

UNIVERSIDADE ESTADUAL PAULISTA
Programa de Pós-Graduação em Engenharia Mecânica

**Identificação da passada
de um exoesqueleto utilizando algoritmo
de classificação não supervisionado k-means**

Carlos Eduardo de Oliveira

Bauru
2022

Identificação da passada de um exoesqueleto utilizando algoritmo de classificação não supervisionado k-means

Carlos Eduardo de Oliveira

Dissertação apresentada à Faculdade de Engenharia de Bauru, Programa de Pós-Graduação em Engenharia Mecânica na Área de Projetos Mecânicos, como parte dos requisitos necessários à obtenção de Título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Marcos Silveira

Bauru

2022

O48i

Oliveira, Carlos Eduardo de

Identificação da passada de um exoesqueleto utilizando algoritmo de classificação não supervisionado k-means / Carlos Eduardo de Oliveira. -- Bauru, 2022

123 p. : il.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Faculdade de Engenharia, Bauru

Orientador: Marcos Silveira


1. Exoesqueleto. 2. Identificação de passada. 3. Cluclerização k-means.. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Engenharia, Bauru. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE CARLOS EDUARDO DE OLIVEIRA, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 20 dias do mês de dezembro do ano de 2021, às 14:00 horas, por meio de Videoconferência, realizou-se a defesa de DISSERTAÇÃO DE MESTRADO de CARLOS EDUARDO DE OLIVEIRA, intitulada **IDENTIFICAÇÃO DA PASSADA DE UM EXOESQUELETO UTILIZANDO ALGORITMO DE CLASSIFICAÇÃO NÃO SUPERVISIONADO K-MEANS**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. MARCOS SILVEIRA (Orientador(a) - Participação Virtual) do(a) Departamento de Engenharia Mecânica / Faculdade de Engenharia de Bauru - UNESP, Profa. Dra. MAÍRA MARTINS DA SILVA (Participação Virtual) do(a) Departamento de Engenharia Mecânica / Universidade de São Paulo, Prof. Dr. FABRICIO CESAR LOBATO DE ALMEIDA (Participação Virtual) do(a) Departamento de Engenharia de Biossistemas / Faculdade de Ciências e Engenharia de Tupã - UNESP. Após a exposição pelo mestrando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final: APROVADO _____. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.



Prof. Dr. MARCOS SILVEIRA

Identificação da passada de um exoesqueleto utilizando algoritmo de classificação não supervisionado k-means

Resumo – O objetivo deste trabalho é estudar o comportamento cinemático de um modelo de exoesqueleto de membros inferiores, a fim de identificar padrões de passada utilizando métricas biomecânicas quantitativas. As ferramentas para identificação dos padrões de passada bem como alterações dos padrões provocada por doenças crônicas como diabetes ou uma lesão causada por trauma, só podem ser diagnóstica com uso de sistemas, como por exemplo, acelerometria, videogrametria e exoesqueleto. Este trabalho busca uma forma de identificar os padrões de passada com estrutura exoesqueleto de membros inferiores, principalmente através da identificação de quais variáveis cinemáticas e métricas biomecânicas são mais relevantes nesta identificação. Neste trabalho especificamente, as análises foram realizadas com 18 métricas a partir de variações paramétricas de comprimento de fêmur e tíbia e combinações de trajetória de pé e pelve. Os resultados mostraram que o algoritmo não supervisionado k-means é capaz de realizar identificação precisa, até 100% em alguns casos, desde que uma boa seleção das métricas seja feita. Métodos de redução de dimensão e de seleção de atributos foram utilizados e comparados para realizar esta seleção. Em geral, as métricas relacionadas a trajetória do joelho foram as mais bem-sucedidas na previsão de padrões de passada.

Palavras-chave: exoesqueleto, identificação de passada, clusterização k-means

The gait identification of exoskeleton with unsupervised clustering algorithm k-means

Abstract - The objective of this work is to study the kinematic behavior of a lower limb exoskeleton model, in order to identify gait patterns using quantitative biomechanical metrics. Techniques for identifying gait patterns as well as changes in patterns caused by chronic illnesses such as diabetes or an injury caused by trauma, can only be diagnostic using systems, such as accelerometry, videogrammetry and exoskeleton. This work seeks a way to identify gait patterns with exoskeleton structure of lower limbs, mainly through the identification of which kinematic variables and biomechanical metrics are most relevant in this identification. In this work specifically, the analyzes were performed with 18 metrics from parametric variations of femur and tibia length and combinations of foot and pelvis trajectory. The results showed that the unsupervised k-means algorithm is capable of performing accurate identification, up to 100% in some cases, as long as a good selection of metrics is done. Dimension reduction and attribute selection methods were used and compared to perform this selection. In general, metrics related to knee trajectory were the most successful in predicting gait patterns.

Keywords: exoskeleton, gait identification, k-means clustering

Agradecimentos

Primeiramente gostaria de agradecer a Deus, por me dar sabedoria, perseverança e inspiração para a realização deste sonho.

A minha esposa Eliane pelo carinho, paciência, compreensão e apoio durante todos os momentos difíceis e me fazer acreditar de que seria possível.

A toda minha família, em especial ao meu pai o Sr. Eduardo e a minha mãe Sra. Lourdes, e minhas irmãs Fernanda e Isabel, que sempre me apoiaram nos estudos, nunca deixaram que eu desanimasse dos meus objetivos.

Agradeço ao meu orientador Professor Dr. Marcos Silveira pela confiança, conhecimentos transmitidos, atenção, incentivo e principalmente pelo comprometimento e dedicação, pois sem isto não seria possível realizar esse trabalho.

Aos docentes e membros do grupo de pesquisa NDE, Professor Dr. Paulo José Paupitz Gonçalves, Professor Dr. Fabrício César Lobato de Almeida, com os quais tive o prazer em aprender e que, com compromisso e competência exercem a sua função.

Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) (processo nº: 88882.432821/2019-01) pelo apoio financeiro. Agradeço aos meus companheiros de laboratório: Carolina, Daniel, Massao, Gabriel, Sillas, Gabriella, Diego, Willian, Douglas, Luíza, Matheus, Danilo, Fernando, Pedro e Murilo pela amizade e apoio de cada um de vocês e em especial ao meu amigo Julio Cesar de Moraes Fernandes por toda a ajuda e companheirismo nessa caminhada.

Sumário

Lista de figuras	10
Nomenclatura	16
1 Introdução	20
1.1 Introdução ao problema	20
1.2 Revisão Bibliográfica	21
1.2.1 Métodos de identificação de passada	23
1.2.2 Algoritmo de Clusterização	27
1.2.3 Métodos estatísticos	32
1.2.4 Coeficiente de correlação	35
1.2.5 Variância	37
1.3 Justificativa	37
1.4 Objetivos	38
1.5 Estrutura da Dissertação	38
2 Modelo matemático de exoesqueleto assistivo de membros inferiores	40
2.1 Modelo matemático	40
2.2 Métricas Biomecânicas	45
3 Análise de trajetória do joelho	49
3.1 Critérios da análise da trajetória do joelho	49

3.2	Trajectoria do joelho com dimensões nominais	50
3.3	Variação paramétrica de L_2 e L_3	53
3.4	Sensibilidade das métricas biomecânicas	59
4	Identificação de padrão de passada com k-means	65
4.1	Crerios utilizados no método de classificação de passada	65
4.2	Projeção 2D	66
4.2.1	Clusterização dos padrões de passada	66
4.3	Coefficiente de correlação	73
4.3.1	Clusterização dos padrões de passada	74
4.4	Valor médio	78
4.4.1	Clusterização dos padrões de passada	79
4.5	Desvio Padrão	85
4.5.1	Clusterização dos padrões de passada	85
5	Conclusões	90
6	Publicações	92
	Referências Bibliográficas	93
A	Resultados Complementares	97
A.1	Projeção 2D	97
A.1.1	Clusterização dos padrões de passada	97
A.2	Coefficiente de correlação	113
A.2.1	Clusterização dos padrões de passada	113
A.3	Valor médio	116
A.3.1	Clusterização dos padrões de passada	116
A.4	Desvio Padrão	121
A.4.1	Clusterização dos padrões de passada	121

Lista de Figuras

1.1	(a) Exoesqueleto de membro superior tipo extensivo (Fonte: Luque (2019)) e (b) Exoesqueleto de membro inferior do tipo assistivo (Fonte: Jardim (2009))	23
1.2	Representação esquática de passo e passada (Fonte:Vaughan et al. (1999))	24
1.3	Clusterização com algoritmo k-means (a) $K = 2$; (b) $K = 3$; (c) $K = 4$ modificado (Fonte:James et al. (2013))	28
1.4	Clusterização com algoritmo k-means $K = 3$ modificado (Fonte:James et al. (2013))	31
2.1	(a) Representação do robô bípede de 8 GDL (Fonte: (Bezerra (2002))) e (b) Simplificação planificada do robô bípede de 8 GDL (Fonte: (Bezerra (2002) - modificado)	41
2.2	(a) Modelo exoesqueleto simplificado com identificação dos pontos de articulação, segmentos e principais ângulos de interesse e (b) trajetórias assumidas pelos pontos de articulação B (pé) e D (pelve).	42
2.3	Padrões resultantes da combinação das trajetórias assumidas pelos pontos B e D : (a) P_1 , (b) P_2 , (c) P_3 e (d) P_4	43
2.4	(a) A_C - área abaixo da curva da trajetória do C (joelho); (b) S_1 - com- primento total da trajetória do ponto C ; (c) S_2 - comprimento parcial da trajetória do ponto C ; (d) S_3 comprimento parcial da trajetória do ponto C (joelho).	47

3.1	(a, c, e, g) Trajetórias do ponto B (pé), C (joelho) e D (pelve) para os padrões P_1 – P_4 e (b, d, f, h) os ângulos de interesse b , c e g sendo: a-b com o padrão P_1 , c-d com o padrão P_2 , e-f com o padrão P_3 e g-h com o padrão P_4	52
3.2	(a) Trajetória do ponto C (joelho) e em (b, c, d, e, f) comportamento dos ângulos c , dd , b , γ , β em função de x_B para o padrão P_1	54
3.3	(a) Trajetória do ponto C (joelho) e em (b, c, d, e, f) comportamento dos ângulos c , dd , b , γ , β em função de x_B para o padrão P_2	55
3.4	(a) Trajetória do ponto C (joelho) e em (b, c, d, e, f) comportamento dos ângulos c , dd , b , γ , β em função de x_B para o padrão P_3	57
3.5	(a) Trajetória do ponto C (joelho) e em (b, c, d, e, f) comportamento dos ângulos c , dd , b , γ , β em função de x_B para o padrão P_4	58
3.6	Valores das métricas (a) A_C , (b) S_1 , (c) S_2 , (d) S_3 , (e) $y_{C\max}$, (f) $dd_{\max}$ em função da razão R , para os padrões P_1 (azul), P_2 (vermelho), P_3 (preto), P_4 (lilás).	60
3.7	Valores das métricas (a) $b_{\max}$, (b) $\beta_{\max}$, (c) $x_{C\max}$, (d) $c_{\min}$, (e) $\gamma_{\max}$, (f) Δ_y em função da razão R , para os padrões P_1 (azul), P_2 (vermelho), P_3 (preto), P_4 (lilás).	62
3.8	Valores das métricas (a) Δ_x , (b) $\bar{y}_C$, (c) $\bar{c}$, $\bar{\gamma}$, (d) $\bar{\beta}$, (e) $\bar{x}_C$ em função da razão R , para os padrões P_1 (azul), P_2 (vermelho), P_3 (preto), P_4 (lilás).	64
4.1	Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) A_C e S_1 ; (c-d) $x_{C\max}$ e $\bar{x}_C$ e (e-f) A_C e S_2 . Número de clusters $k = 4$. Círculos são pontos de dados, e ‘x’ é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	68

4.2	Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) S_1 e $c_{\min}$; (c-d) S_2 e $\beta_{\max}$ e (e-f) $y_{C\max}$ e A_C . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	70
4.3	Variância e relação as componentes principais utilizando o método da PCA para um conjunto de 18 métricas.	72
4.4	Imagem com resultado do coeficiente de correlação das 18 métricas em escala de gradiente.	73
4.5	Clusterização com as 18 métricas (esquerda) e com métricas 7 selecionadas por coeficiente de correlação (direita), sendo (a-b) A_C e S_2 ; (c-d) S_2 e $c_{\min}$ e (e-f) $\bar{x}_C$ e $dd_{\max}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	75
4.6	Variância e relação as componentes principais utilizando o método da PCA para um conjunto de 7 métricas selecionadas por correlação.	77
4.7	Valores médios (a) das 18 métricas originais e (b) médios normalizados.	78
4.8	Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por valor médio (direita), sendo (a-b) $dd_{\max}$ e $\beta_{\max}$; (c-d) $\beta_{\max}$ e $c_{\min}$ e (e-f) $b_{\max}$ e $\beta_{\max}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	80
4.9	Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por valor médio normalizado (direita), sendo (a-b) $dd_{\max}$ e $\beta_{\max}$; (c-d) $\beta_{\max}$ e $\bar{y}_C$ e (e-f) $b_{\max}$ e $\beta_{\max}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	82

4.10	Variância e relação as componentes principais utilizando o método da PCA para um conjunto de 5 métricas selecionadas por valores médios (a) e médios normalizados (b).	84
4.11	Valores de desvio padrão para as 18 métricas originais.	85
4.12	Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por desvio padrão (direita), sendo (a-b) $dd_{\max}$ e $b_{\max}$; (c-d) $dd_{\max}$ e $\beta_{\max}$ e (e-f) $\beta_{\max}$ e $\bar{c}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	87
4.13	Variância e relação as componentes principais utilizando o método da PCA para um conjunto de 5 métricas selecionadas por desvio padrão . . .	89
A.1	Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) S_3 e $\beta_{\max}$; (c-d) $y_{C\max}$ e $c_{\min}$ e (e-f) $y_{C\max}$ e $x_{C\max}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	99
A.2	Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) S_1 e $x_{C\max}$; (c-d) $c_{\min}$ e $\gamma_{\min}$ (e-f) S_3 e $\gamma_{\min}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	101
A.3	Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) A_C e $c_{\min}$; (c-d) S_2 e $\bar{c}$ e (e-f) A_C e S_3 . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	103

- A.4 Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) $\bar{x}_C$ e $dd_{\max}$; (c-d) S_2 e $c_{\min}$ e (e-f) $c_{\min}$ e $dd_{\max}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster. 105
- A.5 Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) $dd_{\max}$ e $\beta_{\max}$; (c-d) $\beta_{\max}$ e $c_{\min}$ e (e-f) $b_{\max}$ e $\beta_{\max}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster. 107
- A.6 Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) $\beta_{\max}$ e $\bar{y}_C$; (c-d) $b_{\max}$ e $\bar{y}_C$ e (e-f) $\bar{y}_C$ e $\bar{x}_C$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster. 109
- A.7 Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) $\beta_{\max}$ e $\bar{c}$; (c-d) $\gamma_{\min}$ e $dd_{\max}$ e (e-f) $\gamma_{\min}$ e $\bar{c}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster. 111
- A.8 Clusterização com as 18 métricas (esquerda) e com métricas 7 selecionadas por correlação (direita), sendo (a-b) A_C e S_3 ; (c-d) A_C e $c_{\min}$; (e-f) $c_{\min}$ e $dd_{\max}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster. 114

A.9	Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por média (direita), sendo (a-b) $c_{\min}$ e $dd_{\max}$; (c-d) $dd_{\max}$ e $\beta_{\max}$ e (e-f) $c_{\min}$ e $\bar{\beta}$. Número de clusters $k = 4$. Círculos são pontos de dados, e ‘x’ é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	117
A.10	Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por valor médio normalizada (direita), sendo (a-b) $dd_{\max}$ e $b_{\max}$; (c-d) $b_{\max}$ e $\bar{y}_C$ e (e-f) $\bar{y}_C$ e $\bar{x}_C$. Número de clusters $k = 4$. Círculos são pontos de dados, e ‘x’ é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	119
A.11	Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por média (direita), sendo (a-b) $b_{\max}$ e $\beta_{\max}$; (c-d) $\gamma_{\min}$ e $dd_{\max}$ e (e-f) $\gamma_{\min}$ e $\bar{c}$. Número de clusters $k = 4$. Círculos são pontos de dados, e ‘x’ é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.	122

Lista de Símbolos

Símbolo	Descrição
Letras latinas	
A	Matriz com as 18 métricas utilizadas
A_B	Amplitude da função senoidal B (pé)
A_C	Métrica área abaixo da curva da trajetória do ponto C (joelho)
A_D	Amplitude da função senoidal do ponto D (pelve)
A_n	Matriz com as 18 métricas utilizadas com normalização dos valores
A_{n1}	Matriz com as 2 métricas utilizadas com normalização dos valores
A_{n2}	Matriz com as 7 métricas utilizadas com normalização dos valores coeficiente de correlação
A_3	Matriz com as 5 métricas utilizadas média
A_{n4}	Matriz com as 5 métricas utilizadas média com normalização dos valores
A_{n5}	Matriz com as 5 métricas utilizadas desvio padrão
a	Altura mínima da curva
a_{Dy}	Altura inicial do ponto D (pelve) no eixo y
B	Ponto de articulação que representa o pé
b	Ângulo entre o segmento Z e a tíbia(L_2)
$b_{\max}$	Valor máximo do ângulo b

C	Ponto de articulação que representa o joelho
c	Ângulo interno entre a tíbia(L_2) e o fêmur
$c_{\min}$	Valor mínimo ângulo c
$\bar{c}$	Valor médio do ângulo c
D	Ponto de articulação que representa a pelve
dd	Ângulo entre o segmento Z e o fêmur(L_3)
$dd_{\max}$	Valor máxima do ângulo dd
g	Ângulo entre o segmento Z e o eixo x
K	Número de clusteres
L_2	Comprimento da tíbia
L_{2v}	Vetor de intervalo de comprimento da tíbia
L_3	Comprimento do fêmur
L_{3v}	Vetor de intervalo de comprimentos do fêmur
N	Número de pontos da trajetória
P_1	Padrão de deslocamento 1: B senoidal e D senoidal
P_2	Padrão de deslocamento 2: B senoidal e D constante
P_3	Padrão de deslocamento 3: B elíptico e D senoidal
P_4	Padrão de deslocamento 4: B elíptico e D constante
r	Distância da altura máxima B no eixo y até o foco da trajetória elíptica do ponto B
S_1	Comprimento total da trajetória do ponto C (x_{Ci} até x_{Cf})
S_2	Comprimento parcial da trajetória do ponto C (x_{Cmax} até x_{Cf})
S_3	Comprimento parcial da trajetória do ponto C (x_{Ci} até x_{Cmax})
t_d	Distância percorrida do ponto D (pelve) no eixo x em passo perna direita

t_p	Distância percorrida do ponto B (pé) no eixo x em passo perna direita
X	Distância entre o ponto B e o ponto D no eixo x
x_B	Coordenada do pé (B) no eixo x
x_C	Coordenada do joelho (C) no eixo x
$x_{C\max}$	Valor máximo do ponto C no eixo x
x_{Cf}	Coordenada final do joelho (C) no eixo x
x_{Ci}	Coordenada inicial do joelho (C) no eixo x
$\bar{x}_C$	Métrica valor médio da curva do ponto C no eixo x
Y	Distância entre o ponto B e o ponto D no eixo y
y_B	Coordenada do pé (B) no eixo y
y_C	Coordenada do joelho (C) no eixo y
y_{BE}	Função elíptica do ponto B
y_{BS}	Função senoidal do ponto B
y_C	Coordenado do joelho (C) no eixo y
$y_{C\max}$	Métrica valor máximo do ponto C no eixo y
y_{DC}	Valor constante para altura da pelve
y_{DS}	Função senoidal do ponto D
$\bar{y}_C$	Valor médio da curva do ponto C no eixo y
Z	Segmento entre os pontos B e D
Letras Gregas	
β	Ângulo entre a tíbia(L_2) e o eixo x
$\beta_{\max}$	Métrica valor máximo do ângulo β
$\bar{\beta}$	Métrica médio do ângulo β
γ	Ângulo entre a fêmur e o eixo y
$\gamma_{\min}$	Métrica valor mínimo do ângulo γ
$\bar{\gamma}$	Métrica valor médio do ângulo γ

Δ_x	Métrica diferença entre o máximo e o mínimo da curva do ponto C no eixo x
Δ_y	Métrica diferença entre o máximo e o mínimo da curva do ponto C no eixo y
ϕ	Ângulo de fase
ϕ_D	Ângulo de fase da função senoidal do ponto D
ϕ_B	Ângulo de fase da função senoidal do ponto B
ω	Frequência espacial
ω_B	Frequência espacial da função senoidal do ponto B
ω_D	Frequência espacial da função senoidal do ponto D
Abreviações	
PCA	Análise Componente Principal
GDL	Grau de liberdade

Capítulo 1

Introdução

Este capítulo apresenta uma introdução ao problema que será desenvolvido neste trabalho, uma revisão bibliográfica sobre os tipos e aplicações de exoesqueletos, detalhando os exoesqueletos assistivos de membro inferior, os conceitos para identificação dos padrões de passada e as técnicas utilizadas recentemente nesta identificação. Também são mostrados os principais parâmetros biomecânicos que foram exploradas neste trabalho. O método de clusterização não supervisionado k-means é apresentado com suas características e exemplos de aplicações. Por fim, são apresentados a justificativa, objetivos e a estrutura da dissertação.

1.1 Introdução ao problema

O trabalho analisou o comportamento cinemático de um modelo de exoesqueleto de membros inferiores, a fim de identificar padrões de passada utilizando métricas biomecânicas quantitativas que desenvolveu o estudo da cinemática do corpo humano conforme (Abernethy et al., 2013). Neste contexto, as ferramentas para identificação dos padrões de passada bem como alterações dos padrões provocada por doenças crônicas como diabetes Mathie et al. (2004) onde foram utilizados acelerômetro para identificar as alterações no padrão de marcha ou uma lesão causada por trauma conforme Santos et al.

(2017) que em seu trabalho mostrou a estrutura de exoesqueleto para reabilitação de pessoas com lesão parcial da medula vertebral ou acidente vascular cerebral, só podem ser diagnóstica com uso de sistemas, como por exemplo, acelerometria, videogrametria e exoesqueleto. Este trabalho buscou uma forma de identificar os padrões de passada através da estrutura exoesqueleto de membros inferiores modelada, principalmente através da identificação de quais variáveis cinemáticas e métricas biomecânicas são mais relevantes nesta identificação. Foram realizadas análises de com 18 métricas a partir de variações paramétricas de comprimento de fêmur e tíbia e combinações de trajetória de pé e pelve. Serão utilizados métodos de redução de dimensão e de seleção de atributos foram utilizados e comparados para realizar esta seleção. Analisaremos as métricas que forneceram as melhores classificação dos padrões de passada.

1.2 Revisão Bibliográfica

A pesquisa relacionada a exoesqueleto encontrou aplicações no desenvolvimento de ferramentas e equipamentos para ajudar os seres humanos nas atividades diárias podendo ser para aumento da força, resistência, agilidade ou para reabilitação devido a algum trauma ou doença (Chen et al., 2016). Composto por uma estrutura mecânica, sensores, atuadores e controlador, um exoesqueleto geralmente é um dispositivo vestível e é amplamente utilizado em várias aplicações de engenharia, como por exemplo, para aumentar a resistência e a força dos soldados e auxiliar pacientes em fase de reabilitação que sofreram distúrbios de locomoção (Kumar et al., 2019). Em vista disso, a utilização de exoesqueletos e sua necessidade apresenta um campo de aplicações que se estende por diferentes áreas, e portanto, faz-se necessário o entendimento e o estudo de diferentes aspectos, tipos e conceitos que envolve principalmente os parâmetros biomecânicos dos seres humanos. Os exoesqueletos podem ser divididos em duas categorias, referentes à parte do corpo: membro superior conforme mostrado na figura 1.1-a e membro inferior mostrado na figura 1.1-b (Jardim, 2009). De acordo com sua finalidade, eles podem ser

classificados como assistivos mostrado na figura 1.1-b, destinados a auxiliar na execução de funções perdidas, e extensivos mostrado na figura 1.1-a destinados a aumentar a força do usuário (Pons, 2008). Outra aplicação dos exoesqueletos é ajudar a identificar os padrões de passada humana e alteração nos padrões devido a enfermidade e traumas anteriores. Stancic et al. (2012) utilizaram parâmetros cinemáticos como deslocamentos angulares e velocidades relacionadas à pelve, tornozelo e joelho para identificação da marcha. Um dispositivo mecânico foi utilizado para impor uma limitação do joelho para simular comprometimento. Foi introduzido um fator de passada padrão composto por uma soma ponderada de deslocamentos, velocidades e acelerações, permitindo a identificação de uma maneira mais eficiente do que quando se usa parâmetros cinemáticos isolados.

Bittner et al. (2018) usaram uma abordagem orientada a dados para calcular o gradiente de uma função de custo relacionada a um grande número de parâmetros da marcha. Entre suas contribuições, este método modela os padrões locais de marcha a partir de ruídos das medições, o que é comum ao usar dados de campo de robôs e animais.

Yang et al. (2019) mencionam algumas das mais recentes tecnologias relacionadas à robótica, entre elas, aplicações de exoesqueletos. Por exemplo, Ding et al. (2018b) apresentam um exoesqueleto flexível e ajustável ao corpo do usuário, que oferece novas formas de integração humana semelhantes às roupas. Desta forma, é possível fornecer força e equilíbrio sem perturbar o movimento natural do usuário. O desenvolvimento de novos atuadores e transdutores de força também é importante para a instrumentação desses exoesqueletos. Kotikian et al. (2018) utilizaram atuadores elastoméricos fabricados com tecnologia de impressão 3D de alta temperatura, capazes de exercer mais força do que outros atuadores elastoméricos.

Composto por uma estrutura mecânica, sensores, atuadores e controlador, um exoesqueleto geralmente é um dispositivo vestível e é amplamente utilizado em várias aplicações de engenharia, como por exemplo, para aumentar a resistência e a força dos




Figura 1.1: (a) Exoesqueleto de membro superior tipo extensivo (Fonte: Luque (2019)) e (b) Exoesqueleto de membro inferior do tipo assistivo (Fonte: Jardim (2009))

soldados e auxiliar pacientes em fase de reabilitação que sofreram distúrbios de locomoção (Kumar et al., 2019). Em vista disso, a utilização de exoesqueletos e sua necessidade apresenta um campo de aplicações que se estende por diferentes áreas, e portanto, faz-se necessário o entendimento e o estudo de diferentes aspectos, tipos e conceitos que envolve principalmente os parâmetros biomecânicos dos seres humanos.

1.2.1 Métodos de identificação de passada

A marcha é um movimento cíclico repetindo-se os passos e passadas conforme mostra a figura 1.2. Considera-se passo a distância entre o contato do calcanhar de um pé e o contato do calcanhar do pé oposto com o solo passada e á medida do intervalo entre dois contatos sequenciais do calcanhar do mesmo pé no solo, sendo equivalente a um ciclo de marcha completo (Kutken, 2017).

O reconhecimento automático, a descrição, a classificação e o agrupamento de pa-



Figura 1.2: Representação esquática de passo e passada (Fonte:Vaughan et al. (1999))

drões são problemas importantes em uma variedade de disciplinas científicas e de engenharia, como biologia, psicologia, medicina, marketing, visão computacional, inteligência artificial e sensoriamento remoto (Jain et al., 2000).

O problema de reconhecimento pode ser definido como uma tarefa de classificação ou categorização, onde as classes são definidas pelo projetista do sistema, na classificação supervisionada, ou são aprendidas com base na similaridade de padrões, denominada classificação não supervisionada (Jain et al., 2000).

A maioria dos métodos de reconhecimento de marcha existentes usam silhuetas ou modelos de corpo articulados como características da marcha. Esses métodos sofrem com o desempenho de reconhecimento dificultado ao lidar com variáveis que geram confusão na imagem, como roupas, objetos transportados e ângulo de visão. No trabalho de estrutura do encoder para separar explicitamente ângulos de visão associados a tecnologia de filtros para resultar em imagens de melhor qualidade para análise do padrão de passada o trabalho resultou em sistema capaz identificar o padrões sem influência das roupas que pessoa esteja utilizando e aparência facial conforme Zhang et al. (2019).

Embora muito utilizada, a alta dimensionalidade é um dos problemas recorrentes encontrados na aplicação de técnicas estatísticas para classificação de padrões. Técnicas analíticas ou computacionais determinadas em pequenas dimensões passam a ser de difícil implementação em espaços de 50 ou 100 dimensões (Paolucci, 2006). Portanto, diferentes técnicas podem ser aplicadas com o objetivo de reduzir a dimensionalidade do espaço de características, para possibilitar a solução do problema.

Os métodos de identificação de passada também têm papel importante na reabi-

litação de pacientes com doenças crônicas, como o pé diabético. Rosa et al. (2015) apresentaram metodologias e a modelagem dinâmica para a criação de palmilhas para pacientes com essa doença e concluíram que a modelagem da marcha diabética é uma tarefa desafiadora. Devido ao centro de pressão do pé humano ser deslocado em portadores de diabetes, existe a necessidade de um estudo da marcha do paciente antes da confecção da palmilha.

A acelerometria oferece um método prático e de baixo custo para monitorar objetivamente os movimentos humanos, e tem aplicabilidade particular para o monitoramento de indivíduos em vida livre. Os acelerômetros têm sido usados para monitorar uma série de movimentos diferentes, incluindo marcha, transferências sentar-para-ficar de pé, oscilação postural e quedas. Eles também têm sido usados para medir os níveis de atividade física e para identificar e classificar os movimentos realizados (Mathie et al., 2004).

A videogrametria é uma tecnologia de medição na qual as coordenadas tridimensionais de pontos em um objeto são determinadas por medições feitas em duas ou mais imagens de vídeo obtidas de diferentes ângulos. As imagens podem ser obtidas de duas câmeras que visualizam simultaneamente o objeto ou de imagens sucessivas capturadas pela mesma câmera com a visualização do objeto (Anumba and Wang, 2012).

Bijalwan et al. (2021) em trabalho investigou a biomecânica das articulações de pelve, quadril, joelho e tornozelo usando um microsoft sensor Kinect v2 e uma unidade de medida inercial IMU. A principal contribuição do trabalho foi determinar os ângulos da articulação do joelho e tornozelo para identificação do padrão de passada. O trabalho também validou a abordagem e relação inversamente proporcional do ângulos da articulação do joelho e tornozelo.

Viswakumar et al. (2019) usaram uma nova abordagem da videogrametria que a simples câmera de um celular e um sistema de estimativa de imagem 2D para obter importantes pontos anatômicos. A partir desses pontos de referência, calculamos o ângulo de flexão e extensão do joelho. Analisou os efeitos da iluminação ambiente e do traje do sujeito no ângulo do joelho medido. Também testamos a eficácia de nossa

abordagem comparando os ângulos medidos do joelho com um banco de dados normativo dos padrões de marcha. A técnica mostrou grande tolerância a variação de iluminação ambiente, resultados que concordaram com o padrão de marcha do banco de dados.

A fim de auxiliar os fisioterapeutas durante o processo de reabilitação de indivíduos com alguma deficiência motora, diferentes tipos de exoesqueletos de membros inferiores têm sido desenvolvidos.

Nunes et al. (2018) apresentam um trabalho que tem como objetivo avaliar a influência da estrutura de um novo exoesqueleto modular sobre as características cinéticas e atividades musculares de um sujeito saudável caminhando em uma esteira. Essa análise se dá por meio da relação entre o torque do motor e os pesos para diferentes configurações de marcha, usando como entrada as posições das juntas e as forças de reação do solo. Com base nos resultados obtidos e com o objetivo de elaborar uma forma de atuação sobre o posicionamento dos motores, foi proposta uma estratégia de controle para auxiliar os pacientes com algum tipo de problema motor nos membros inferiores. Os resultados experimentais mostraram que o auxílio do robô proposto com base nas primitivas motoras foi eficiente para recuperar a posição da articulação do joelho, mesmo que o sujeito estivesse utilizando o exoesqueleto.

Para controlar um robô de exoesqueleto, a fase de evento de marcha do robô precisa ser identificada e neste contexto diferentes métodos de detecção de trajetória para um exoesqueleto de extremidade inferior baseado em uma unidade de medição inercial inteligente (UMII) são utilizados.

De acordo com Ding et al. (2018a), um UMII é projetado como um monitor de marcha para realizar de forma independente a amostragem de dados, processamento de dados e transmissão sem fio e também tem boa portabilidade que pode ser facilmente fixado na superfície de um sapato. Além disso, um algoritmo de detecção online pode ser utilizado para detectar os eventos de marcha.

Em seu estudo, Ding et al. (2018a) determinou a precisão e a taxa de detecção do UMII experimentalmente por 10 indivíduos saudáveis caminhando em uma plataforma

de força e esteira. Eventos de marcha foram coletados em uma esteira com várias velocidades de caminhada e os erros médio levados em consideração. Quando aplicado a um robô de exoesqueleto de extremidade inferior, o UMII foi capaz de detectar com sucesso eventos de marcha da caminhada síncrona entre humanos e robôs.

Novos metodos de identificação de passada estão sendo proposta como Jung et al. (2022), que utilizaram método dos ângulos articulares, propondo uma abordagem de aprendizado de máquina para reduzir progressivamente o número de características, ou seja os ângulos articulares. Este o método possa ser usado para outras aplicações além do monitoramento das fases da marcha com aplicação direta para áreas médicas e de tecnologia assistiva.

Em Santos et al. (2017) o trabalho avalia como a utilização do exoesqueleto, os experimentos considerando a interação entre um sujeito saudável e o exoesqueleto são realizados para avaliar a influência da estrutura do exoesqueleto nos perfis cinemáticos e de atividade muscular durante a caminhada.

1.2.2 Algoritmo de Clusterização

A clusterização é uma técnica usada para agrupamento de informações com o maior nível de similaridade conforme um determinado número de grupos (*clusters*). Essa técnica é aplicada em várias áreas do conhecimento como medicina, engenharia e marketing (James et al. (2013); Wu (2012)).

Quando se estuda os métodos de clusterização, existem várias técnicas para agrupamento de informações, no entanto duas técnicas se destacam na clusterização de dados: a clusterização hierárquica e clusterização utilizando o k-means, sendo esta última uma das técnicas mais comuns utilizadas em aprendizado de máquinas (Baumann, 2019).

O algoritmo de clusterização k-means tem a característica de ser não supervisionado, pois não possui restrições na formação dos clusteres. Essa técnica de clusterização é uma abordagem utilizada para particionar um conjunto de dados em K clusters distintos e

não sobrepostos.

Para realizar o agrupamento, é necessário primeiro especificar o número desejado de clusters K , então, o algoritmo k-means atribuirá cada observação a exatamente um dos K clusters (James et al., 2013). A figura 1.3 apresenta os resultados obtidos da realização da clusterização k-means em um exemplo simulado que consiste em 150 observações em duas dimensões, usando três valores diferentes de K .




Figura 1.3: Clusterização com algoritmo k-means (a) $K = 2$; (b) $K = 3$; (c) $K = 4$ modificado (Fonte:James et al. (2013))

O procedimento de clusterização k-means resulta de um problema matemático intuitivo sendo que $C_1, \dots, C_K$ denotam os conjuntos contendo os índices das observações em cada cluster. Esses conjuntos satisfazem duas propriedades:

1. $C_1 \cup C_2 \cup \dots \cup C_K = \{1, \dots, n\}$, o que significa que cada observação pertence a pelo menos um dos K clusters.
2. $C_k \cap C_{k'} = \emptyset$ para todos $k \neq k'$, dessa forma, os clusters não se sobrepõem: nenhuma observação pertence a mais de um cluster

Portanto, se a i -ésima observação está no k -ésimo cluster, então $i \in C_k$. A ideia por trás do k-means é que uma boa clusterização é aquela para a qual a variação dentro do cluster é a menor possível.

A variação dentro do cluster para o cluster C_k é uma medida $W(C_k)$ da quantidade pela qual as observações dentro de um cluster diferem umas das outras. Portanto, o que se quer resolver é um problema de minimização, que é definido como

$$\underset{C_1, \dots, C_K}{\text{minimizar}} \left\{ \sum_{k=1}^K W(C_k) \right\} \quad (1.1)$$

Consequentemente, a equação 1.1 mostra que o objetivo é particionar as observações em K clusters de forma que a variação total dentro do cluster, somada a todos os K clusters, seja a menor possível. Contudo, além da resolução da equação 1.1 é preciso estabelecer a variação dentro do cluster. Existem muitas maneiras possíveis de definir este conceito, e geralmente a escolha mais comum envolve a distância Euclidiana quadrada, que é definida por

$$W(C_k) = \frac{1}{|C_k|} \sum_{i, i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2 \quad (1.2)$$

sendo, $|C_k|$ denota o número de observações no k -ésimo cluster. Dessa forma, a variação dentro do cluster para o k -ésimo cluster é a soma de todas as distâncias Euclidianas

quadradas pareadas entre as observações no k -ésimo cluster, dividido pelo número total de observações no k -ésimo cluster.

Combinando as equações 1.1 e 1.2 é obtido o problema de otimização que define a clusterização k-means, e fica na forma

$$\underset{C_1, \dots, C_K}{\text{minimizar}} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i, i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2 \right\} \quad (1.3)$$

Uma vez definida a clusterização, o próximo passo é encontrar um algoritmo para resolver a equação 1.3, o que significa na prática, particionar as observações em K clusters de forma que o objetivo da equação 1.3 seja minimizado.

Na figura 1.4 mostra como o número de k pode variar e o impacto na separação dos clusteres a medida que variamos o número k . Esse é um problema muito difícil de resolver com precisão, uma vez que existem quase K^n maneiras de particionar n observações em K clusters. Este é um número muito grande, a menos que K e n sejam pequenos. Para isso, existe uma aproximação que fornece um mínimo local, conforme apresentado por James et al. (2013), o algoritmo pode ser descrito da seguinte maneira.

1. Atribuir aleatoriamente um número, de 1 a K , para cada uma das observações.

Eles servem como atribuições iniciais do grupo para as observações.

2. Realizar as iterações até que as atribuições do cluster parem de mudar:

(a) Para cada um dos K clusters, calcule o centroide do cluster. O k -ésimo centroide do cluster é o vetor das médias da função p para as observações no k -ésimo cluster.

(b) Atribuir cada observação ao cluster cujo centroide está mais próximo, sendo que o mais próximo é definido usando a distância Euclidiana.

Portanto, esse algoritmo apresentado garante diminuir o valor do objetivo determinado na equação 1.3 em cada etapa. Portanto, a seguinte identidade pode ser aplicada nesse

caso, e é definida como

$$\frac{1}{|C_k|} \sum_{i,i' \in C_k} \sum_{j=1}^p (x_{ij} - x_{i'j})^2 = 2 \sum_{i \in C_k} \sum_{j=1}^p (x_{ij} - \bar{x}_{kj})^2 \quad (1.4)$$

sendo que $\bar{x}_{kj} = \frac{1}{|C_k|} \sum_{i \in C_k} x_{ij}$ é a média para a função de j no cluster C_k .

Na Etapa 2(a), as médias do cluster são as constantes que minimizam os desvios da soma dos quadrados, e na Etapa 2(b), a realocação das observações são aplicadas para melhorar a resolução da equação 1.4. Isso significa que, à medida que o algoritmo é executado, o agrupamento obtido melhorará continuamente até que o resultado não mude mais. O objetivo definido na equação 1.3 nunca aumentará. Quando o resultado não muda mais, um ótimo local foi alcançado. A figura 1.4 mostra a progressão do algoritmo no exemplo mostrado anteriormente, na figura 1.3.




Figura 1.4: Clusterização com algoritmo k-means $K = 3$ modificado (Fonte:James et al. (2013))

O nome do método de clusterização k-means deriva do fato de que na Etapa 2(a), os centroides do cluster são calculados como a média das observações atribuídas a cada cluster.

Vale ressaltar que, como o algoritmo k-means encontra um ótimo local em vez de global, os resultados obtidos dependerão da atribuição inicial (aleatória) do cluster de cada observação na Etapa 1 do Algoritmo. Por esse motivo, é importante executar o algoritmo várias vezes a partir de diferentes configurações iniciais aleatórias. Em seguida, seleciona-se a melhor solução, ou seja, aquela para a qual o objetivo da equação 1.3 é o menor.

1.2.3 Métodos estatísticos

A análise de componentes principais (PCA) permite resumir e visualizar as informações em um conjunto de dados contendo indivíduos observações descritos por múltiplas variáveis quantitativas correlacionadas. Cada variável pode ser considerada uma dimensão diferente. Se houver mais de 3 variáveis no conjunto de dados, pode ser muito difícil visualizar um hiperespaço multidimensional.

A PCA é utilizada para extrair as informações importantes de uma tabela de dados multivariada e para expressar essas informações como um conjunto de algumas novas variáveis chamadas componentes principais. Essas novas variáveis correspondem a uma combinação linear dos originais. O número de componentes principais é menor ou igual ao número de variáveis originais. As informações em um determinado conjunto de dados correspondem à variação total que ele contém.

O objetivo da PCA é identificar direções (ou componentes principais) ao longo das quais a variação nos dados é máxima. Dessa forma, a PCA reduz a dimensionalidade de dados multivariados para dois ou três componentes principais, que podem ser visualizados graficamente, com perda mínima de informações (Kassambara, 2017).

A análise de componentes principais é demonstrada em detalhes a seguir, conforme

mostrado por (Johnson et al., 2002; Hongyu et al., 2016).

Considerando as variáveis $X_1, X_2, \dots, X_p$ em cada um dos n indivíduos ou unidades experimentais é observado que esse conjunto de $n \times p$ medidas tem origem em uma matriz de dados $\mathbf{X}(n \times p)$ que fica na forma:

$$\mathbf{X} = \begin{bmatrix} x_{11} & \dots & x_{1p} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{np} \end{bmatrix}$$

Contudo, para se obter os componentes principais de uma forma usual, considera-se um conjunto de p variáveis $X_1, X_2, \dots, X_p$ com suas respectivas médias $\mu_1, \mu_2, \dots, \mu_p$ e variância $\sigma_1^2, \sigma_2^2, \sigma_3^2, \dots, \sigma_p^2$. Nesse contexto, estas variáveis não são independentes e possuem covariância entre a i -ésima e k -ésima variável que é definida por σ_{ik} , para $i \neq k = 1, 2, \dots, p$. Portanto, as p variáveis podem ser expressas de forma vetorial, e é dada por: $\mathbf{X} = [X_1, X_2, \dots, X_p]'$, sendo o vetor de médias definidos por $\mu = [\mu_1, \mu_2, \dots, \mu_p]'$. A matriz de covariância é representada por Σ , e fica na forma:

$$\Sigma = \begin{bmatrix} \sigma_{11}^2 & \dots & \sigma_{1p}^2 \\ \vdots & \ddots & \vdots \\ \sigma_{n1}^2 & \dots & \sigma_{np}^2 \end{bmatrix}$$

Consequentemente, são obtidos os pares de autovalores e autovetores $(\lambda, e_1), (\lambda_2, e_2), \dots, (\lambda_p, e_p)$, em que $\lambda_1 \leq \lambda_2 \leq \dots \lambda_p$ estão associados a Σ . Por fim, o i -ésimo componente principal é definido conforme mostrado por Johnson et al. (2002), e fica na forma

$$\begin{aligned} Z_i &= e_i' \mathbf{X} \\ &= e_{i1}X_1 + e_{i2}X_2 + \dots e_{ip}X_p \end{aligned} \tag{1.5}$$

A variável Z_i não é mensurada a partir do experimento ou levantamento amostral, e é denominada variável latente (Johnson et al., 2002). Assim, a finalidade é determiná-la a partir das p variáveis que estão contidas no vetor $\mathbf{X}$. O objetivo principal é projetar os pontos coordenados originais em um plano e maximizar a distância entre eles. Dessa forma, é equivalente a maximizar a variabilidade de Z_i . Portanto, a variância de Z_i é dada por:

$$\begin{aligned} \text{Var}(Z_i) &= \text{Var}(e_i' X) \\ &= e_i' \text{Var}(X) e_i \\ &= e_i' \Sigma e_i \end{aligned} \tag{1.6}$$

sendo que $i = 1, \dots, p$.

De acordo com Hongyu et al. (2016), pode-se utilizar a decomposição espectral da matriz Σ , que é dada por $\Sigma = P\Lambda P'$, sendo que P é a matriz composta pelos autovetores de Σ em suas colunas e Λ , a matriz diagonal de autovalores de Σ , portanto, tem-se que:

$$\begin{aligned} \text{tr}(\Sigma) &= \text{tr}(P\Lambda P') = \text{tr}(\Lambda P'P) = \text{tr}(\Lambda I) \\ &= \text{tr}(\Lambda) = \sum_{i=1}^p \lambda_i \end{aligned} \tag{1.7}$$

e

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_k \end{bmatrix}$$

Note que, $\text{tr}(\Sigma)$ representa a soma dos elementos da diagonal, que fica na forma:

$$\text{tr}(\Sigma) = \sum_{i=1}^p \sigma_{ii} = \sum_{i=1}^p \lambda_i \tag{1.8}$$

Assim sendo, a variabilidade total contida em cada uma das variáveis originais é igual a variabilidade total que está contida nos componentes principais (Johnson et al., 2002). Note também que, a contribuição de cada componente principal (Z_i) é indicada em porcentagem. Contudo, ocorre que individualmente cada componente pode ser calculada, por exemplo, para k -ésimo componente principal. Assim, a proporção de explicação, definida como C_k , é dada por:

$$\begin{aligned} C_k &= \frac{Var(Z_i)}{\sum_{i=1}^p Var(Z_i)} \times 100 \\ &= \frac{\lambda_i}{\sum_{i=1}^p \lambda_i} \times 100 \\ &= \frac{\lambda_i}{tr(S)} \times 100 \end{aligned} \tag{1.9}$$

Através da proporção de explicação da variância total, que o modelo de k componentes principais é responsável, é possível determinar o número de componentes que deve-se reter. Na maioria dos casos, são adotados modelos que expliquem pelos menos 80% da variação total (Johnson et al., 2002).

Em casos gerais, escolhe-se o primeiro componente principal, que é o de maior importância, como sendo o que apresenta maior variância e que explique o máximo de variabilidade dos dados. O segundo componente de maior importância, o que apresenta a segunda maior variância e assim sucessivamente, até o componente principal de menor importância (Manly and Alberto, 2016). Por outro lado, os últimos componentes principais serão responsáveis por direções que não estão associadas a muita variabilidade. Em outras palavras, esses últimos componentes principais identificarão relações lineares entre as variáveis originais próximo de constante (Johnson et al., 2002; Anderson, 2003).

1.2.4 Coeficiente de correlação

O coeficiente de correlação é um parâmetro que mede a interdependência entre duas variáveis aleatórias (Pinheiro et al., 2013). Seja (X, Y) uma variável aleatória bidi-

mensional. Levando em consideração que $E(X) = \mu_X$ e $E(Y) = \mu_Y$ existem e que $DP(X) = \sigma_X$ e $DP(Y) = \sigma_Y$ são finitos e não nulos. O coeficiente de correlação entre X e Y , que são denotados por $\rho(X, Y)$, é definido como

$$\rho(X, Y) = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{DP(X)DP(Y)} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \quad (1.10)$$

Por convenção, quanto às variáveis envolvidas pode-se denotar o coeficiente de correlação simplesmente por ρ , e suas propriedades são definidas como:

1. O coeficiente de correlação é adimensional.
2. Pode-se demonstrar que $-1 \leq \rho \leq 1$.
3. Se X e Y são v.a.s independentes, $\rho(X, Y) = 0$.
4. Se X e Y são duas variáveis aleatórias tais que $Y = aX + b$, a e b constantes reais, $a \neq 0$, então

$$\rho(X, Y) = 1, \text{ se e somente se } a > 0 \text{ e}$$

$$\rho(X, Y) = -1, \text{ se e somente se } a < 0.$$

O resultado anterior mostra que o coeficiente de correlação é uma medida do grau de linearidade da relação entre as variáveis aleatórias X e Y . Quanto mais próximo ρ estiver de $+1$ ou de -1 , maior será esse grau de linearidade. Além disso, $\rho > 1$ indica que há uma tendência de que X e Y cresçam conjuntamente, enquanto que um valor $\rho < 0$ sinaliza para uma tendência de Y decrescer à medida que X aumenta. É importante salientar também que um valor de ρ próximo de zero não significa necessariamente a ausência de uma relação entre X e Y . Esse fato indica apenas que a relação, se existir, não é linear. Isso porque, como mostrado anteriormente, $\text{Cov}(X, Y) = 0$ não implica independência entre X e Y .

1.2.5 Variância

Em análises estatísticas, o simples conhecimento da média de uma variável aleatória X , em geral, não é suficiente para se ter uma ideia clara da distribuição de X (Pinheiro et al., 2013). Existe assim uma necessidade de se ter uma medida adicional que permita quantificar o grau de dispersão dos valores de X . Um das medidas de dispersão mais frequentemente empregadas é a variância. Se X é uma variável aleatória discreta que assume os valores $x_1, x_2, x_3, \dots$ com probabilidades $p(x_1), p(x_2), p(x_3), \dots$ respectivamente, e se $E(X)$ é finito, então sua variância é calculada por:

$$\text{Var}(X) = \sum_{i=1}^{\infty} (x_i - E(X))^2 p(x_i) \quad (1.11)$$

sendo que neste caso aceita-se que $\text{Var}(X)$ existe e é finita se a série da direita for convergente.

Portanto, observa-se que a variância é a média ponderada dos quadrados das diferenças entre cada valor da variável e a sua esperança, sendo que o correspondente peso é novamente igual à probabilidade de que a variável assumira esse valor.

1.3 Justificativa

As ferramentas para identificação dos padrões de passada bem como alterações dos padrões provocada por doenças crônicas como diabetes ou uma lesão causada por trauma, só podem ser diagnóstica com uso de sistemas, como por exemplo, de câmeras que fazem captura da imagem para identificação destes padrões. Contudo, para realizar essas análises é necessário que haja uma grande quantidade de pacientes e que todos sejam submetidos aos testes de caminhada para captura das imagens, o que torna a identificação dos padrões bastante trabalhosa.

Dessa forma, este trabalho apresenta a modelagem biomecânica de um exoesqueleto de membro inferior para identificar os padrões de passada a fim de minimizar os esforços

exigidos pelos pacientes. Além disso, o estudo da identificação desses padrões possui aplicações importantes em relação à saúde, onde através da identificação da marcha de um indivíduo é possível, por exemplo, revelar possíveis anomalias posturais.

Como forma de maximizar a identificação das passadas com resultados satisfatórios na modelagem, ferramentas estatísticas e de aprendizagem de máquina são utilizadas como forma de verificar quais variáveis cinemáticas e métricas biomecânicas são mais relevantes.

1.4 Objetivos

O objetivo deste trabalho é estudar o comportamento cinemático de uma estrutura do tipo exoesqueleto assistivo de membros inferiores, de forma a identificar padrões de passada. Este objetivo será dividido em três partes:

1. Modelagem matemática de uma estrutura tipo exoesqueleto, estabelecendo a influência de parâmetros cinemáticos;
2. Identificar padrões de passada, com base em métricas quantitativas biomecânicas, relacionando passadas conhecidas com parâmetros do modelo;

1.5 Estrutura da Dissertação

Este trabalho está estruturado da seguinte maneira: o capítulo 1 apresenta revisão bibliográfica as justificativas e os objetivos do trabalho. No capítulo 2, a modelagem matemática do exoesqueleto assistivo de membros inferiores, as variações biomecânicas e metodologia do trabalho. No capítulo 3, é apresentada a análise da trajetória dos joelhos para os padrões adotados, os resultados da variação biomecânica dos comprimentos do fêmur e tíbia assim como a determinação das métricas biomecânicas utilizadas. O capítulo 4 apresenta a análise dos resultados obtidos através da utilização k-means e

utilização de técnicas estatísticas para redução números de métricas biomecânicas e melhora da eficácia na clusterização dos padrões. Já o capítulo 5 apresenta as conclusões finais.

Capítulo 2

Modelo matemático de exoesqueleto assistivo de membros inferiores

Este capítulo apresenta o modelo simplificado de exoesqueleto assistivo de membros inferiores utilizado neste trabalho. Também apresenta os parâmetros e métricas biomecânicas quantitativas, relacionando-as com as variáveis cinemáticas.

2.1 Modelo matemático

O modelo do exoesqueleto utilizado neste trabalho é baseado em uma estrutura de exoesqueleto assistivo de membro inferior como a figura 2.1. A figura 2.1-a apresenta o modelo de robô bípede de 8 GDL utilizado por Bezerra (2002). Sendo na figura 2.1-b os pontos de articulação de interesse são o pé (ponto B), joelho (C) e pelve (D) mostrados em uma projeção 2D onde são bem identificados.

O modelo utilizado neste trabalho é uma simplificação do modelo utilizado por Bezerra (2002), e é mostrado na figura 2.2-a. Este modelo é denominado como modelo simplificado de exoesqueleto, no qual L_2 é o comprimento da tíbia e L_3 o comprimento do fêmur. A denominação dos pontos de interesse segue o mesmo mostrado anteriormente: pé (B), joelho (C) e pelve (D). Também são mostrados os demais ângulos de




Figura 2.1: (a) Representação do robô bípede de 8 GDL (Fonte: (Bezerra (2002))) e (b) Simplificação planificada do robô bípede de 8 GDL (Fonte: (Bezerra (2002) - modificado))

interesse. De acordo com estudos ergonômicos, os pontos B e D podem assumir diferentes trajetórias, como senoidal, elíptica e com amplitude constante, conforme mostra a figura 2.2-b. O modelo matemático também segue o apresentado por Bezerra (2002), com a diferença que neste trabalho $L_2 \neq L_3$. A trajetória senoidal assumida pelo ponto B pode ser descrita por:

$$y_{BS} = A_B \sin((\omega_B x_B) + \phi_B) \quad (2.1)$$

na qual A_B é a amplitude, ω_B é a frequência espacial, x_B é o deslocamento do ponto B no eixo x e ϕ_B é o ângulo de fase. Onde x_B é o deslocamento do ponto B no eixo x e está compreendido no intervalo $[0, t_p]$, sendo que $t_p = 0.1$ m. A trajetória elíptica do ponto B pode ser descrita por:

$$y_{BE} = A_B \sqrt{1 - \left(\frac{x_B^2}{r^2} \right)} \quad (2.2)$$




Figura 2.2: (a) Modelo exoesqueleto simplificado com identificação dos pontos de articulação, segmentos e principais ângulos de interesse e (b) trajetórias assumidas pelos pontos de articulação B (pé) e D (pelve).

na qual A_B é a altura máxima da elipse e r é a distância a altura máxima B no eixo y até o foco da trajetória elíptica do ponto B . Onde x_B é o deslocamento do ponto B no eixo x e está compreendido no intervalo $[0, t_p]$, sendo que $t_p = 0.1$ m.

A trajetória senoidal do ponto D pode ser descrita por:

$$y_{DS} = A_D \sin((\omega_D x_D) + \phi_D) + a_{Dy} \quad (2.3)$$

na qual A_D é a amplitude, ω_D é a frequência espacial, x_D é o deslocamento do ponto B no eixo x , ϕ_D é o ângulo de fase e a_{Dy} é a distância inicial da curva em relação ao eixo y . Para trajetória com amplitude constante do ponto D ao longo da passada, a equação 2.3 é utilizada com $A_D = 0$. Sendo x_D é o deslocamento do ponto D no eixo x e está compreendido no intervalo $[0, t_d]$, sendo que $t_d = 0.05$ m.

A partir dos 4 tipos de trajetórias assumidas pelos pontos B e D são definidos quatro padrões resultantes da combinação entre os pontos e são denominados P_1 , P_2 , P_3 e P_4 , definidos da seguinte forma: para o padrão P_1 (figura 2.3-a) o ponto B descreve trajetória senoidal e o ponto D trajetória senoidal; no padrão P_2 (figura 2.3-b) o ponto

B possui trajetória senoidal e o ponto D trajetória com amplitude constante; para o padrão P_3 (figura 2.3-c) o ponto B descreve trajetória elíptica e o ponto D trajetória senoidal; no padrão P_4 (figura 2.3-d) o ponto B assume trajetória elíptica e o ponto D descreve trajetória com amplitude constante. A figura 2.3 apresenta os 4 tipos de padrões considerados nesse trabalho.




Figura 2.3: Padrões resultantes da combinação das trajetórias assumidas pelos pontos B e D : (a) P_1 , (b) P_2 , (c) P_3 e (d) P_4 .

Os ângulos de interesse (c , b , dd , g , γ , β) e o segmento Z mostrados na figura 2.2-a são definidos a fim de se calcular a trajetória do ponto C e posteriormente definir as métricas que serão utilizadas no processo de clusterização. Para determinação desses ângulos, são determinadas as distâncias absolutas entre os pontos B e D em relação aos eixos x e y , dadas por:

$$\begin{aligned} X &= x_B - x_D \\ Y &= y_D - y_B \end{aligned} \tag{2.4}$$

Por relações trigonométricas de triângulo retângulo, o segmento Z é dado por:

$$Z = \sqrt{X^2 + Y^2} \tag{2.5}$$

Utilizando a lei dos cossenos é possível calcular os ângulos internos c , dd e b . O ângulo c , formado na parte interna entre a tíbia e o fêmur é dado por:

$$c = \arccos \left(\frac{-Z^2 + L_2^2 + L_3^2}{2L_2 L_3} \right) \quad (2.6)$$

O ângulo dd , formado entre o segmento Z e o fêmur, é dado por:

$$dd = \arccos \left(\frac{-L_2^2 + Z^2 + L_3^2}{2Z L_3} \right) \quad (2.7)$$

O ângulo b é obtido através da somatória dos ângulos internos do triângulo BCD , e é dado por:

$$b = \pi - c - dd \quad (2.8)$$

O ângulo g , formado entre o segmento Z e o eixo x , é dado por:

$$g = \arccos \left(\frac{x_B - x_D}{Z} \right) \quad (2.9)$$

O ângulo γ , formado entre o eixo x e o fêmur (L_3), é dado por:

$$\gamma = g - dd \quad (2.10)$$

Por fim, o ângulo β , formado entre a tíbia (L_2) e o eixo x , é dado por:

$$\beta = b + g \quad (2.11)$$

Uma vez determinados todos os ângulos de interesse é possível se obter as compo-

nentes da posição do ponto C nos eixos x e y , dadas por:

$$\begin{aligned}x_C &= x_B + L_2 \cos(\pi - g - b) \\y_C &= y_B + L_2 \sin(\pi - g - b)\end{aligned}\tag{2.12}$$

2.2 Métricas Biomecânicas

As métricas biomecânicas utilizadas neste trabalho são obtidas a partir das variáveis cinemáticas do modelo simplificado de exoesqueleto e são dependentes dos padrões adotados P_1 , P_2 , P_3 e P_4 .

A métrica A_C é obtida através do cálculo da área abaixo da curva de trajetória do ponto C (joelho) e é dada por:

$$A_C = \int_{x_{Ci}}^{x_{Cf}} C(x_C, y_C) dx \tag{2.13}$$

A métrica S é definida pelo comprimento da trajetória do ponto C e é subdividida em três métricas distintas S_1 , S_2 e S_3 , sendo S_1 o comprimento total da curva de trajetória do ponto C do ponto x_{Ci} até x_{Cf} ; S_2 o comprimento do ponto x_{Cmax} até o ponto x_{Cf} ; S_3 é o comprimento do ponto x_{Ci} até x_{Cmax} . Estas métricas são dadas de forma geral por:

$$S = \sum_{n=1}^{N-1} \sqrt{\Delta x_{C,n}^2 + \Delta y_{C,n}^2} \tag{2.14}$$

na qual $\Delta x_{C,n}$ e $\Delta y_{C,n}$ são as componentes nas direções x e y da distância entre pontos consecutivos na trajetória do ponto C , e N é o número de pontos nos segmentos de interesse.

A métrica Δ_y é a diferença entre o valor máximo e mínimo da trajetória do ponto C

em relação ao eixo y e é dada por:

$$\Delta_y = y_{C\max} - y_{C\min} \quad (2.15)$$

Da mesma forma, Δ_x corresponde à diferença entre o valor máximo e mínimo da trajetória do ponto C em relação ao eixo x e é dada por:

$$\Delta_x = x_{C\max} - x_{C\min} \quad (2.16)$$

A métrica $\bar{y}_C$ mede o deslocamento médio do ponto C em relação ao eixo y e é dada por:

$$\bar{y}_C = \frac{\sum y_C}{N} \quad (2.17)$$

na qual N é número de pontos na trajetória.

A métrica $\bar{x}_C$ mede o deslocamento médio do ponto C em relação ao eixo x e é dada por:

$$\bar{x}_C = \frac{\sum x_C}{N} \quad (2.18)$$

A figura 2.4 mostra um exemplo de trajetória do ponto C e ilustra as métricas A_C , S_1 , S_2 e S_3 .




Figura 2.4: (a) A_C - área abaixo da curva da trajetória do C (joelho); (b) S_1 - comprimento total da trajetória do ponto C ; (c) S_2 - comprimento parcial da trajetória do ponto C ; (d) S_3 comprimento parcial da trajetória do ponto C (joelho).

Além disso, os valores máximos foram aplicados também aos ângulos dd , b e β . Os valores mínimos foram aplicados aos ângulos c e γ . Portanto, o conjunto das 18 métricas definidas aqui e que serão analisadas posteriormente são listadas na tabela 2.1.

Tabela 2.1: Métricas Biomecânicas

Símbolos	Métricas
(A_C)	Área abaixo da curva da trajetória do C (joelho)
(S_1)	Comprimento total da trajetória do ponto C (joelho)
(S_2)	Comprimento parcial inicial da trajetória do ponto C (joelho)
(S_3)	Comprimento parcial final da trajetória do ponto C (joelho)
$(y_{C\max})$	Valor máximo do ponto C no eixo y
$(dd_{\max})$	Valor máximo do ângulo dd
$(b_{\max})$	Valor máximo do ângulo b
$(\beta_{\max})$	Valor máximo do ângulo β
$(x_{C\max})$	Valor máximo do ponto C no eixo y
$(c_{\min})$	Valor mínimo ângulo c
$(\gamma_{\min})$	Valor mínimo ângulo γ
(Δ_y)	Diferença entre o máximo e o mínimo da curva do ponto C no eixo y
(Δ_x)	Diferença entre o máximo e o mínimo da curva do ponto C no eixo x
$(\bar{y}_C)$	Valor médio da curva do ponto C no eixo y
$(\bar{c})$	Valor médio do ângulo c
$(\bar{\gamma})$	Valor médio do ângulo γ
$(\bar{\beta})$	Valor médio do ângulo β
$(\bar{x}_C)$	Valor médio da curva do ponto C no eixo x

Capítulo 3

Análise de trajetória do joelho

Neste capítulo são mostradas análises das trajetórias do joelho (ponto C) do modelo de exoesqueleto simplificado para os 4 padrões de trajetórias de pé e pelve (P_1 – P_4). Para cada padrão, foi feita uma análise de sensibilidade da relação entre comprimento da tíbia e do fêmur. As métricas biomecânicas definidas no capítulo anterior são utilizadas para uma análise quantitativa.

3.1 Critérios da análise da trajetória do joelho

Os parâmetros utilizados são baseados em um robô bípede conforme modelo apresentado por Bezerra (2002). Para todas as análises apresentadas, é considerado um tamanho fixo da passada $t_p = 0.1$ m. A amplitude da curva senoidal do ponto B é $A_B = 0.025$ m. O ponto D percorre $t_d = 0.05$ m a cada passada, e quando uma trajetória senoidal é considerada, sua amplitude é $A_D = 0.009$ m. O ponto D apresenta uma trajetória com uma defasagem em relação a origem tanto no eixo x quanto no eixo y , sendo essas dimensões $a_{Dx} = 0.00255$ m e $a_{Dy} = 0.3995$ m. Para todas as trajetórias calculadas, $N = 201$ pontos são considerados.

O comprimento nominal da tíbia (L_2) e do fêmur (L_3) são $L_2 = L_3 = 0.19107$ m. Porém, a fim de se investigar a influência da variação nos comprimentos L_2 e L_3

nos padrões de passada, uma variação destes comprimentos é adotada. Dessa forma, é conveniente definir uma razão de comprimento R :

$$R = \frac{L_3}{L_2} \quad (3.1)$$

Foram utilizados 21 valores de L_2 e L_3 , com valores limites escolhidos a partir de variação de 25% para mais e para menos do valor nominal, resultando em R de 0.60 a 1.67.

3.2 Trajetória do joelho com dimensões nominais

Nesta seção são apresentadas o comportamento das trajetórias do ponto C (joelho) para os 4 padrões definidos para trajetória de pelve e pé (P_1 – P_4).

A figura 3.1 mostra as trajetórias de pé (B), joelho (C) e pelve (D), e ângulos b , c , e g . A figura 3.1-a mostra B , C e D para o padrão P_1 , e percebe-se que a elevação máxima do joelho ocorre próxima a metade da passada. A figura 3.1-b mostra que o ângulo de abertura do joelho (c) possui dois pontos mínimos, próximos a 25 % e 75 % da passada, enquanto que o ângulo do pé (b) possui valores máximos nessas posições. O ângulo g possui comportamento linear e tem ligeira diminuição ao longo da passada.

A figura 3.1-c mostra que, para o padrão P_2 , a trajetória do joelho tem comportamento linear ascendente até 90% da passada, e depois há um retorno. A figura 3.1-d mostra que o ângulo c possui um único ponto mínimo, e este ocorre na parte intermediária da passada, com valor menor que encontrado no padrão P_1 . O ângulo b tem comportamento análogo, com um único ponto máximo com valor maior do que para P_1 . O ângulo g tem comportamento semelhante.

A figura 3.1-e mostra que, para o padrão P_3 , o joelho tem menor deslocamento na direção x , tem maior ponto máximo na direção y entre todos os quatro padrões, e segundo maior retorno no final da trajetória, indicando que a trajetória elíptica do ponto B pé acentua este retorno. A figura 3.1-f revela que os dois valores mínimos de c

ocorrem antes de 25 % e depois de 75 % da passada.

A figura 3.1-g mostra que, para o padrão P_4 , o joelho mostra o maior retorno no final da trajetória, e seu máximo valor na direção y ocorre no final da trajetória, indicando que a trajetória da pelve tem mais influência nesta característica que a trajetória do pé. A figura 3.1-h mostra que o comportamento dos ângulos é semelhante ao padrão P_4 , também indicando que a característica de trajetória da pelve é mais relevante.




Figura 3.1: (a, c, e, g) Trajetórias do ponto B (pé), C (joelho) e D (pelve) para os padrões P_1 – P_4 e (b, d, f, h) os ângulos de interesse b , c e g sendo: a-b com o padrão P_1 , c-d com o padrão P_2 , e-f com o padrão P_3 e g-h com o padrão P_4

3.3 Variação paramétrica de L_2 e L_3

Nesta seção são mostradas as análises da variação dos parâmetros L_2 e L_3 através da razão R , e como esta variação influencia as variáveis cinemáticas do modelo. Nas figuras apresentadas nesta seção serão mostradas 3 curvas somente, relativas aos valores nominais ($R = 1$), maior razão ($R = 1.67$) e menor razão ($R = 0.60$). São apresentadas análises do comportamento do ponto C e dos ângulos c , dd , b , β e γ .

A figura 3.2 mostra a trajetória de C e o comportamento dos ângulos c , dd , b , β e γ em função de x_B para o padrão P_1 . Nota-se que, para maiores valores de R , relativos a menores comprimentos L_3 , há diminuição do valor máximo de y_C e um aumento do comprimento total da curva do ponto C . Neste padrão é onde ocorre menor retorno da trajetória do joelho após atingido $x_{C\max}$, e $y_{C\max}$ ocorre na parte central da trajetória. Nota-se a variação de R desloca os valores de ângulo c para baixo, independentemente se $R > 1$ ou $R < 1$. Menores valores da razão R aumentam os valores do ângulo dd , sendo que $R < 1$ resultam em maior desvio da curva nominal do que $R < 1$.

A figura 3.3 mostra a trajetória de C e o comportamento dos ângulos c , dd , b , β e γ em função de x_B para o padrão P_2 . Nota-se aumento do comprimento total da curva do ponto C para os maiores valores de R . A trajetória constante do ponto D (pelve) acentua o retorno do joelho após o ponto $x_{C\max}$, e o deslocamento $y_{C\max}$ acontece no final da trajetória. Para o ângulo c , há comportamento semelhante ao padrão P_1 , com $R \neq 1$ deslocando a curva para baixo. Maiores valores de R diminuem os valores do ângulo dd , e aumentam os valores de b , β e γ .




Figura 3.2: (a) Trajetória do ponto C (joelho) e em (b, c, d, e, f) comportamento dos ângulos c , dd , b , γ , β em função de x_B para o padrão P_1 .




Figura 3.3: (a) Trajetória do ponto C (joelho) e em (b, c, d, e, f) comportamento dos ângulos c , dd , b , γ , β em função de x_B para o padrão P_2 .

A figura 3.4 mostra a trajetória de C e o comportamento dos ângulos c , dd , b , β e γ em função de x_B para o padrão P_3 . Para os maiores valores de R provocam diminuição de y_C e um aumento do comprimento total da curva do ponto C . Para o ângulo c , há comportamento semelhante aos padrões P_1 e P_2 , com $R \neq 1$ deslocando a curva para baixo. Maiores valores de R diminuem os valores do ângulo dd , e aumentam os valores de b , β e γ .

A figura 3.5 mostra a trajetória de C e o comportamento dos ângulos c , dd , b , β e γ em função de x_B para o padrão P_4 . Este padrão resulta em maior retorno do joelho após atingido o ponto $x_{C_{\max}}$. Para o ângulo c , há comportamento semelhante aos padrões P_1 e P_2 , com $R \neq 1$ deslocando a curva para baixo. Maiores valores de R diminuem os valores do ângulo dd , e aumentam os valores de b , β e γ .




Figura 3.4: (a) Trajetória do ponto C (joelho) e em (b, c, d, e, f) comportamento dos ângulos c , dd , b , γ , β em função de x_B para o padrão P_3 .




Figura 3.5: (a) Trajetória do ponto C (joelho) e em (b, c, d, e, f) comportamento dos ângulos c , dd , b , γ , β em função de x_B para o padrão P_4 .

3.4 Sensibilidade das métricas biomecânicas

Nesta seção é mostrada a sensibilidade das 18 métricas biomecânicas (apresentadas na tabela 2.1) aos padrões (P_1 – P_4) e à razão R , de forma a buscar quais métricas podem conter mais informação para posterior uso na identificação de passada. As 18 métricas são mostradas nas figuras 3.6 a 3.8, na qual diferentes cores são utilizadas para diferenciar os padrões adotados sendo elas: P_1 (azul), P_2 (vermelho), P_3 (preto), P_4 (lilás), e 21 valores de R são utilizados, de $R = 0.60$ a $R = 1.67$.

Para A_C é possível notar que quanto maior for a área da trajetória do joelho maior é o deslocamento da articulação do joelho durante a passada. Os padrões P_1 e P_3 , com trajetória senoidal de D , sofrem pequena variação em função de R . A diminuição do valor de R resulta em: P_1 diminuição de 0.99%; P_2 aumento de 106.06%; P_3 aumento de 5.1%; P_4 aumento de 103.04%.

Para S_1 , há boa distinção entre os padrões de deslocamento com relação à trajetória de B , como P_1 e P_2 com menores valores e P_3 e P_4 com os maiores valores.

Para S_2 , há boa distinção entre o padrões de deslocamento com relação à trajetória de B , como P_1 e P_2 com menores valores e P_3 e P_4 com os maiores valores. Com esta métrica consegue-se principalmente valores mais distintos para o menores valores de R .

Para S_3 , não há diferenças significativas entre os padrões, somente P_2 resulta em valores distintos dos demais padrões.

Para $y_{C_{\max}}$ e $dd_{\max}$, os valores são muito próximos para todos os padrões, indicando que estas métricas não fornecem grande distinção nos valores entre os padrões adotados.




Figura 3.6: Valores das métricas (a) A_C , (b) S_1 , (c) S_2 , (d) S_3 , (e) y_{Cmax} , (f) dd_{max} em função da razão R , para os padrões P_1 (azul), P_2 (vermelho), P_3 (preto), P_4 (lilás).

Para $b_{\max}$, os valores máximos ocorrem para os padrões P_2 e P_4 , mostrando que o deslocamento da pelve influencia mais esta métrica, fazendo os valores máximos serem iguais quando a altura da pelve é constante.

Para $\beta_{\max}$, estes valores não tiveram variações significativas para os diferentes padrões adotados, mesmo ocorrendo ligeiro aumento da diferença entre os valores para os $R > 1$ não torna possível a diferenciação dos padrões.

Para $x_{C\max}$, os valores desta métrica não mostrou estar ligado aos padrões de deslocamento adotados, mas se mostra interessante para fazer a separação dos padrões P_2 e P_3 pelo primeiro possuir os menores valores o segundo os maiores valores para esta métrica.

Para $c_{\min}$, os valores mínimos são referentes aos padrões P_2 e P_4 , mostrando que o deslocamento da pelve influencia mais esta métrica, fazendo os valores mínimos serem iguais quando a altura da pelve é constante.

Para $\gamma_{\min}$, indicam a maior elevação do fêmur indicando um maior gasto de energia, porém, a análise deste ângulo mínimo se mostrou bastante correlacionado para os quatro padrões ocorrendo um aumento proporcional para aumento da razão R .

Para Δ_y , os valores desta métrica conseguem dividir os tipos os padrões em dois grupos P_1 e P_3 pelve senoidal com os maiores valores de variação e menor sensibilidade ao aumento da razão R e um segundo grupo P_2 e P_4 onde possui diminuição da área com o aumento da razão R .




Figura 3.7: Valores das métricas (a) b_{max} , (b) β_{max} , (c) x_{Cmax} , (d) c_{min} , (e) γ_{min} , (f) Δ_y em função da razão R , para os padrões P_1 (azul), P_2 (vermelho), P_3 (preto), P_4 (lilás).

Para Δ_x , os valores desta métrica estão mais correlacionados com a trajetória do ponto B (pé) pois os valores desta métrica para os padrões P_1 e P_2 com resultados mais próximos e o mesmo acontece para os padrões P_3 e P_4 , porém, todos possuem valores muito próximos dificultando a diferenciação dos padrões.

Para $\bar{y}_C$ e $\bar{c}$, os valores possuem uma sensibilidade de variação R sendo observado a diminuição dos valores das métricas aumentando o valor R .

Para $\bar{\gamma}$ e $\bar{\beta}$, os valores destas métricas tiveram aumento de seu valor com aumento R no entanto como os valores para todos os padrões não é possível distinguir os padrões por esta métrica.

Para $\bar{x}_C$, os valores desta métrica apresentam maior sensibilidade a trajetória do ponto B (pé) pois foi possível agrupar em dois conjuntos de valores para os padrões P_1 e P_2 com os menores valores e os padrões P_3 e P_4 para os maiores valores.




Figura 3.8: Valores das métricas (a) Δ_x , (b) $\overline{y}_C$, (c) $\overline{c}$, $\overline{\gamma}$, (d) $\overline{\beta}$, (e) $\overline{x}_C$ em função da razão R , para os padrões P_1 (azul), P_2 (vermelho), P_3 (preto), P_4 (lilás).

Capítulo 4

Identificação de padrão de passada com k-means

Nesta capítulo são apresentados os resultados para identificação dos padrões de passada utilizando algoritmo de clusterização k-means. São utilizados 4 métodos de seleção de métricas para maior sucesso na clusterização, levando em consideração também maior facilidade para ser obtida em uma estrutura de exoesqueleto assistivo de membro inferior. Os 4 métodos utilizados foram: projeção 2D, coeficiente de correlação, média e desvio padrão.

4.1 Critérios utilizados no método de classificação de passada

As análises utilizando clusterização k-means são utilizadas com as 18 métricas, organizadas na matriz A . Nessa matriz, cada coluna é relativa a uma métrica e cada linha é relativa a um dos 21 valores de R de cada padrão P_1-P_4 .

$$A = [A_C \ S_1 \ S_2 \ S_3 \ y_{C\max} \ dd_{\max} \ b_{\max} \ \beta_{\max} \ x_{C\max} \ c_{\min} \ \gamma_{\min} \ \Delta_y \ \Delta_x \ \bar{y}_C \ \bar{c} \ \bar{\gamma} \ \bar{\beta} \ \bar{x}_C] \quad (4.1)$$

O algoritmo k-means é utilizado com número de clusters $k = 4$, de forma a tentar identificar os padrões P_1 – P_4 à partir dos valores obtidos das análises de sensibilidade do capítulo anterior.

Para cada um dos 4 métodos de seleção de métricas, é feita uma comparação entre o resultado da clusterização com 18 métricas e com as métricas selecionadas, de forma a verificar a efetividade do método. Também é utilizado o método PCA (principal component analysis) para auxiliar a selecionar um número de métricas de acordo com o número de componentes principais relativo a, no mínimo, 95.0% da variância dos dados.

4.2 Projeção 2D

Nesta seção são mostrados os resultados de clusterização com escolha de variáveis por projeção 2D. Este método consiste em selecionar métricas duas a duas em uma projeção 2D do espaço 18D, e realizar uma clusterização com essas duas métricas escolhidas.

4.2.1 Clusterização dos padrões de passada

As figuras 4.1 e 4.2 mostram os resultados das clusterizações com todas as 18 métricas (esquerda) e com as 2 selecionadas (direita) para algumas projeções de interesse. Além da nuvem de pontos de dados, também são mostrados com símbolo ‘x’ o centro geométrico dos clusters encontrados pelo algoritmo. As cores identificam pontos pertencendo ao mesmo cluster.

Para o plano definido por A_C e S_1 , verifica-se que este par de métricas consegue classificar os padrões P_1 (vermelho), P_2 (azul), P_3 (verde) e P_4 (preto) com 100 % de acerto na identificação.

Para $x_{C\max}$ e $\bar{x}_C$, pode-se verificar que somente o padrão P_2 consegue ser identificado corretamente (em verde).

Para A_C e S_2 , os padrões conseguem ser todos separados conseguindo 100 % de acerto na identificação, sendo os padrões classificados assim P_1 (verde), P_2 (vermelho), P_3 (preto) e P_4 (azul) com 100 % de acerto na identificação.

Para S_1 e $c_{\min}$, os padrões P_1 , P_2 e P_4 conseguem ser corretamente identificados em único cluster, embora 4 elementos do padrão P_3 são incorretamente classificados como P_4 .

Para S_2 e $\beta_{\max}$, nenhum dos padrões é corretamente identificado.

Para $y_{C\max}$ e A_C , nenhum dos padrões é corretamente identificado.

As tabelas 4.1–4.6 mostram a análise das identificações com verdadeiros e falsos positivos e negativos.

Como resultado da análise por projeção 2D, as métricas que resultam em melhor desempenho da clusterização são A_C , S_1 , S_2 , $\bar{x}_C$, $\bar{x}_{C\max}$ e $c_{\min}$.

Os resultados através da PCA para o conjunto completo de dados (18 métricas) são mostrados na figura 4.3. A curva vermelha mostra a variabilidade acumulada em função dos componentes principais, e a curva preta a variância por componente principal. Nota-se que os quatro componentes principais que representam a mudança de acumulam 99,45% da variância do conjunto completo de dados.




Figura 4.1: Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) A_C e S_1 ; (c-d) x_{Cmax} e $\bar{x}_C$ e (e-f) A_C e S_2 . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela 4.1: Resultado quantitativo das métricas - $A_C \times S_1$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	10	0	0	0	21	0	0
P_2	0	11	10	0	0	0	21	0
P_3	11	0	0	10	0	0	0	21
P_4	0	0	10	11	21	0	0	0

Tabela 4.2: Resultado quantitativo das métricas - $x_{C_{\max}} \times \bar{x}_C$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	0	0	17	4
P_2	11	0	10	0	0	0	0	21
P_3	0	11	0	10	16	2	3	0
P_4	0	0	10	11	0	17	2	2

Tabela 4.3: Resultado quantitativo das métricas - $A_C \times S_2$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	0	0	0	21
P_2	11		10	0	0	21	0	0
P_3	0	11	0	10	21	0	0	0
P_4	0	0	10	11	0	0	21	0




Figura 4.2: Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) S_1 e c_{min} ; (c-d) S_2 e β_{max} e (e-f) $y_{C_{max}}$ e A_C . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela 4.4: Resultado quantitativo das métricas - $S_1 \times c_{min}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	10	0	0	0	0	21	0
P_2	0	11	10	0	0	21	0	0
P_3	11	0	0	10	4	0	0	17
P_4	0	0	10	11	21	0	0	0

Tabela 4.5: Resultado quantitativo das métricas - $S_2 \times \beta_{max}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	11	10	0	0
P_2	11	10	0	0	12	9	0	0
P_3	0	0	11	10	0	0	10	11
P_4	0	10	0	11	0	0	13	8

Tabela 4.6: Resultado quantitativo das métricas - $y_{C_{max}} \times A_C$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	0	11	0	10
P_2	11	10	0	0	11	0	10	0
P_3	0	0	11	10	0	11	0	10
P_4	0	10	0	11	10	0	11	0




Figura 4.3: Variância e relação as componentes principais utilizando o método da PCA para um conjunto de 18 métricas.

4.3 Coeficiente de correlação

Inicialmente, adotou-se que coeficiente maior que 0.7 indica alta correlação entre duas métricas, e desta forma redundância de informação. Para eliminar essa redundância, nos casos onde há coeficiente maior que 0.7 entre duas métricas, uma delas foi excluída. Para detalhar a correlação entre as métricas a figura 4.4 mostra com cores sendo os valores mais alto em tom amarelo e os menores em cores azul.




Figura 4.4: Imagem com resultado do coeficiente de correlação das 18 métricas em escala de gradiente.

Por exemplo, o coeficiente de correlação entre as métricas S_1 e S_3 é 0,8. As duas grandezas possuem a mesma complexidade de medição, portanto escolheu-se eliminar S_1 por possuir alta correlação também com $x_{C_{\max}}$, Δ_x e $\bar{x}_C$. Similarmente, $y_{C_{\max}}$ e $dd_{\max}$ são altamente correlacionadas. A métrica $y_{C_{\max}}$ possui grau de dificuldade maior para ser medida, e também possui alta correlação com $b_{\max}$, $\beta_{\max}$, $\gamma_{\min}$, Δ_x , $\bar{y}_C$, $\bar{c}$, $\bar{\gamma}$ e $\bar{\beta}$, e por isso é eliminada. Como resultado da análise das correlações entre as métricas, as 7 métricas selecionadas foram dispostas na matriz A_{n2} :

$$A_{n2} = [A_C \ S_2 \ S_3 \ dd_{\max} \ c_{\min} \ \Delta_x \ \bar{x}_C] \quad (4.2)$$

4.3.1 Clusterização dos padrões de passada

A figura 4.5 mostra os resultados das clusterizações com todas as 18 métricas (esquerda) e com as 7 métricas selecionadas (direita) para algumas projeções de interesse.

Por exemplo, a projeção em A_C e S_2 mostra correta identificação dos padrões P_1 e P_2 (vermelho e verde), embora não é possível identificar corretamente os padrões P_3 e P_4 . As outras projeções mostram o mesmo resultado em diferentes perspectivas, indicando que em algumas projeções mostram-se mais vantajosas para distinção dos pontos e clusters.

As tabelas 4.7–4.9 mostram a análise das identificações com verdadeiros e falsos positivos e negativos.

Como resultado da análise por coeficiente de correlação, as métricas que resultam em melhor desempenho da clusterização são A_C , S_2 e $c_{\min}$.

Os resultados PCA para o conjunto de dados com as 7 métricas selecionadas por correlação são mostrados na figura 4.6. A curva vermelha mostra a variabilidade acumulada em função dos componentes principais, e a curva preta a variância por componente principal. Nota-se que os quatro componentes principais acumulam 99,30% da variância do conjunto de dados.




Figura 4.5: Clusterização com as 18 métricas (esquerda) e com métricas 7 selecionadas por coeficiente de correlação (direita), sendo (a-b) A_C e S_2 ; (c-d) S_2 e c_{min} e (e-f) $\bar{x}_C$ e dd_{max} . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela 4.7: Resultado quantitativo das métricas - $A_C \times S_2$

	18 métricas				7 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	0	21	0	0
P_2	11	0	10	0	0	0	0	21
P_3	0	11	0	10	9	0	12	0
P_4	0	0	10	11	10	0	11	0

Tabela 4.8: Resultado quantitativo das métricas - $S_2 \times c_{\min}$

	18 métricas				7 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	0	0	0	21
P_2	10	11	0	0	0	21	0	0
P_3	0	0	11	10	9	0	12	0
P_4	10	0	0	11	10	0	11	0

Tabela 4.9: Resultado quantitativo das métricas - $\bar{x}_C \times dd_{\max}$

	18 métricas				7 métricas por correlação			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	0	21	0	0
P_2	11	0	10	0	0	0	0	21
P_3	0	11	0	10	9	0	12	0
P_4	0	0	10	11	10	0	11	0




Figura 4.6: Variância e relação as componentes principais utilizando o método da PCA para um conjunto de 7 métricas selecionadas por correlação.

4.4 Valor médio

Uma análise de valores médios das 18 métricas originais mostra que as métricas com os maiores valores são dd_{max} , b_{max} , β_{max} , c_{min} e $\bar{\beta}$, como mostrado na figura 4.7-a. Análise semelhante para a média normalizada resulta nas métricas dd_{max} , b_{max} , β_{max} , $\bar{y}_C$ e $\bar{\beta}$, conforme mostrado na figura 4.7-b.




Figura 4.7: Valores médios (a) das 18 métricas originais e (b) médios normalizados.

Como resultado da análise das média entre as métricas, as 5 métricas com os maiores valores de média com os valores não normalizados selecionadas foram dispostas na matriz A_{n3} :

$$A_{n3} = [dd_{max} \ b_{max} \ \beta_{max} \ c_{min} \ \bar{\beta}] \quad (4.3)$$

A matriz A_{n4} mostra o resultado da análise das entre as métricas, as 5 métricas com maiores valores de média normalizado selecionados foram dispostas na matriz A_{n4} :

$$A_{n4} = [dd_{max} \ b_{max} \ \beta_{max} \ \bar{y}_C \ \bar{x}_C] \quad (4.4)$$

4.4.1 Clusterização dos padrões de passada

As figuras 4.8 e 4.9 mostram os resultados das clusterizações com todas as 18 métricas (esquerda) e com as 5 selecionadas pelo valor médio (direita) para algumas projeções de interesse. Além da nuvem de pontos de dados, também são mostrados com símbolo ‘x’ o centro geométrico dos clusters encontrados pelo algoritmo. As cores identificam pontos pertencendo ao mesmo cluster.

A análise da figura 4.8 mostra que as métricas resultante da seleção do valor médio não consegue separar os padrões para as métricas: $dd_{\max}$ e $\beta_{\max}$; $\beta_{\max}$ e $c_{\min}$; $b_{\max}$ e $\beta_{\max}$. Neste caso fica evidenciado que a seleção da métrica é importante, porém, as métricas selecionadas por este método não possibilita a separação dos padrões.

Para o método de seleção sendo utilizado os maiores valores médios normalizados também não teve sucesso na seleção dos padrões como mostra a figura 4.9.

As tabelas 4.10–4.15 mostram a análise das identificações com verdadeiros e falsos positivos e negativos.

Como resultado da análise por valor médio, o método não teve sucesso em nenhuma clusterização.

Os resultados da PCA para o conjunto de dados com as 5 métricas selecionadas por valores médios são mostrados na figura 4.10. A curva vermelha mostra a variabilidade acumulada em função dos componentes principais, e a curva preta a variância por componente principal. Nota-se que os três componentes principais acumulam 99,92% da variância do conjunto de dados.




Figura 4.8: Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por valor médio (direita), sendo (a-b) dd_{max} e β_{max} ; (c-d) β_{max} e c_{min} e (e-f) b_{max} e β_{max} . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela 4.10: Resultado quantitativo das métricas - $dd_{\max} \times \beta_{\max}$

	18 métricas				5 métricas valor médio			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	4	4	0	13
P_2	11	10	0	0	6	8	7	0
P_3	0	0	11	10	7	6	8	0
P_4	0	10	0	11	7	7	7	0

Tabela 4.11: Resultado quantitativo das métricas - $\beta_{\max} \times c_{\min}$

	18 métricas				5 métricas valor médio			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	10	0	0	4	4	13	0
P_2	0	11	10	0	8	6	0	7
P_3	11	0	0	10	6	7	0	8
P_4	0	0	10	11	7	7	0	7

Tabela 4.12: Resultado quantitativo das métricas - $b_{\max} \times \beta_{\max}$

	18 métricas				5 métricas valor médio			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	4	4	13	0
P_2	10	11	0	0	8	6	0	7
P_3	0	0	11	10	6	7	0	8
P_4	10	0	0	11	7	7	0	7




Figura 4.9: Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por valor médio normalizado (direita), sendo (a-b) dd_{max} e β_{max} ; (c-d) β_{max} e $\bar{y}_C$ e (e-f) b_{max} e β_{max} . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela 4.13: Resultado quantitativo das métricas - $dd_{\max} \times \beta_{\max}$

	18 métricas				5 métricas valor médio normalizado			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	5	5	6	5
P_2	11	0	10	0	4	6	7	4
P_3	0	11	0	10	8	3	3	7
P_4	0	0	10	11	7	3	4	7

Tabela 4.14: Resultado quantitativo das métricas - $\beta_{\max} \times \bar{y}_C$

	18 métricas				5 métricas valor médio normalizada			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	10	0	0	6	5	5	5
P_2	0	11	10	0	7	6	4	4
P_3	11	0	0	10	3	3	8	7
P_4	0	0	10	11	4	3	7	7

Tabela 4.15: Resultado quantitativo das métricas - $b_{\max} \times \beta_{\max}$

	18 métricas				5 métricas valor médio normalizado			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	10	0	0	5	5	5	6
P_2	11	0	10	0	4	6	4	7
P_3	0	11	0	10	8	3	7	3
P_4	0	0	10	11	7	3	7	4




Figura 4.10: Variância e relação as componentes principais utilizando o método da PCA para um conjunto de 5 métricas selecionadas por valores médios (a) e médios normalizados (b).

4.5 Desvio Padrão

Uma análise de valores de desvio padrão das 18 métricas originais mostra que as métricas com os maiores valores são dd_{max} , b_{max} , β_{max} , γ_{min} , $\bar{c}$, como mostrado na figura 4.11.




Figura 4.11: Valores de desvio padrão para as 18 métricas originais.

Como resultado da análise do desvio padrão entre as métricas, as 5 métricas com os maiores valores de desvio padrão foram disposto na matriz A_{n5} :

$$A_{n5} = [dd_{max} \ b_{max} \ \beta_{max} \ \gamma_{min} \ \bar{c}] \quad (4.5)$$

4.5.1 Clusterização dos padrões de passada

A figura 4.12 mostra os resultados das clusterizações com todas as 18 métricas (esquerda) e com as 5 selecionadas pelo desvio padrão (direita) para as projeções de interesse. Além da nuvem de pontos de dados, também são mostrados com símbolo 'x' o centro geométrico dos clusters encontrados pelo algoritmo. As cores identificam pontos pertencendo ao mesmo cluster.

As tabelas 4.16–4.18 mostram a análise das identificações com verdadeiros e falsos positivos e negativos.

Como resultado da análise por desvio padrão, o método não teve sucesso na separação de nenhum dos padrões nas clusterizações realizadas.

Os resultados da PCA para o conjunto de dados com essas métricas selecionadas por valores de desvio padrão são mostrados na figura 4.13. A curva vermelha mostra a variabilidade acumulada em função dos componentes principais, e a curva preta a variância por componente principal. Nota-se que os três componentes principais acumulam 99,91% da variância do conjunto de dados.




Figura 4.12: Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por desvio padrão (direita), sendo (a-b) dd_{max} e b_{max} ; (c-d) dd_{max} e β_{max} e (e-f) β_{max} e $\bar{c}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela 4.16: Resultado quantitativo das métricas - $dd_{\max} \times b_{\max}$

	18 métricas				5 métricas desvio padrão			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	5	4	6	6
P_2	11	10	0	0	6	5	5	5
P_3	0	0	11	10	5	5	5	6
P_4	0	10	0	11	5	5	5	6

Tabela 4.17: Resultado quantitativo das métricas - $dd_{\max} \times \beta_{\max}$

	18 métricas				5 métricas desvio padrão			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	5	4	6	6
P_2	11	10	0	0	6	5	5	5
P_3	0	0	11	10	5	5	5	6
P_4	0	10	0	11	5	5	5	6

Tabela 4.18: Resultado quantitativo das métricas - $\beta_{\max} \times \bar{c}$

	18 métricas				5 métricas desvio padrão			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	6	5	6	4
P_2	11	0	10	0	5	6	5	5
P_3	0	11	0	10	5	5	6	5
P_4	0	0	10	11	5	5	6	5




Figura 4.13: Variância e relação as componentes principais utilizando o método da PCA para um conjunto de 5 métricas selecionadas por desvio padrão

Capítulo 5

Conclusões

No presente trabalho, foi feita uma introdução aos tipos e aplicações de exoesqueleto de membro inferior assistivo bem como uma revisão bibliográfica com intuito de explicar os principais tipos de estruturas de exoesqueleto. Foram mostradas também as equações cinemáticas de um modelo simplificado de exoesqueleto de membros inferiores assistivo, permitindo a variação dos parâmetros biomecânicos; sendo também definida a modelagem matemática das 18 métricas biomecânicas utilizadas.

No capítulo 3, através de simulações numéricas com as dimensões nominais fixa de L_2 (tíbia) e L_3 (fêmur) foi possível identificar o comportamento dos ângulos do pé (B), joelho (C) e pelve (D), bem como a trajetória do joelho (C) para os 4 padrões definidos para trajetória de pelve e pé (P_1-P_4). Estes resultados mostraram como os padrões de trajetória influenciam de modo importante a trajetória do joelho (C), destacando a relevância da trajetória da pelve (D), que para os padrões $P_1 - P_3$, apresentaram o ponto máximo de elevação y_{Cmax} na região mais central da trajetória e sendo capaz de deslocar este ponto máximo para o final da trajetória do joelho para os padrões $P_2 - P_4$. Foram apresentados também neste capítulo os resultados da variação paramétrica da relação entre o tamanho da parte superior da perna e a parte inferior da perna, a razão R , esta razão possui relevante influência na trajetória do joelho e no comportamento dos ângulos de interesse. Sendo que pode ser destacado o primeiro aspecto com relação a trajetória

do joelho (C), onde os valores $R < 1$ têm a característica de diminuir o deslocamento total do joelho e para $R > 1$ confere o aumento deste deslocamento. O segundo aspecto relevante foram os resultados apresentados pelas curvas características do ângulo c que tiveram comportamentos semelhantes em sua curvas características, tanto para valores de $R < 1$ quanto para $R > 1$, deslocando a curva no mesmo sentido. Ainda no capítulo 3 foram apresentadas as simulações numéricas com as análises de sensibilidade das 18 métricas biomecânicas para as 21 variações do valor da razão R para os quatro padrões (P_1-P_4), sendo que as métricas A_C , S_2 e $x_{\max}$ mostraram resultados interessantes, como distanciamento entre os valores dos padrões e sensibilidade a variação de R .

No capítulo 4 o algoritmo k-means foi utilizado com o número de clusters $k = 4$, de forma a tentar identificar os padrões P_1-P_4 à partir dos valores obtidos nas análises de sensibilidade, foram utilizados 4 métodos de seleção das métricas: Projeção 2D, Coeficiente de Correlação, Valor médio, Desvio padrão. Também foram apresentadas para cada uma das clusterizações realizadas uma análise quantitativa para avaliar a eficácia da seleção aplicada.

Para o método Projeção 2D foi possível obter uma melhor identificação. Por exemplo, ao usar apenas as métricas S_1 , S_2 e A_C , foi possível obter 100% de identificação correta para o critério de seleção de métricas utilizando a projeção 2D. Análises posteriores mostraram, que as métricas A_C , S_1 , S_2 , $\bar{x}_C$, $x_{C\max}$ e $c_{\min}$ foram as mais bem-sucedidas na identificação de padrões de passada.

Quando aplicou-se o método do Coeficiente de correlação, foi obtido um resultado positivo, pois em todas as clusterizações realizadas para esse método, sempre 2 padrões foram identificados, conseguindo agrupar todos os elementos do padrão com uma única cor no clusters. Sendo as métricas A_C , S_2 e $c_{\min}$ as mais bem eficazes neste método.

Por outro lado, os métodos de seleção de valores médio e desvio padrão não apresentaram resultado final positivo, pois não conseguiram separar nenhum padrão nas clusterizações realizadas.

Capítulo 6

Publicações

1. C. E. Oliveira e M. Silveira, Identificação de passada de um exoesqueleto utilizando algoritmo de classificação não supervisionado “k-means”. In: XI Seminário da pós Graduação 2018, Bauru, São Paulo.
2. C. E. Oliveira, J. C. M. Fernades and M. Silveira, In: Influence of biomechanical parameters on the gait identification of exoskeleton with unsupervised clustering algorithm, COBEM 2019, Uberlândia, Minas Gerais.
3. C. E. Oliveira e M. Silveira, Clusterização não supervisionada para análise da influência de parâmetros biomecânicos e seleção de métricas para identificação de passada de um exoesqueleto. In: Seminário da pós Graduação 2019, Bauru, São Paulo.

Referências Bibliográficas

- B. Abernethy, V. Kippers, and S. J. Hanrahan. *Biophysical foundations of human movement*. Human Kinetics, 2013.
- T. W. Anderson. *An introduction to multivariate statistical analysis*. Wiley-Interscience, 2003.
- C. J. Anumba and X. Wang. *Mobile and pervasive computing in construction*. John Wiley & Sons, 2012.
- P. Baumann. A binary linear programming based k-means approach for the capacitated centered clustering problem. In *2019 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, pages 335–339. IEEE, 2019.
- C. A. D. Bezerra. *Desenvolvimento de um robo bipede para locomoção em ambiente desestruturado*. PhD thesis, Universidade Estadual de Campinas, 2002.
- V. Bijalwan, V. B. Semwal, and T. K. Mandal. Fusion of multi-sensor-based biomechanical gait analysis using vision and wearable sensor. *IEEE Sensors Journal*, 21(13):14213–14220, 2021.
- B. Bittner, R. L. Hatton, and S. Revzen. Geometrically optimal gaits: a data-driven approach. *Nonlinear Dynamics*, 94(3):1933–1948, 2018.
- B. Chen, H. Ma, L. Qin, F. Gao, K. Chan, S. Law, L. Qin, and W. Liao. Recent

- developments and challenges of lower extremity exoskeletons. *Journal of Orthopaedic Translation*, 5:26–37, 2016.
- S. Ding, X. Ouyang, T. Liu, Z. Li, and H. Yang. Gait event detection of a lower extremity exoskeleton robot by an intelligent imu. *IEEE Sensors Journal*, 18(23): 9728–9735, 2018a.
- Y. Ding, M. Kim, S. Kuindersma, and C. J. Walsh. Human in the loop optimization of hip assistance with a soft exosuit during walking. *Sci. Robot.*, 3(15):eaar5438, 2018b.
- K. Hongyu, V. L. M. Sandanielo, and G. J. de Oliveira Jr. Análise de componentes principais: resumo teórico, aplicação e interpretação. *E&S Engineering and Science*, 5(1):83–90, 2016.
- A. K. Jain, R. P. W. Duin, and J. Mao. Statistical pattern recognition: A review. *IEEE Transactions on pattern analysis and machine intelligence*, 22(1):4–37, 2000.
- G. James, D. Witten, T. Hastie, and R. Tibshirani. *An introduction to statistical learning*, volume 112. Springer, 2013.
- B. Jardim. *Atuadores Elásticos em Série Aplicados no Desenvolvimento de um Exoesqueleto para Membros Inferiores. 2009. 102f.* PhD thesis, Dissertação (Mestrado em Engenharia Mecânica). Escola de Engenharia de São Carlos, Universidade de São Carlos, São Carlos, 2009.
- R. A. Johnson, D. W. Wichern, et al. *Applied multivariate statistical analysis*, volume 5. Prentice hall Upper Saddle River, NJ, 2002.
- E. Jung, C. Lin, M. Contreras, and M. Teodorescu. Applied machine learning on phase of gait classification and joint-moment regression. *Biomechanics*, 2(1):44–65, 2022.
- A. Kassambara. *Practical guide to principal component methods in R: PCA, M (CA), FAMD, MFA, HCPC, factoextra*, volume 2. Sthda, 2017.

- A. Kotikian, R. L. Truby, J. W. Boley, T. J. White, and J. A. Lewis. 3d printing of liquid crystal elastomeric actuators with spatially programed nematic order. *Advanced Materials*, 30(10):1706164, 2018.
- V. Kumar, Y. V. Hote, and S. Jain. Review of exoskeleton: history, design and control. In *2019 3rd International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE)*, pages 677–682. IEEE, 2019.
- R. S. Kuteken. *Geração de padrões de marcha para sistemas robóticos bípedes humanoides*. PhD thesis, Universidade Estadual de Campinas, 2017.
- E. P. Luque. Evaluation of the use of exoskeletons in the range of motion of workers. Master’s thesis, 2019.
- B. F. J. Manly and J. A. N. Alberto. *Multivariate statistical methods: a primer*. CRC press, 2016.
- M. Mathie, A. Coster, N. Lovell, and B. G. Celler. Accelerometry: Providing an integrated, practical method for long-term, ambulatory monitoring of human movement. *Physiological measurement*, 25:R1–20, 05 2004. doi: 10.1088/0967-3334/25/2/R01.
- P. F. Nunes, G. G. Peña, W. M. Santos, and A. A. G. Siqueira. Control of exoskeleton for lower limbs and influence on kinetic and muscular properties by using motor primitives. 2018.
- L. A. Paolucci. Comparação de dois métodos para representação da força de reação do solo no desempenho de classificação de padrões da marcha. Master’s thesis, 2006.
- J. Pinheiro, S. Cunha, G. Gomes, and S. Carvajal. *Probabilidade e estatística: quantificando a incerteza*. Elsevier Brasil, 2013.
- J. L. Pons. *Wearable robots: biomechatronic exoskeletons*. John Wiley & Sons, 2008.

- S. S. R. F. Rosa, M. C. Reis, M. F. F. Rosa, D. C3lon, C. A. Reis, and J. M. Balthazar. Use of natural latex as a biomaterial for the treatment of diabetic foot—a new approach to treating symptoms of diabetes mellitus. In *Topics in Public Health*, page 17. IntechOpen, 2015.
- W. M. Santos, Samuel L Nogueira, Gustavo C de Oliveira, Guido G Pe3a, and Adriano AG Siqueira. Design and evaluation of a modular lower limb exoskeleton for rehabilitation. pages 447–451, 2017.
- I. Stancic, T. G. Supuk, and M. Bonkovic. New kinematic parameters for quantifying irregularities in the human and humanoid robot gait. *International journal of advanced robotic systems*, 9(5):215, 2012.
- C. L. Vaughan, B. L Davis, C. Jeremy, et al. *Dynamics of human gait*. Kiboho Publishers, 1999.
- A. Viswakumar, V. Rajagopalan, T. Ray, and C. Parimi. Human gait analysis using openpose. In *2019 fifth international conference on image information processing (ICIIP)*, pages 310–314. IEEE, 2019.
- J. Wu. *Advances in K-means clustering: a data mining thinking*. Springer Science & Business Media, 2012.
- G. Z. Yang, R. J. Full, N. Jacobstein, P. Fischer, J. Bellingham, H. Choset, H. Christensen, P. Dario, B. J. Nelson, and R. Taylor. Ten robotics technologies of the year. 2019.
- Z. Zhang, L. Tran, X. Yin, Y. Atoum, X. Liu, J. Wan, and N. Wang. Gait recognition via disentangled representation learning. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 4710–4719, 2019.

Apêndice A

Resultados Complementares

Neste apêndice é mostrados todos os resultados todos resultados em complemento ao capítulo 4.

A.1 Projeção 2D

Nesta seção são mostrados os resultados complementares da clusterização com escolha de variáveis por projeção 2D. Este método consiste em selecionar métricas duas a duas em uma projeção 2D do espaço 18D, e realizar uma clusterização com essas duas métricas escolhidas. Em complemento aos resultados apresentados no capítulo 4.

A.1.1 Clusterização dos padrões de passada

As figuras A.1 – A.7 mostram os resultados das clusterizações com todas as 18 métricas (esquerda) e com as 2 selecionadas (direita) para algumas projeções de interesse. Além da nuvem de pontos de dados, também são mostrados com símbolo 'x' o centro geométrico dos clusters encontrados pelo algoritmo. As cores identificam pontos pertencendo ao mesmo cluster.

Para S_3 e $\beta_{\max}$, nenhum dos padrões é corretamente identificado.

Para $y_{C\max}$ e $c_{\min}$, nenhum dos padrões é corretamente identificado.

Para $y_{C\max}$ e $x_{C\max}$, nenhum dos padrões é corretamente identificado.

Para S_1 e $x_{C\max}$, os padrões P_2 e P_4 conseguem ser corretamente identificados em único cluster, embora 4 elementos do padrão P_1 e classificado P_2 e também 4 elementos P_3 são incorretamente classificados como P_4 .

Para $c_{\min}$ e $x_{C\max}$, nenhum dos padrões é corretamente identificado.

Para S_3 e $\gamma_{\min}$, nenhum dos padrões é corretamente identificado.

Para A_C e $c_{\min}$, os padrões P_1 e P_3 conseguem ser corretamente identificados em único cluster com 100% de assertividade.

Para $S_2 \times \bar{c}$, nenhum dos padrões é corretamente identificado.

Para A_C e S_3 , nenhum dos padrões é corretamente identificado.

Para $x_{C\max}$ e $dd_{\max}$, nenhum dos padrões é corretamente identificado.

Para S_2 e $c_{\min}$, os padrões P_1 , P_2 e P_4 conseguem ser corretamente identificados em único cluster, embora 4 elementos do padrão P_3 tenha 2 elementos de seu padrão classificado P_2 e dois para P_4 .

Para $c_{\min}$ e $dd_{\max}$, nenhum dos padrões é corretamente identificado.

Para $dd_{\max}$ e $\beta_{\max}$, nenhum dos padrões é corretamente identificado.

Para $\beta_{\max}$ e $c_{\min}$, nenhum dos padrões é corretamente identificado.

Para $b_{\max}$ e $\beta_{\max}$, nenhum dos padrões é corretamente identificado.

Para $\beta_{\max}$ e $\bar{y}_C$, nenhum dos padrões é corretamente identificado.

Para $b_{\max}$ e $\bar{y}_C$, nenhum dos padrões é corretamente identificado.

Para $\bar{y}_C$ e $\bar{x}_C$, nenhum dos padrões é corretamente identificado.

Para $\beta_{\max}$ e $\bar{c}$, nenhum dos padrões é corretamente identificado.

Para $\gamma_{\min}$ e $dd_{\max}$, nenhum dos padrões é corretamente identificado.

Para $\gamma_{\min}$ e $\bar{c}$, nenhum dos padrões é corretamente identificado.

As tabelas A.1–A.21 mostram a análise das identificações com verdadeiros e falsos positivos e negativos.

Os resultados PCA para o conjunto completo de dados (18 métricas) são mostrados na figura 4.3. A curva azul mostra a variabilidade acumulada em função dos compo-

mentos principais, e a curva preta a variância por componente principal. Nota-se que os quatro componentes principais acumulam 99,45% da variância do conjunto completo de dados.




Figura A.1: Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) S_3 e β_{max} ; (c-d) y_{Cmax} e c_{min} e (e-f) y_{Cmax} e x_{Cmax} . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.1: Resultado quantitativo métricas - $S_3 \times \beta_{\max}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	10	0	0	10	5	0	6
P_2	0	11	10	0	0	11	10	0
P_3	11	0	0	10	10	1	0	10
P_4	0	0	10	11	9	6	0	6

Tabela A.2: Resultado quantitativo métricas - $y_{C_{\max}} \times c_{\min}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	0	10	0	11
P_2	11	10	0	0	11	0	10	0
P_3	0	0	11	10	10	0	11	0
P_4	0	10	0	11	11	0	10	0

Tabela A.3: Resultado quantitativo métricas - $y_{C_{\max}} \times x_{C_{\max}}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	8	0	9	4
P_2	11	10	0	0	0	0	0	9
P_3	0	0	11	10	10	0	11	0
P_4	0	10	0	11	7	0	9	5




Figura A.2: Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) S_1 e $x_{C_{max}}$; (c-d) c_{min} e γ_{min} (e-f) S_3 e γ_{min} . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.4: Resultado quantitativo métricas - $S_1 \times x_{C_{\max}}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	0	0	10	0	0	4	17
P_2	0	11	0	10	0	0	21	0
P_3	11	10	0	0	17	0	4	0
P_4	0	0	10	11	0	21	0	0

Tabela A.5: Resultado quantitativo métricas - $c_{\min} \times \gamma_{\min}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	3	0	18	0
P_2	0	0	11	10	6	5	0	10
P_3	11	10	0	0	10	5	0	6
P_4	0	10	0	11	6	6	0	9

Tabela A.6: Resultado quantitativo métricas - $S_3 \times \gamma_{\min}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	0	0	17	4
P_2	11	0	10	0	0	0	0	21
P_3	0	11	0	10	16	2	3	0
P_4	0	0	10	11	0	17	2	2




Figura A.3: Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) A_C e c_{min} ; (c-d) S_2 e $\bar{c}$ e (e-f) A_C e S_3 . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.7: Resultado quantitativo métricas - $A_C \times c_{\min}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	0	0	21	0
P_2	11	0	10	0	0	5	0	16
P_3		11	0	10	21	0	0	0
P_4	0	0	10	11	0	11	0	10

Tabela A.8: Resultado quantitativo métricas - $S_2 \times \bar{c}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	8	0	9	4
P_2	11	10	0	0	0	12	0	9
P_3	0	0	11	10	10	0	11	0
P_4	0	10	0	11	7	0	9	5

Tabela A.9: Resultado quantitativo métricas - $A_C \times S_3$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	10	0	0	0	15	0	6
P_2	0	11	10	0	3	0	18	0
P_3	11	0	0	10	0	7	0	14
P_4	0	0	10	11	15	0	6	0




Figura A.4: Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) $\bar{x}_C$ e dd_{max} ; (c-d) S_2 e c_{min} e (e-f) c_{min} e dd_{max} . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.10: Resultado quantitativo métricas - $\bar{x}_C \times dd_{\max}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	10	6	6	5
P_2	11	0	10	0	7	0	9	5
P_3	0	11	0	10	5	13	3	0
P_4	0	0	10	11	5	12	4	0

Tabela A.11: Resultado quantitativo métricas - $S_2 \times c_{\min}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	21	0	0	0
P_2	10	11	0	0	0	0	21	0
P_3	0	0	11	10	0	2	2	17
P_4	10	0	0	11	0	21	0	0

Tabela A.12: Resultado quantitativo métricas - $c_{\min} \times dd_{\max}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	3	18	0	0
P_2	10	11	0	0	7	0	8	6
P_3	0	0	11	10	10	0	7	4
P_4	10	0	0	11	7	0	8	6




Figura A.5: Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) dd_{max} e β_{max} ; (c-d) β_{max} e c_{min} e (e-f) b_{max} e β_{max} . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.13: Resultado quantitativo métricas - $dd_{\max} \times \beta_{\max}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	6	4	6	5
P_2	11	10	0	0	5	6	5	5
P_3	0	0	11	10	5	4	6	6
P_4	0	10	0	11	5	6	5	5

Tabela A.14: Resultado quantitativo métricas - $\beta_{\max} \times c_{\min}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	10	0	0	18	3	0	0
P_2	0	11	10	0	0	6	5	10
P_3	11	0	0	10	0	10	5	6
P_4	0	0	10	11	0	6	6	9

Tabela A.15: Resultado quantitativo métricas - $b_{\max} \times \beta_{\max}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	7	3	6	5
P_2	10	11	0	0	6	5	5	5
P_3	0	0	11	10	5	5	5	6
P_4	10	0	0	11	5	5	6	5




Figura A.6: Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) β_{max} e $\bar{y}_C$; (c-d) b_{max} e $\bar{y}_C$ e (e-f) $\bar{y}_C$ e $\bar{x}_C$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.16: Resultado quantitativo métricas - $\beta_{\max} \times \bar{y}_C$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	10	0	0	6	4	6	5
P_2	0	11	10	0	5	5	6	5
P_3	11	0	0	10	5	6	5	5
P_4	10	0	10	11	5	5	6	5

Tabela A.17: Resultado quantitativo métricas - $b_{\max} \times \bar{y}_C$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	5	6	4	6
P_2	11	10	0	0	5	5	5	6
P_3	0	0	11	10	5	6	5	5
P_4	0	10	0	11	5	5	5	6

Tabela A.18: Resultado quantitativo métricas - $\bar{y}_C \times \bar{x}_C$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	5	7	9	0
P_2	11	10	0	0	6	6	9	0
P_3	0	0	11	10	1	5	3	12
P_4	0	10	0	11	1	5	3	12




Figura A.7: Clusterização com as 18 métricas (esquerda) e com métricas selecionadas duas a duas (direita), sendo (a-b) $\beta_{\max}$ e $\bar{c}$; (c-d) $\gamma_{\min}$ e $dd_{\max}$ e (e-f) $\gamma_{\min}$ e $\bar{c}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.19: Resultado quantitativo métricas - $\beta_{\max} \times \bar{c}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	5	5	5	6
P_2	11	0	10	0	6	5	5	5
P_3	0	11	0	10	5	6	5	5
P_4	0	0	10	11	5	5	6	5

Tabela A.20: Resultado quantitativo métricas - $\gamma_{\min} \times dd_{\max}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	6	7	3	5
P_2	10	11	0	0	5	6	5	5
P_3	0	0	11	10	5	5	5	6
P_4	10	0	0	11	6	5	5	5

Tabela A.21: Resultado quantitativo métricas - $\gamma_{\min} \times \bar{c}$

	18 métricas				2 métricas			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	7	4	5	5
P_2	11	10	0	0	7	4	5	5
P_3	0	0	11	10	5	5	6	5
P_4	0	10	0	11	6	5	5	5

A.2 Coeficiente de correlação

A figura A.8 mostra os resultados das clusterizações com todas as 18 métricas (esquerda) e com as 7 métricas selecionadas (direita) para algumas projeções de interesse. Em complemento aos resultados apresentados no capítulo 4.

A.2.1 Clusterização dos padrões de passada

Para A_C e S_3 , mostra correta identificação dos padrões P_1 e P_2 (vermelho e verde), embora não é possível identificar corretamente os padrões P_3 e P_4 . As outras projeções mostram o mesmo resultado em diferentes perspectivas, indicando que em algumas projeções mostram-se mais vantajosas para distinção dos pontos e clusters.

Para A_C e $c_{\min}$, mostra correta identificação dos padrões P_1 e P_2 (vermelho e verde), embora não é possível identificar corretamente os padrões P_3 e P_4 . As outras projeções mostram o mesmo resultado em diferentes perspectivas, indicando que em algumas projeções mostram-se mais vantajosas para distinção dos pontos e clusters.

Para $c_{\min}$ e $dd_{\max}$, mostra correta identificação dos padrões P_1 e P_2 (vermelho e verde), embora não é possível identificar corretamente os outros 2 padrões. Neste caso os padrões P_1 e P_2 estão sobreposto devido a métrica $c_{\min}$ que possui os mesmo valores para está métrica para ambos os padrões.

As tabelas A.22–A.24 mostram a análise das identificações com verdadeiros e falsos positivos e negativos.

Os resultados PCA para o conjunto de dados com as 7 métricas selecionadas por correlação são mostrados na figura 4.6. A curva vermelha mostra a variabilidade acumulada em função dos componentes principais, e a curva preta a variância por componente principal. Nota-se que os quatro componentes principais acumulam 99,30% da variância do conjunto de dados.




Figura A.8: Clusterização com as 18 métricas (esquerda) e com métricas 7 selecionadas por correlação (direita), sendo (a-b) A_C e S_3 ; (c-d) A_C e c_{min} ; (e-f) c_{min} e dd_{max} . Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.22: Resultado quantitativo das métricas - $A_C \times S_3$

	18 métricas				7 métricas por correlação			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	11	10	0	0	0	0	0	21
P_2	0	11	10	0	0	21	0	0
P_3	11	0	0	10	9	0	12	0
P_4	0	0	10	11	10	0	11	0

Tabela A.23: Resultado quantitativo das métricas - $A_C \times c_{\min}$

	18 métricas				7 métricas por correlação			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	11	0	0	0	0	21	0
P_2	11	0	10	0	0	0	21	0
P_3	0	11	0	10	12	0	0	9
P_4	0	0	10	11	11	0	0	10

Tabela A.24: Resultado quantitativo das métricas - $c_{\min} \times dd_{\max}$

	18 métricas				7 métricas por correlação			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	0	0	0	21
P_2	10	11	0	0	0	21	0	0
P_3	0	0	11	10	12	0	9	0
P_4	10	0	0	11	11	0	10	0

A.3 Valor médio

As figuras A.9 e A.10 mostram os resultados das clusterizações com todas as 18 métricas (esquerda) e com as 5 selecionadas pelo valor médio (direita) para algumas projeções de interesse. Além da nuvem de pontos de dados, também são mostrados com símbolo ‘x’ o centro geométrico dos clusters encontrados pelo algoritmo. As cores identificam pontos pertencendo ao mesmo cluster. Em complemento aos resultados apresentados no capítulo 4.

A.3.1 Clusterização dos padrões de passada

Para $c_{\min}$ e $dd_{\max}$, nenhum dos padrões é corretamente identificado.

As tabelas A.25–A.29 mostram a análise das identificações com verdadeiros e falsos positivos e negativos.

Os resultados PCA para o conjunto de dados com as 5 métricas selecionadas por valores médios são mostrados na figura 4.10. A curva vermelha mostra a variabilidade acumulada em função dos componentes principais, e a curva preta a variância por componente principal. Nota-se que os três componentes principais acumulam 99,92% da variância do conjunto de dados.




Figura A.9: Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por média (direita), sendo (a-b) c_{min} e dd_{max} ; (c-d) dd_{max} e β_{max} e (e-f) c_{min} e $\bar{\beta}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.25: Resultado quantitativo das métricas - $c_{\min} \times dd_{\max}$

	18 métricas				5 métricas média			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	13	4	4	0
P_2	10	11	0	0	0	6	7	8
P_3	0	0	11	10	0	7	7	7
P_4	10	0	0	11	0	10	0	11

Tabela A.26: Resultado quantitativo das métricas - $c_{\min} \times \bar{\beta}$

	18 métricas				5 métricas média			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	13	4	4	0
P_2	10	11	0	0	0	6	8	7
P_3	0	0	8	3	0	7	6	8
P_4	10	0	0	11	0	7	7	7




Figura A.10: Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por valor médio normalizada (direita), sendo (a-b) dd_{max} e b_{max} ; (c-d) b_{max} e $\bar{y}_C$ e (e-f) $\bar{y}_C$ e $\bar{x}_C$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.27: Resultado quantitativo das métricas - $dd_{\max} \times b_{\max}$

	18 métricas				5 métricas valor médio normalizada			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	6	5	5	5
P_2	10	11	0	0	7	4	6	4
P_3	0	0	11	10	3	8	3	7
P_4	10	0	0	11	4	7	3	7

Tabela A.28: Resultado quantitativo das métricas - $b_{\max} \times \bar{y}_C$

	18 métricas				5 métricas valor médio normalizada			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	5	5	5	6
P_2	11	10	0	0	4	6	4	7
P_3	0	0	11	10	8	3	7	3
P_4	0	10	0	11	7	3	7	4

Tabela A.29: Resultado quantitativo das métricas - $\bar{y}_C \times \bar{x}_C$

	18 métricas				5 métricas valor médio normalizada			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	10	0	11	0	5	5	5	6
P_2	11	10	0	0	6	4	4	7
P_3	0	0	11	10	3	8	7	3
P_4	0	10	0	11	3	7	7	4

A.4 Desvio Padrão

Uma análise de valores de desvio padrão das 18 métricas originais mostra que as métricas com os maiores valores são dd_{max} , b_{max} , β_{max} , γ_{min} , $\bar{c}$, como mostrado na figura 4.11. Em complemento aos resultados apresentados no capítulo 4.

A.4.1 Clusterização dos padrões de passada

A figura A.11 mostra os resultados das clusterizações com todas as 18 métricas (esquerda) e com as 5 selecionadas pelo desvio padrão (direita) para as projeções de interesse. Além da nuvem de pontos de dados, também são mostrados com símbolo ‘x’ o centro geométrico dos clusters encontrados pelo algoritmo. As cores identificam pontos pertencendo ao mesmo cluster.

Para S_3 e β_{max} , nenhum dos padrões é corretamente identificado.

Para γ_{min} e dd_{max} , nenhum dos padrões é corretamente identificado.

Para γ_{min} e $\bar{c}$, nenhum dos padrões é corretamente identificado.

As tabelas A.30–A.32 mostram a análise das identificações com verdadeiros e falsos positivos e negativos.

Os resultados PCA para o conjunto de dados com essas métricas selecionadas por valores de desvio padrão são mostrados na figura 4.13. A curva vermelha mostra a variabilidade acumulada em função dos componentes principais, e a curva preta a variância por componente principal. Nota-se que os três componentes principais acumulam 99,91% da variância do conjunto de dados.




Figura A.11: Clusterização com as 18 métricas (esquerda) e com métricas 5 selecionadas por média (direita), sendo (a-b) b_{max} e β_{max} ; (c-d) γ_{min} e dd_{max} e (e-f) γ_{min} e $\bar{c}$. Número de clusters $k = 4$. Círculos são pontos de dados, e 'x' é o centro geométrico do cluster encontrado. As cores identificam pontos pertencendo ao mesmo cluster.

Tabela A.30: Resultado quantitativo das métricas - $b_{\max} \times \beta_{\max}$

	18 métricas				5 métricas desvio padrão			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	11	0	0	6	6	5	4
P_2	10	0	11	0	5	5	5	6
P_3	0	11	0	10	6	5	5	5
P_4	10	0	0	11	6	5	5	5

Tabela A.31: Resultado quantitativo das métricas - $\gamma_{\min} \times dd_{\max}$

	18 métricas				5 métricas desvio padrão			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	5	6	4	4
P_2	10	11	0	0	6	5	5	5
P_3	0	0	11	10	5	5	5	6
P_4	10	0	0	11	5	5	5	6

Tabela A.32: Resultado quantitativo das métricas - $\gamma_{\min} \times \bar{c}$

	18 métricas				5 métricas desvio padrão			
	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$	$C_1(\text{Pr})$	$C_2(\text{Vm})$	$C_3(\text{Az})$	$C_4(\text{Ve})$
P_1	0	10	11	0	5	6	4	4
P_2	10	11	0	0	6	5	5	5
P_3	0	0	11	10	5	5	5	6
P_4	10	0	0	11	5	5	5	6