técnicas de movimentos, nesse caso a técnica utilizada por *bk*.

### 6.3.2 Conjunto de 10 movimentos - 3DOF

Quando acrescentamos mais movimentos e repetimos o experimento, não observamos uma organização tão perfeita quanto no caso considerado na seção 6.3.1, mas o resultado ainda é bom. Nas figuras 22 e 23, reparamos que as atividades anteriores, *walk2StepsRstart* e *skier1RepsLstart*, ainda estão organizadas em clusters bem distintos, apesar que *walk2StepsRstart* se confunde um pouco com *shuffle2StepsRStart*. A maioria das atividades apresenta um cluster principal correspondente bem definido. No entanto *squat1Reps*(agachamento) e o *elbowToKnee1RepsElbowStart*(tocar cotovelo no joelho) são atividades que se confundem entre si(figura 23), porém ainda ocorre a formação de pequenos clusters que permitem a classificação utilizando os vizinhos mais próximos.

### 6.3.3 Conjunto de 10 movimentos - 4DOF

Utilizando um grau de liberdade extra, flexão/extensão do ombro, não houve grandes mudanças no resultado geral da classificação. Porém olhando a exatidão por classes (tabela 2) observamos que a classificação das atividades *squat1Reps* e *elbowToKnee1RepsElbowStart* que se confundiam no caso anterior, agora são melhores classificadas. Isto é esperado uma vez que a atividade *elbowToKnee1RepsElbowStart* envolve a flexão/extensão do ombro de forma essencial. Observando o dendrograma isto também fica claro, um cluster para a atividade *elbowToKnee1RepsElbowStart* pode ser observado na figura 26 e a maioria das amostras de *squat1Reps* se encontra em dois clusters que podem ser visualizados na figura 25.

Por outro lado as atividades *standUpSitChair* e *shuffle2StepsRStart* tiveram a performance de sua classificação prejudicadas de forma significativa.

De uma forma geral podemos pensar que a introdução de mais graus de liberdade,

traz mais informações que podem ser utilizadas, porém também introduz uma maior variabilidade, ainda mais quando se trata de um grau de liberdade que não é essencial a tarefa. Talvez seja possível observar padrões nessa variabilidade, se o número de amostras for suficientemente grande, mas não é o nosso caso.

### 6.3.4 Conjunto de 10 movimentos - MD-DTW

A partir da distância MD-DTW obtemos a melhor exatidão na classificação e clusters melhores definidos nos dendrogramas, no entanto o tempo de processamento para gerar a matriz de distâncias é muito maior nesse caso, comparando os tempos de execução, temos uma diferença de aproximadamente 50000x. Apesar do código do MD-DTW não se encontrar otimizado, tal diferença é resultado intrínseco das diferenças nos algoritmos. O MD-DTW apresentar uma complexidade computacional superior, o ponto crucial é o cálculo da matriz de custos, a partir da equação 5.4 podemos inferir uma complexidade  $O(n^2k)$ , sendo  $n$  o número de amostras do sinal durante a execução do movimento e  $k$  o número de graus de liberdade. Já o algoritmo que gera as *palavras do movimento* tem como ponto crucial a detecção de picos e vales, tarefa de complexidade  $O(nk)$ .

### 6.3.5 Padrão sequencial - walk2StepsLstart

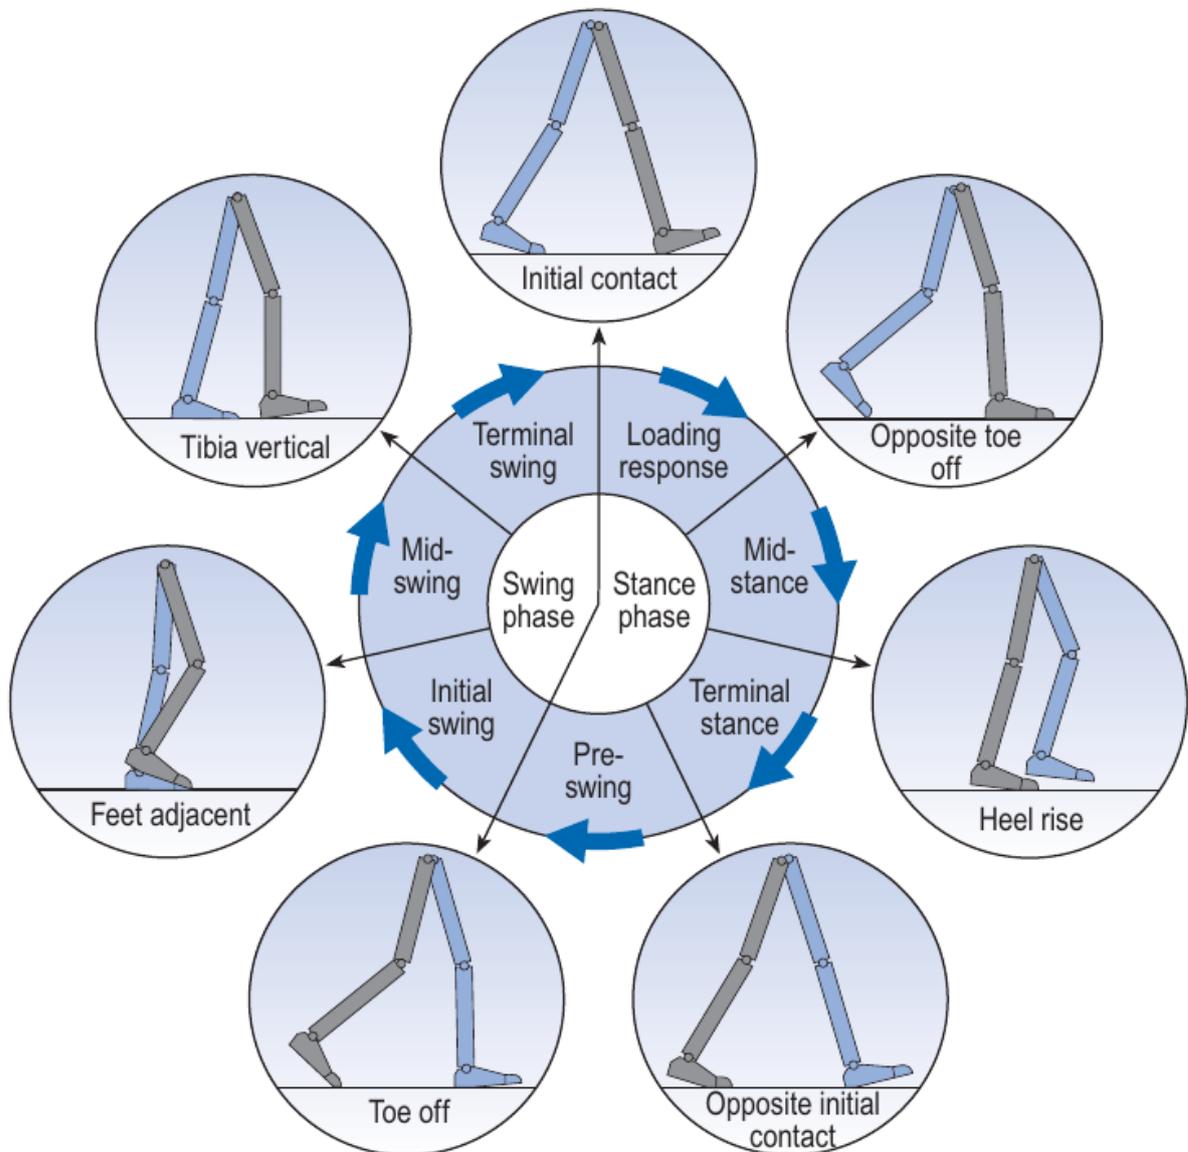
O padrão sequencial encontrado  $\langle 17, 16, 13 \rangle$  corresponde a três picos consecutivos, correspondentes a extensão máxima do quadril, a flexão plantar máxima do tornozelo e a flexão máxima do joelho. O andar é um movimento bem caracterizado e estudado, tais picos ocorrem suscetivamente no andar de uma pessoa normal durante as fases de pré-balanço e balanço inicial, veja fig 21 para as posições das pernas durante as fases do andar.

### 6.3.6 Considerações Gerais

Para as classificações de uma forma geral, sempre observamos que o desempenho foi superior na validação 10-fold CV com relação a LOSOCV, com uma diferença de pelo menos 10%. Essa é uma medida da influência que os dados do próprio sujeito, o qual a atividade esta sendo prevista, tem na classificação.

No caso dos dendrogramas, a altura dos clusters formados mostra a variabilidade do movimento dentro de uma atividade. A atividade "sitDownKneelTieShoes" é para todos os casos a que apresenta maior variabilidade. O que é de se esperar pois é uma atividade que oferece maior liberdade em sua execução, oferecendo múltiplas técnicas para seu objetivo ser cumprido. Já atividades como "walk2StepsRstart", "walkBackwards2StepsRstart" e "skier1RepsLstart" apresentam uma menor variabilidade.

Figura 21 – Posições das pernas durante o ciclo da marcha



(retirado de (WHITTLE, 2007))

Com relação aos graus de liberdade, não seria surpresa se os bons resultados obtidos fossem fruto da escolha de 3 articulações (quadril, joelho, tornozelo) que trabalham de forma sinérgica muitas vezes.

É possível que a diferença de desempenho na classificação entre a classificação utilizando a distância de Levenshtein a partir das *palavras do movimento* em comparação com a distância MD-DTW, possa ser reduzida (ou até mesmo superada) adotando duas estratégias de aprimoramento. Uma aperfeiçoamento na forma como as *palavras do movimento* são construídas, como também na adoção/elaboração de uma métrica alternativa a distância de Levenshtein, de forma a melhorar o resultado. Tais estratégias podem ser exploradas em trabalhos futuros.

Em comparação com outros métodos como redes neurais e SVM, temos uma forma mais fácil de visualizar a classificação, ainda mais com as disponibilidades dos dendrogramas. Uma representação simbólica com base no acoplamento articular, que permite a utilização de algoritmos de processamento de texto, sequências e bioinformática. As operações que levam de uma representação simbólica a outra também podem ser utilizadas para estabelecer um biofeedback, complementando uma simples métrica de similaridade entre dois movimentos.

## 7 Conclusão

Com este trabalho atingimos o objetivo proposto e estabelecemos uma representação simbólica do movimento, denominada *palavras do movimento*, com boa parte das características almejadas. É uma representação simples e prática, a partir da qual foi possível estabelecer uma métrica que quantifica a similaridade entre movimentos. Métrica que foi utilizada para realizar um agrupamento hierárquico e classificação supervisionada de um conjunto de movimentos contendo 10 classes de atividades. Há indícios (seção 6.3.1) que a partir desta representação e métrica seja possível identificar diferentes técnicas de execução de movimento, no entanto ainda são necessários mais experimentos com este foco. As operações que levam de uma representação simbólica a outra (seção 5.1.3) podem ser utilizadas como feedback das diferenças entre dois movimentos. Os movimentos sobre os quais a metodologia deste trabalho foi utilizada foram todos discretos, mas podemos imaginar que a comparação entre movimentos cíclicos possa ser realizada em cima das curvas médias dos ângulos articulares, porem faz-se necessário testes e validações desta hipótese.

Se por um lado a exatidão na classificação dos movimentos é inferior quando utilizamos a distância de Levenshtein a partir das *palavras do movimento* em relação a distância MD-DTW, por outro lado temos um método muito mais rápido em termos de processamento computacional, o que favorece o método proposto em certas aplicações. Por exemplo um biofeedback em tempo real ou uma triagem. Além disso, artifícios como as operações que levam de uma representação simbólica a outra e a mineração de padrões sequenciais são exclusividades das representações simbólicas.

A definição das *palavras do movimento* está intrinsecamente ligada a SAAM, que sob nosso ponto de vista pode ser considerada a essência de um movimento.

Além da proposta das *palavras do movimento*, trazemos uma metodologia que pode ser aplicada quando se possui uma métrica de similaridades entre movimentos, levando a uma abordagem mais objetiva na análise do movimento humano que defendemos.

Existe espaço para diversos aprimoramentos e uma maior validação. O método que gera as *palavras do movimento* pode ser aprimorado com uma redução do número ou estabelecendo um melhor critério de escolha dos parâmetros, a incorporação de mais informações relevantes, como uma escala relacionada a amplitude de variação angular é outro ponto que pode vir a ser explorado. Além da geração das *palavras de movimento*, o que fazemos com as *palavras de movimento* também pode ser aprimorado, como a elaboração de uma métrica de similaridade alternativa a distância de Levenshtein, que considere custos variados de acordo com operação de transformação da string. É pertinente

também, uma validação com indivíduos de diferentes classes (saudável, patológico, adulto, idoso etc ...) executando um movimento específico, seria muito interessante.

Por fim este trabalho pode ser visto como um embrião para uma metodologia de análise do movimento humano.

## Referências

- ADAMS, D. C.; CERNEY, M. M. Quantifying biomechanical motion using Procrustes motion analysis. *Journal of biomechanics*, v. 40, n. 2, p. 437–44, jan. 2007. ISSN 0021-9290. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/16448654>>. Citado na página 27.
- AGRAWAL, R.; SRIKANT, R. Fast algorithms for mining association rules in large databases. In: *Proceedings of the 20th International Conference on Very Large Data Bases*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1994. (VLDB '94), p. 487–499. ISBN 1-55860-153-8. Disponível em: <<http://dl.acm.org/citation.cfm?id=645920.672836>>. Citado na página 49.
- ARNOLD, B. Methods for recognition and classification of human motion patterns—A prerequisite for intelligent devices assisting in sports activities. p. 55–61, fev. 2012. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1474667016306425>>. Citado na página 23.
- BADLER, N. I.; SMOLIAR, S. W. Digital Representations of Human Movement. *ACM Computing Surveys*, v. 11, n. 1, p. 19–38, jan. 1979. ISSN 03600300. Disponível em: <<http://portal.acm.org/citation.cfm?doid=356757.356760>>. Citado na página 28.
- BARTLETT, R. *Introduction to Sports Biomechanics: Analysing Human Movement Patterns*. Second ed. Routledge/Taylor & Francis Group, 2006. 320+ p. ISBN 978-0415339940. Disponível em: <<http://cw.routledge.com/textbooks/9780415339940/>>. Citado na página 17.
- BLESER, G. et al. A personalized exercise trainer for the elderly. n. 5, p. 547–562, 2013. Citado 2 vezes nas páginas 23 e 28.
- CAPPOZZO, A. et al. Human movement analysis using stereophotogrammetry. Part 1: theoretical background. *Gait & posture*, v. 21, n. 2, p. 186–96, fev. 2005. ISSN 0966-6362. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/15639398>>. Citado na página 17.
- CHAU, T. A review of analytical techniques for gait data. Part 1: Fuzzy, statistical and fractal methods. *Gait & posture*, v. 13, n. 1, p. 49–66, fev. 2001. ISSN 0966-6362. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/11166554>>. Citado na página 27.
- CHAU, T. A review of analytical techniques for gait data. Part 2: neural network and wavelet methods. *Gait & posture*, v. 13, n. 2, p. 102–20, abr. 2001. ISSN 0966-6362. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/11240358>>. Citado na página 27.
- DELEO, A. T. et al. Lower extremity joint coupling during running: a current update. *Clinical biomechanics (Bristol, Avon)*, v. 19, n. 10, p. 983–91, dez. 2004. ISSN 0268-0033. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/15531047>>. Citado na página 42.

FU, T.-c. A review on time series data mining. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 24, n. 1, p. 164–181, fev. 2011. ISSN 09521976. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0952197610001727>>. Citado na página 25.

FUKUCHI, R. K. et al. Support vector machines for detecting age-related changes in running kinematics. *Journal of biomechanics*, Elsevier, v. 44, n. 3, p. 540–2, fev. 2011. ISSN 1873-2380. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/20980005>>. Citado na página 28.

GUERRA-FILHO, G.; ALOIMONOS, Y. A language for human action. *IEEE Computer*, v. 40, n. 5, p. 42–51, 2007. Disponível em: <<http://doi.ieeecomputersociety.org/10.1109/MC.2007.154>>. Citado na página 28.

GUERRA-FILHO, G.; FERMULLER, C.; ALOIMONOS, Y. Discovering a language for human activity. . . . of the AAAI 2005 fall symposium . . . , 2005. Disponível em: <<http://www.aaai.org/Papers/Symposia/Fall/2005/FS-05-05/FS05-05-010.pdf>>. Citado na página 28.

HERRAN, A. Muro-de-la; GARCIA-ZAPIRAIN, B.; MENDEZ-ZORRILLA, A. Gait analysis methods: an overview of wearable and non-wearable systems, highlighting clinical applications. *Sensors (Basel, Switzerland)*, v. 14, n. 2, p. 3362–94, jan. 2014. ISSN 1424-8220. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3958266&tool=pmcentrez&rendertype=abstract>>. Citado 2 vezes nas páginas 19 e 21.

HOLT, G. ten; REINDERS, M.; HENDRIKS, E. Multi-dimensional dynamic time warping for gesture recognition. In: *Thirteenth annual conference of the Advanced School for Computing and Imaging*. [S.l.: s.n.], 2007. Citado na página 55.

JUNEJO, I. N.; AGHBARI, Z. A. Using SAX representation for human action recognition. *Journal of Visual Communication and Image Representation*, Elsevier Inc., v. 23, n. 6, p. 853–861, ago. 2012. ISSN 10473203. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1047320312000806>>. Citado na página 29.

KULIC, D. et al. Incremental learning of full body motion primitives and their sequencing through human motion observation. *The International Journal of Robotics Research*, v. 31, n. 3, p. 330–345, nov. 2011. ISSN 0278-3649. Disponível em: <<http://ijr.sagepub.com/cgi/doi/10.1177/0278364911426178>>. Citado na página 32.

LEVENSHTEIN, V. Binary Codes Capable of Correcting Deletions, Insertions and Reversals. *Soviet Physics Doklady*, v. 10, p. 707, 1966. Citado na página 43.

LU, T.-W.; CHANG, C.-F. Biomechanics of human movement and its clinical applications. *The Kaohsiung journal of medical sciences*, Elsevier Taiwan LLC, v. 28, n. 2 Suppl, p. S13–25, fev. 2012. ISSN 1607-551X. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/22301008>>. Citado na página 17.

MENTIPLAY, B. F. et al. Gait assessment using the Microsoft Xbox One Kinect: Concurrent validity and inter-day reliability of spatiotemporal and kinematic variables. *Journal of Biomechanics*, Elsevier, v. 48, n. 10, p. 2166–2170, 2015. ISSN 18732380. Disponível em: <<http://dx.doi.org/10.1016/j.jbiomech.2015.05.021>>. Citado na página 20.

MULLER, M. Information retrieval for music and motion. In: \_\_\_\_\_. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. cap. Dynamic Time Warping, p. 69–84. ISBN 978-3-540-74048-3. Disponível em: <[http://dx.doi.org/10.1007/978-3-540-74048-3\\_4](http://dx.doi.org/10.1007/978-3-540-74048-3_4)>. Citado 2 vezes nas páginas 52 e 53.

MÜLLER, M. et al. *Documentation Mocap Database HDM05*. [S.l.], 2007. Citado 5 vezes nas páginas 20, 22, 24, 33 e 57.

OATIS, C. A. *Kinesiology: the mechanics and pathomechanics of human movement*. [S.l.]: Lippincott Williams Wilkins, 2009. Citado na página 17.

PARK, W. et al. Representing and identifying alternative movement techniques for goal-directed manual tasks. *Journal of biomechanics*, v. 38, n. 3, p. 519–27, mar. 2005. ISSN 0021-9290. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/15652550>>. Citado na página 27.

PARK, W. et al. A quantitative method for representing balance strategies of goal-directed human motions. *Computers in biology and medicine*, v. 38, n. 10, p. 1094–102, out. 2008. ISSN 0010-4825. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/18823622>>. Citado na página 27.

PEI, J. et al. PrefixSpan,: mining sequential patterns efficiently by prefix-projected pattern growth. *International Conference on Data Engineering (ICDE)*, p. 215 – 224, 2001. ISSN 1063-6382. Disponível em: <[http://ieeexplore.ieee.org/xpl/freeabs\\_all.jsp?arnumber=914830](http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=914830)>. Citado na página 51.

PERL, J. A neural network approach to movement pattern analysis. *Human movement science*, v. 23, n. 5, p. 605–20, nov. 2004. ISSN 0167-9457. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/15589624>>. Citado na página 27.

SCHMIDT, A. Movement pattern recognition in basketball free-throw shooting. *Human movement science*, Elsevier B.V., v. 31, n. 2, p. 360–82, abr. 2012. ISSN 1872-7646. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/22402277>>. Citado na página 27.

SIMON, S. R. Quantification of human motion: gait analysis-benefits and limitations to its application to clinical problems. *Journal of biomechanics*, v. 37, n. 12, p. 1869–80, dez. 2004. ISSN 0021-9290. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/15519595>>. Citado na página 22.

WATKINS, J. *Structure and function of the musculoskeletal system*. [S.l.]: Human Kinetics, 2010. Citado na página 17.

WEBER, M. et al. Unsupervised model generation for motion monitoring. *2011 IEEE International Conference on Systems, Man, and Cybernetics*, Ieee, p. 51–54, out. 2011. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6083641>>. Citado na página 28.

WEBER, M. et al. Unsupervised motion pattern learning for motion segmentation. In: *Pattern Recognition (ICPR), 2012 21st International Conference on*. [S.l.: s.n.], 2012. p. 202–205. ISBN 9784990644116. ISSN 1051-4651. Citado na página 28.

WHITTLE, M. *Gait analysis: an introduction*. [S.l.]: Butterworth-Heinemann, 2007. Citado 2 vezes nas páginas 23 e 69.

WOLPERT, D. H. The lack of a priori distinctions between learning algorithms. *Neural Comput.*, MIT Press, Cambridge, MA, USA, v. 8, n. 7, p. 1341–1390, out. 1996. ISSN 0899-7667. Disponível em: <<http://dx.doi.org/10.1162/neco.1996.8.7.1341>>. Citado na página 31.

YANG, Q. et al. 10 challenging problems in data mining research. v. 5, n. 4, p. 597–604, 2006. Citado na página 25.

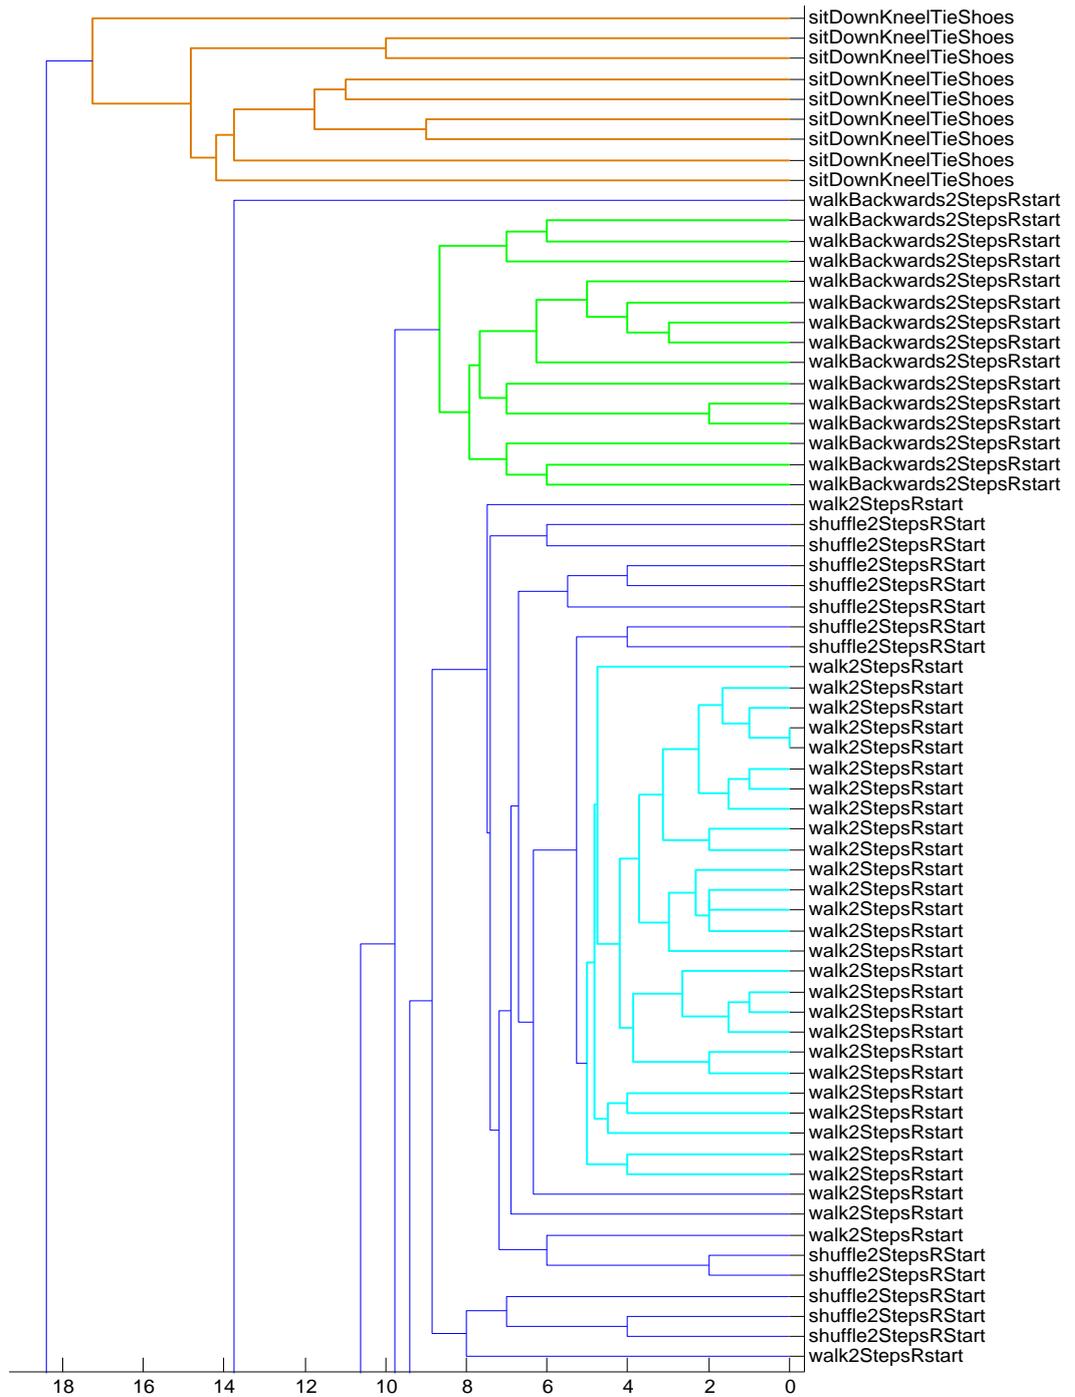
ZHANG, M.; SAWCHUK, A. A. Motion primitive-based human activity recognition using a bag-of-features approach. In: *Proceedings of the 2nd ACM SIGHIT symposium on International health informatics - IHI '12*. New York, New York, USA: ACM Press, 2012. p. 631. ISBN 9781450307819. Disponível em: <<http://dl.acm.org/citation.cfm?doid=2110363.2110433>>. Citado na página 28.

# Apêndices



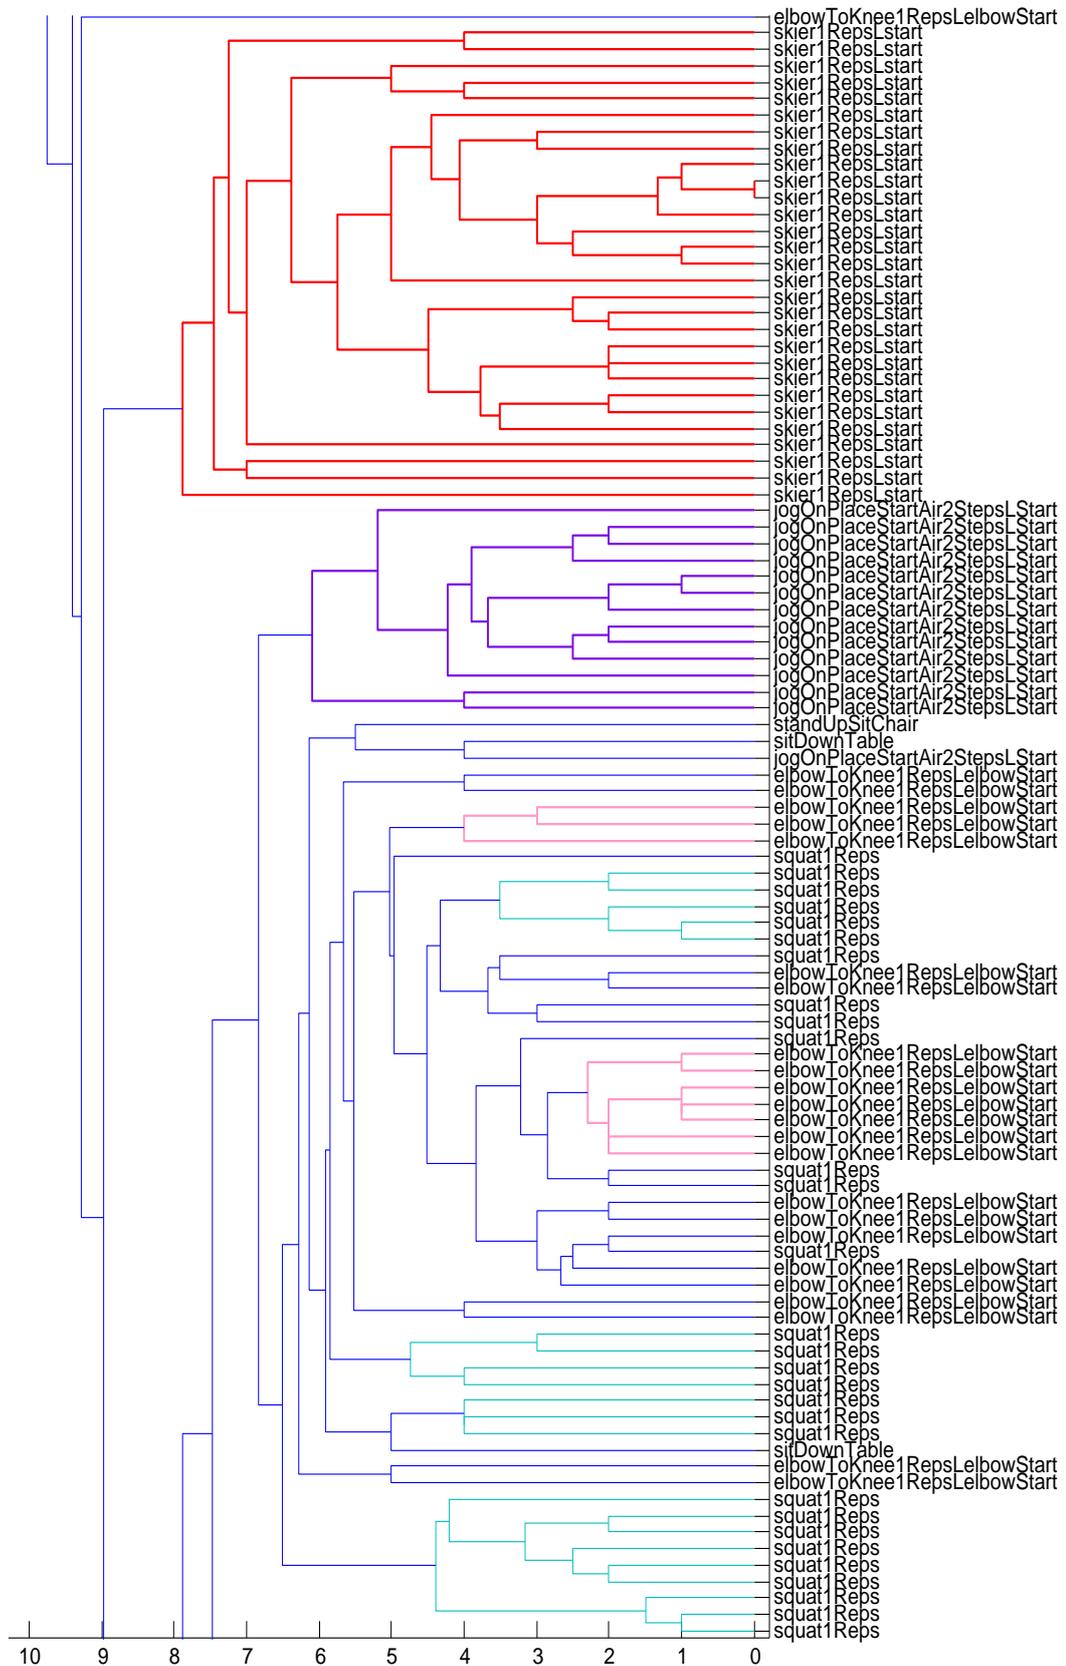
# APÊNDICE A – Dendogramas detalhados

Figura 22 – Parte superior do dendrograma para os 10 movimentos



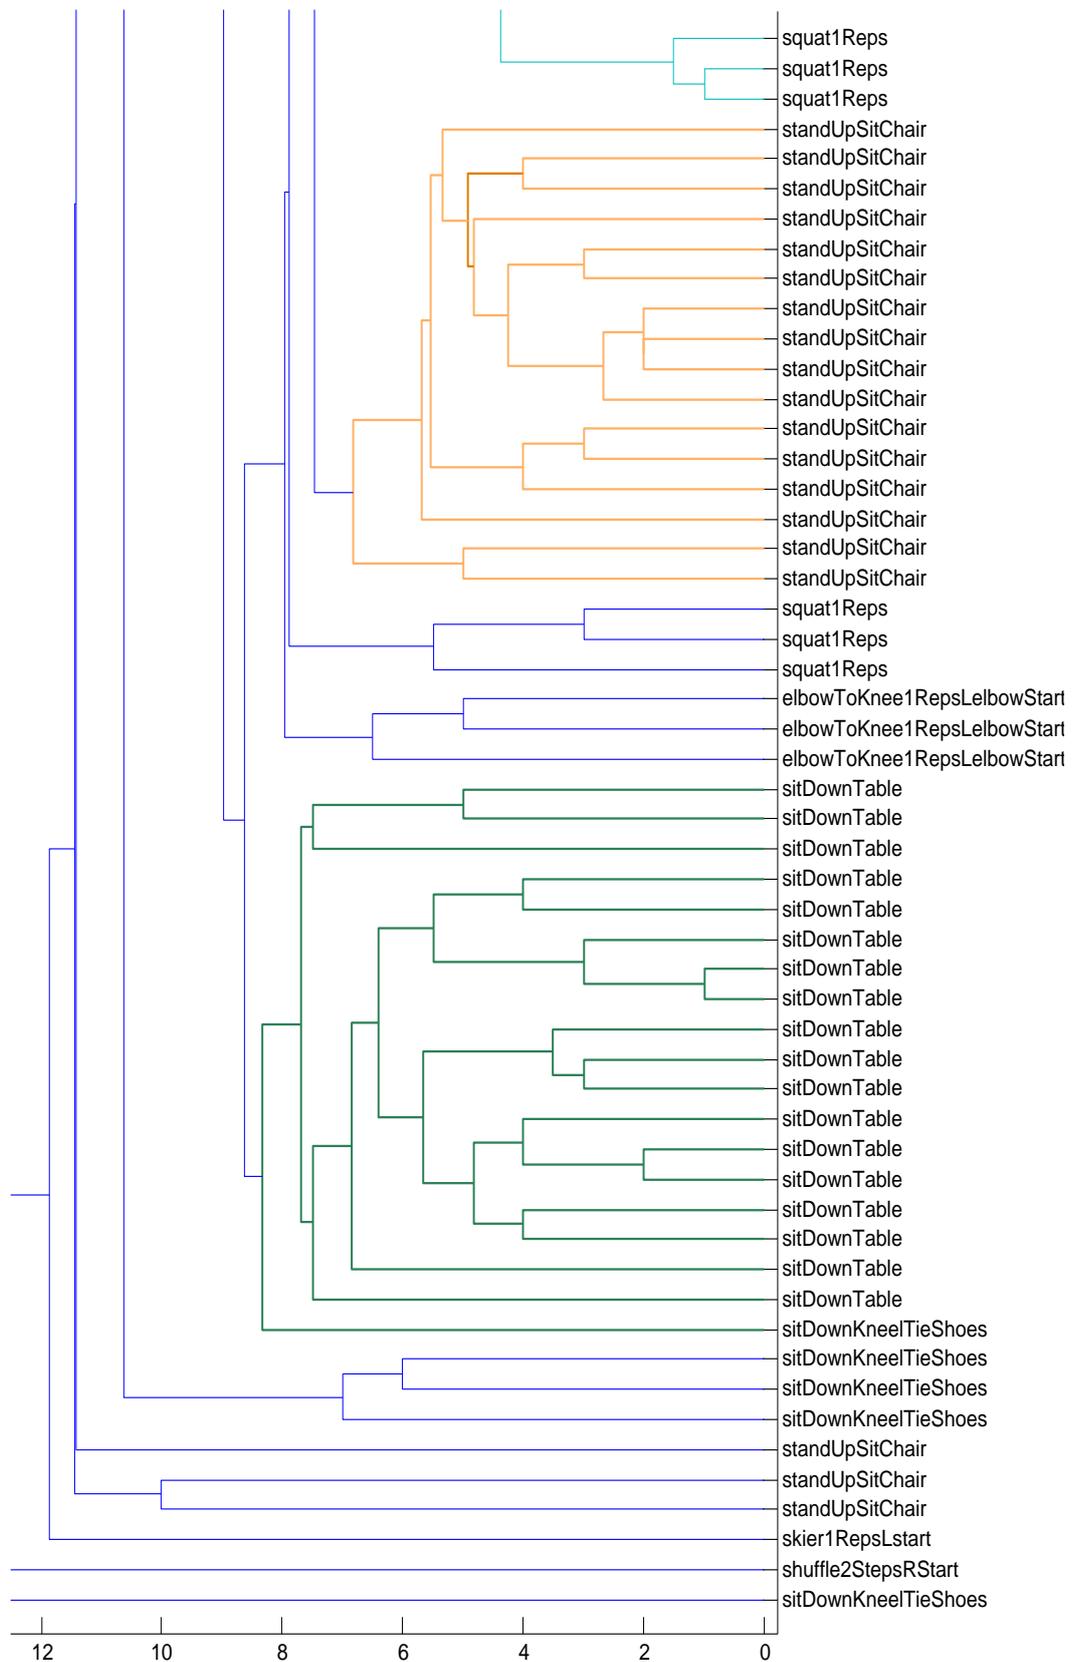
com rótulos das atividades

Figura 23 – Parte central do dendrograma para os 10 movimentos



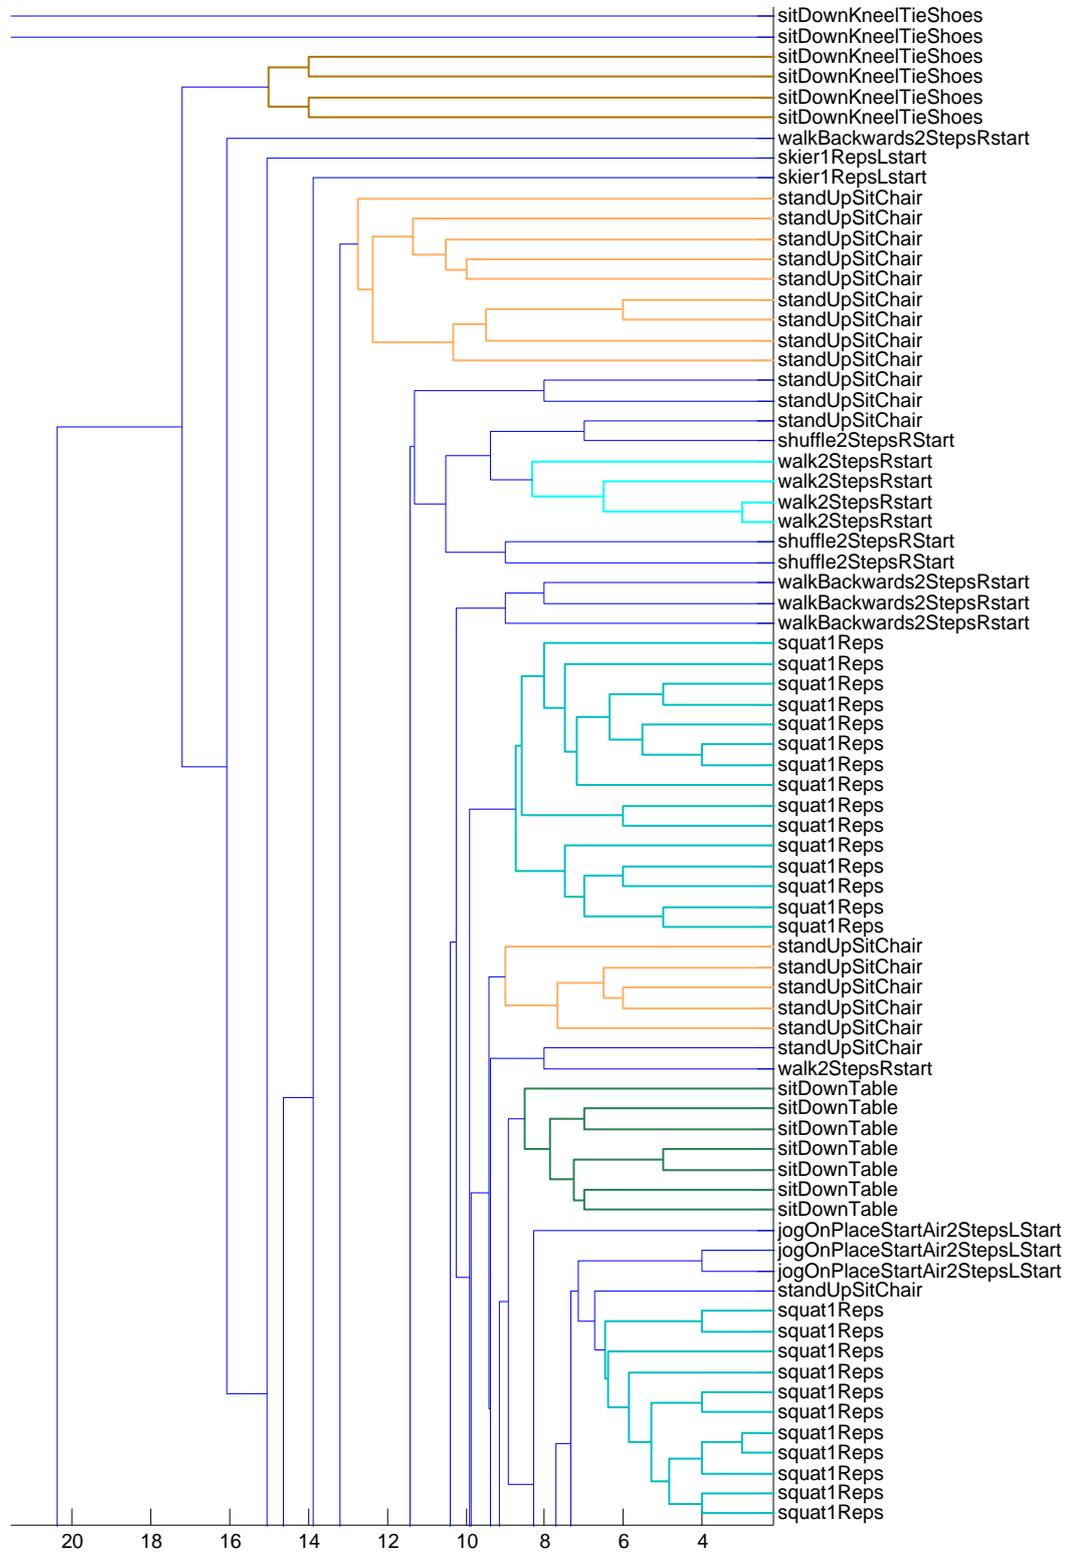
com rótulos das atividades.

Figura 24 – Parte inferior do dendrograma para os 10 movimentos



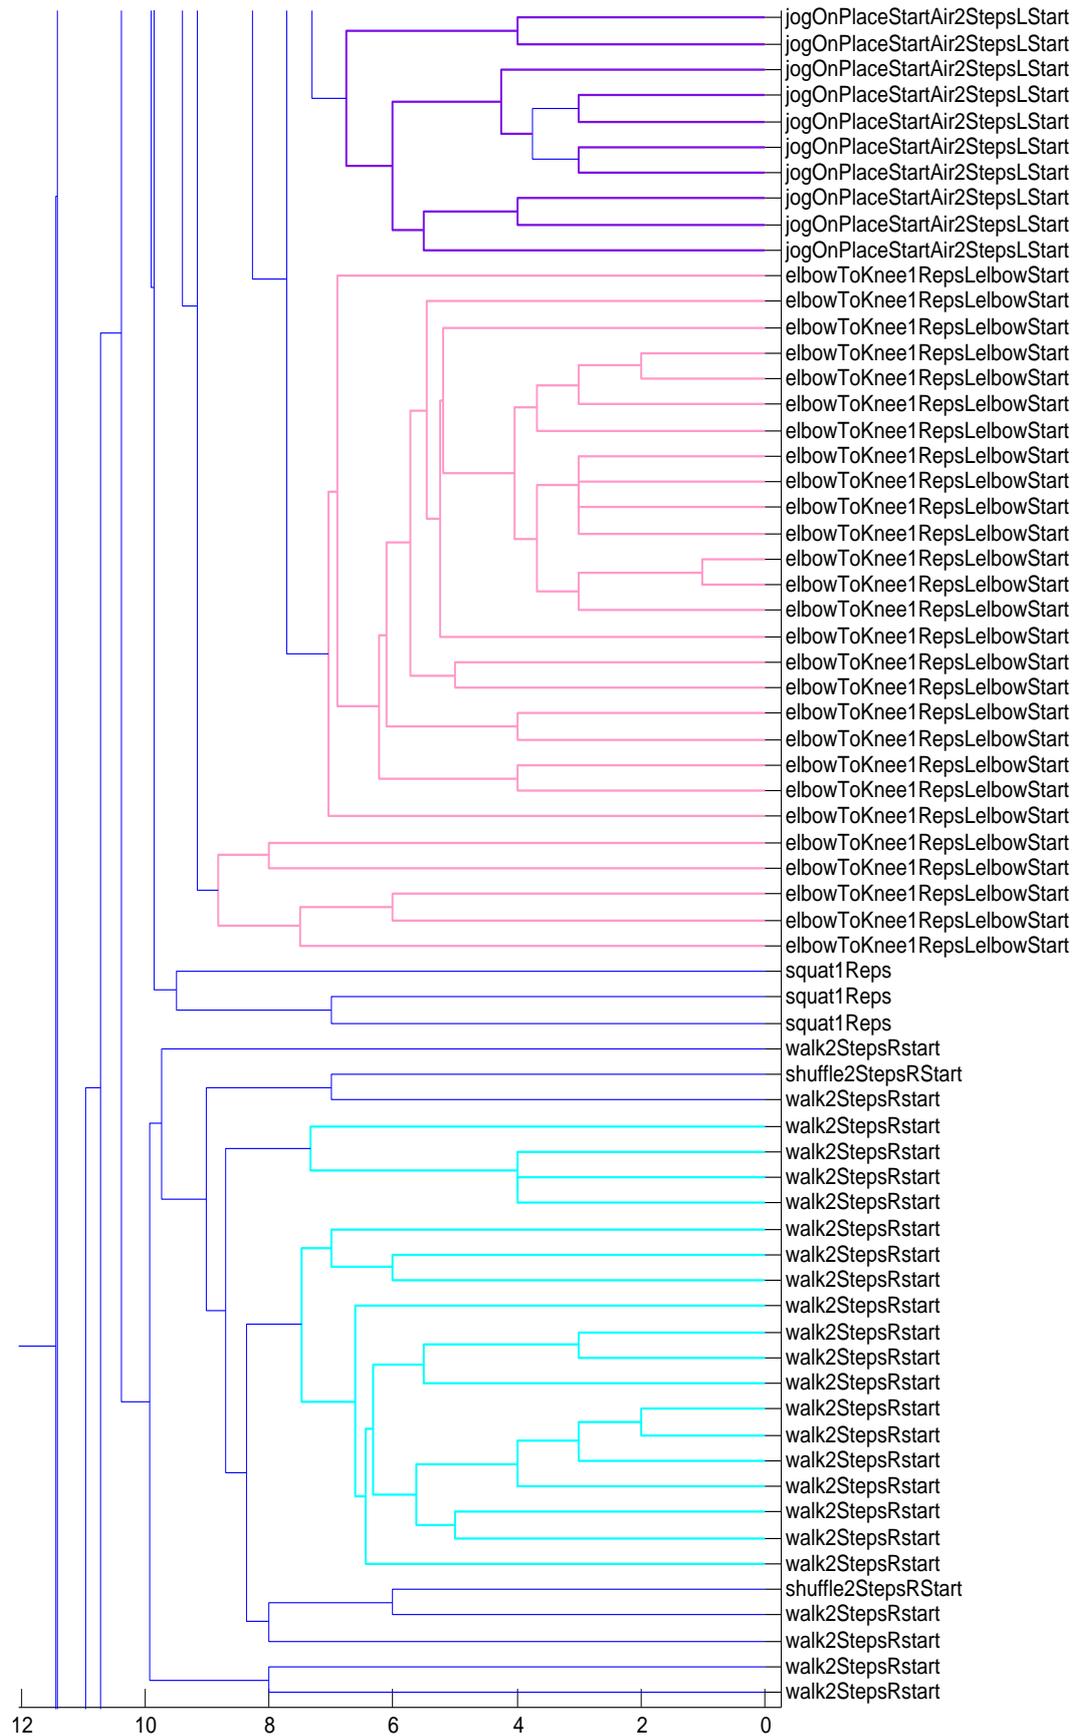
com rótulos das atividades.

Figura 25 – Parte superior do dendrograma para os 10 movimentos



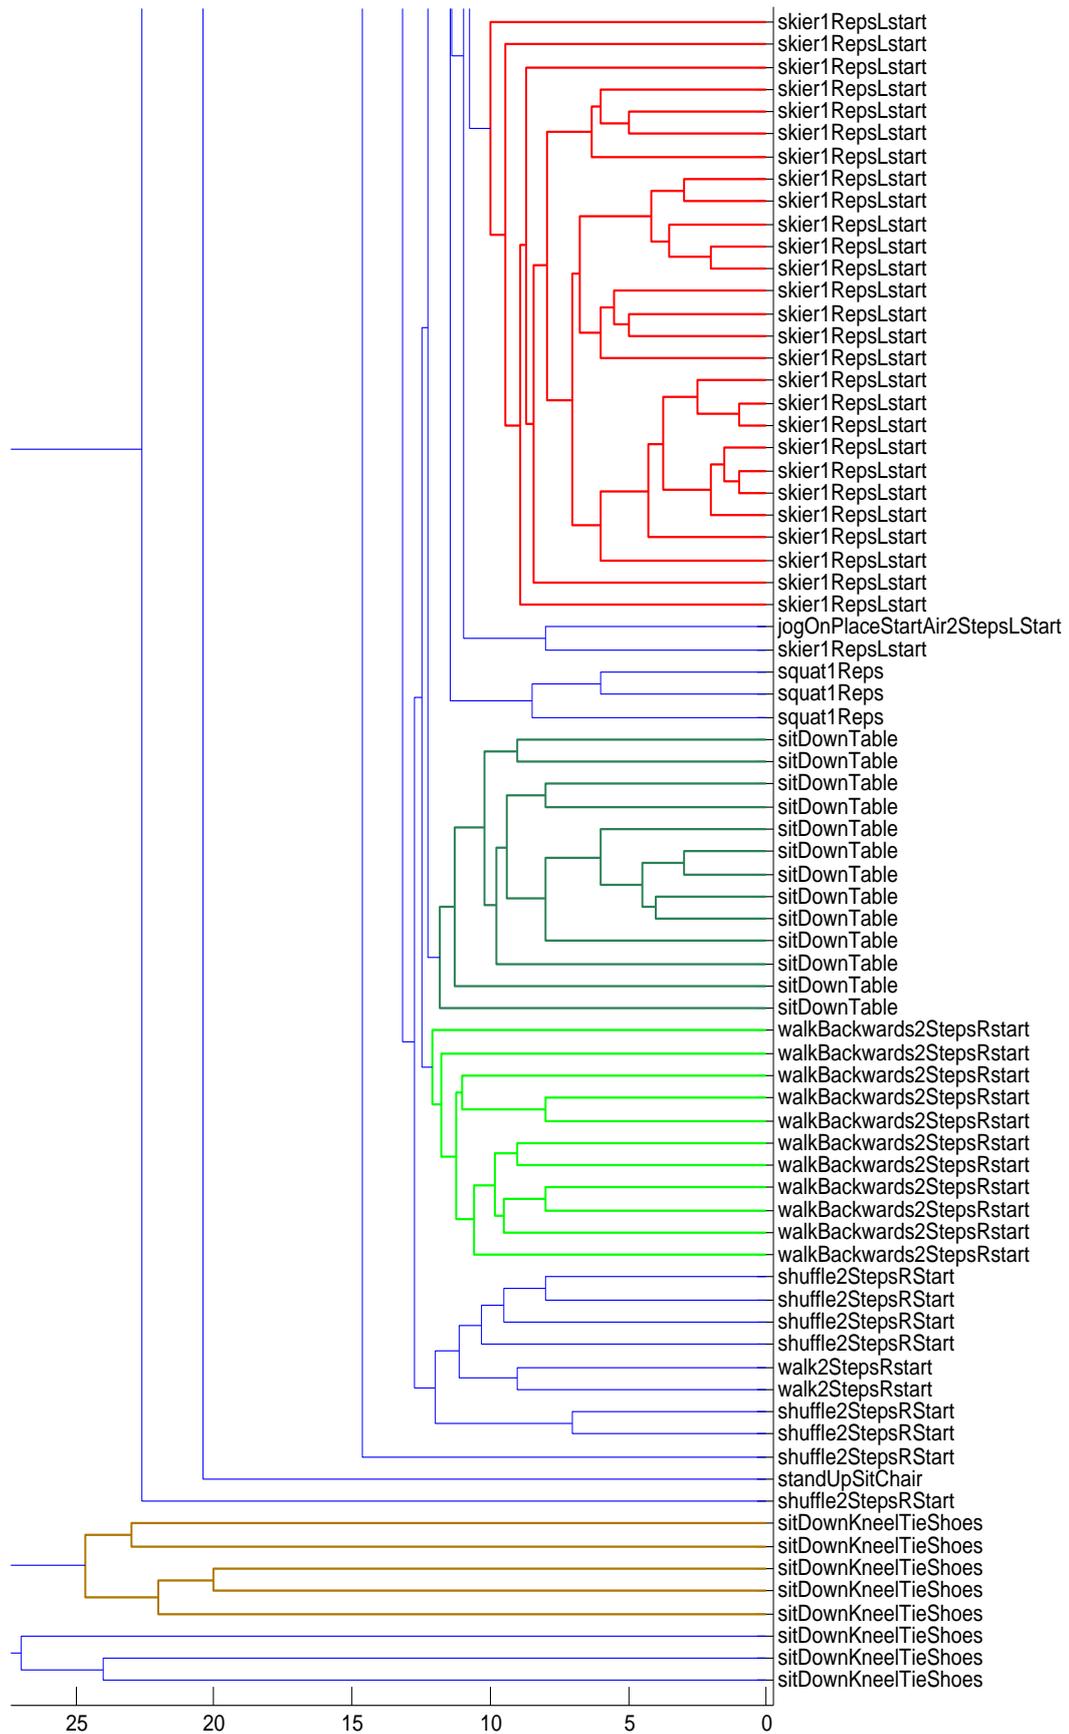
utilizando 4 DOF, com rótulos das atividades.

Figura 26 – Parte central do dendrograma para os 10 movimentos



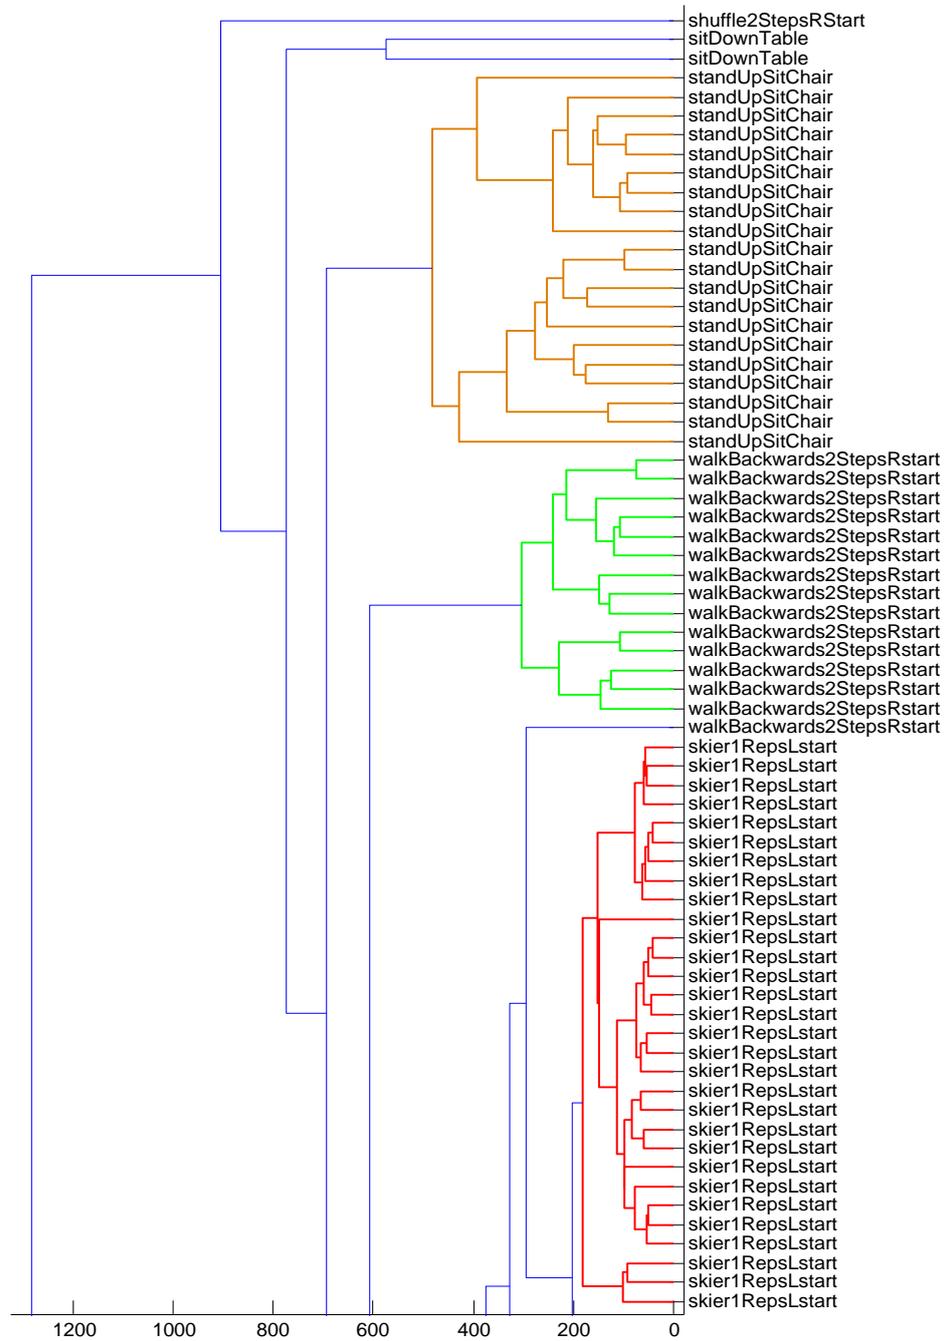
utilizando 4 DOF, com rótulos das atividades.

Figura 27 – Parte inferior do dendrograma para os 10 movimentos



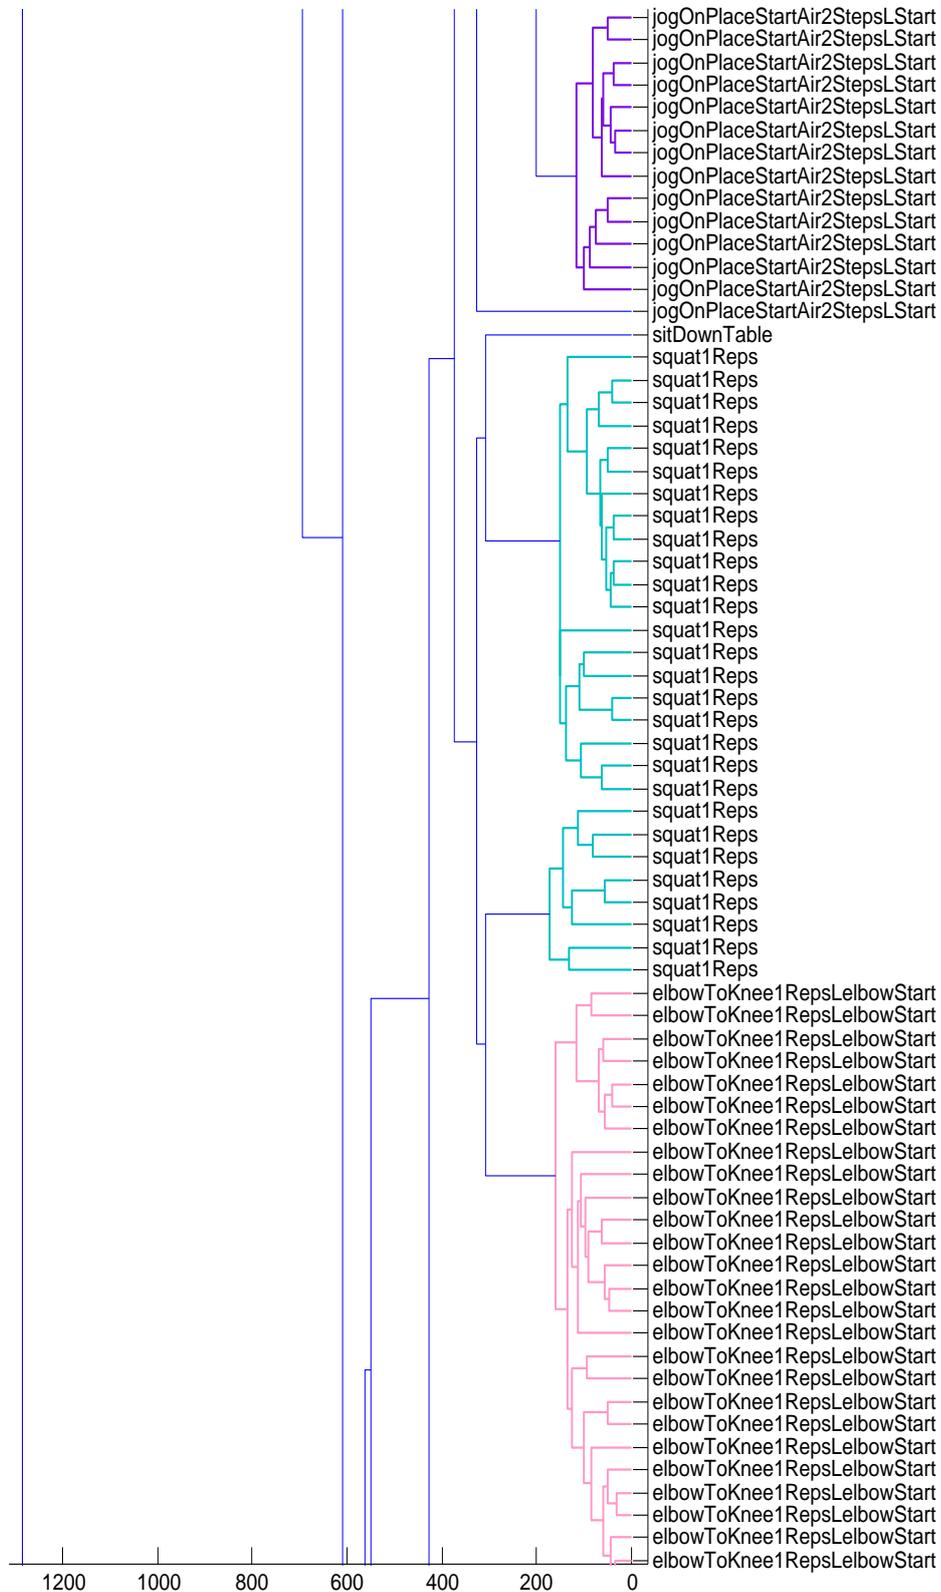
utilizando 4 DOF, com rótulos das atividades.

Figura 28 – Parte superior do dendrograma para os 10 movimentos, a partir da distância MD-DTW



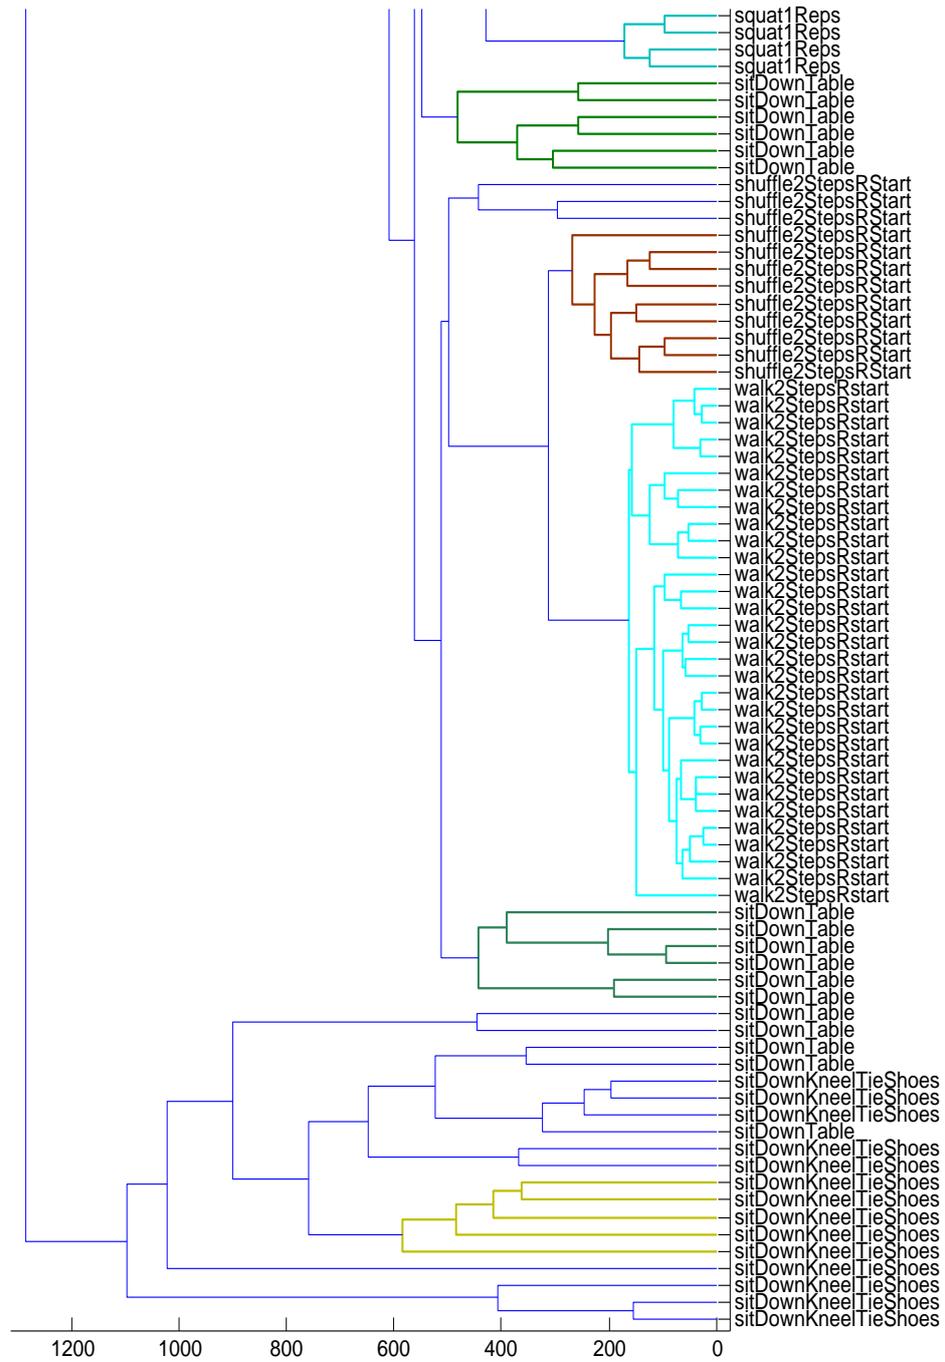
com rótulos das atividades.

Figura 29 – Parte central do dendrograma para os 10 movimentos, a partir da distância MD-DTW



com rótulos das atividades.

Figura 30 – Parte inferior do dendrograma para os 10 movimentos, a partir da distância MD-DTW



com rótulos das atividades.