

Estratégias de salto em abordagens Markovianas colaborativas para estimativa de ângulos de orientação e articulares^{*}

Lucca B. Castro^{*} Mateus Pereira^{*} Edson Francelino^{**}
Roberto S. Inoue^{***} Samuel Nogueira^{*}

^{*} Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de São Carlos, São Carlos, SP.

^{**} Programa de Pós-Graduação em Engenharia Elétrica, Universidade São Paulo, São Carlos, SP.

^{***} Departamento de Computação, Universidade Federal de São Carlos, São Carlos, SP.

Abstract: This paper proposes the development of an approach for better identification of jumps in collaborative Markovian systems, aiming at a better estimation of orientation and joint angles in consecutive segments of the human body and in articulated robotic devices. The proposal consists of elaborating combined strategies to identify sensors with less dynamic acceleration and at the same time greater relation with the movement, using established strategies of strapdown and finite state machines. For application of the proposal, a Markovian Articular Spatial System was implemented using Strapdown and Gait Cycles. The results obtained were promising, and for the angles of movement in the sagittal plane we obtained a Pearson correlation of 0.80 for the trunk and above 0.996 for the other segments, with an RMSE of 2.17 for the trunk and below 1.43 for others. As for the knee joint angle, a correlation of 0.99 and with RMSE of 1.27 was obtained, which demonstrates the efficiency of the method for segments that have a reliable estimate of orientation, which does not occur with the same accuracy for hip joint, as it depends on the trunk segment.

Resumo: Este artigo propõe o desenvolvimento de uma abordagem para melhor identificação de saltos em sistemas Markovianos colaborativos, visando uma melhor estimativa de ângulos de orientação e articulares em segmentos consecutivos do corpo humano e em dispositivos robóticos articulados. A proposta consiste em elaborar estratégias combinadas para identificar sensores com menor aceleração dinâmica e ao mesmo tempo maior relação com o movimento, utilizando estratégias consagradas de *strapdown* e máquinas de estados finitos. Para aplicação da proposta foi implementado um Sistema Markoviano Espacial Articular utilizando *Strapdown* e Ciclos de Marcha. Os resultados obtidos foram promissores, sendo que para os ângulos de movimento no plano sagital obtivemos correlação de Pearson de 0.80 para tronco e acima de 0.996 para os demais segmentos, com EQM de 2.17 para o tronco e abaixo de 1.43 para os demais. Já para o ângulo articular do joelho foi obtido correlação de 0.99 e com EQM de 1.27 o que demonstra a eficiência do método para segmentos que possuem estimativa confiável de orientação, o que não ocorre com a mesma acurácia para articulação do quadril, uma vez que esta depende do segmento do tronco.

Keywords: Strapdown; Kalman-Filter; exoskeleton; solidarity; IMU.

Palavras-chaves: Navegação; Filtro; exoesqueleto; solidário; UMI.

1. INTRODUÇÃO

A aplicação da robótica na reabilitação de pacientes cresce diariamente desde o início do século XXI. O uso desta tecnologia pode aumentar a eficiência terapêutica, possibilitando fornecer treinamentos consistentes por longos períodos, acrescido da coleta de dados para avaliar comorbidades e o progresso do tratamento, Laut et al. (2016). Neste sentido, a informação de atitude dos elos do corpo do

paciente, bem como os ângulos das articulações, possuem um alto valor no desempenho esperado de exoesqueletos e órteses ou mesmo na obtenção de dados terapêuticos. Em T. Watanabe (2011) e H.J. Luinge (2004) é feita a obtenção desses dados através da utilização de Unidades de Medição Inercial, do inglês *Inertial Measurement Units* (IMUs).

Sensores inerciais de baixo custo não são ideais e apresentam erros e ruídos de medição que afetam consideravelmente um sistema de navegação inercial. Fazendo-se necessário o uso de metodologias que considerem incer-

^{*} Pesquisa realizada com apoio do CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil.

tezas paramétricas e dinâmicas possíveis nesses sistemas. Um método frequentemente utilizado pela comunidade científica para realizar o tratamento desses dados, através da fusão e filtragem dos sinais, é a clássica abordagem proposta por Kalman em R.E.Kalman (1960) e de suas derivações, como *Unscented Kalman Filter* (UKF), *Markovian Kalman Filter* (MKF) e o Filtro de Kalman Estendido (FKE).

Estudos como o de H.J. Luinge (2004) apresentam metodologias para estimativa de ângulos de orientação para segmentos do corpo humano através da utilização de um Filtro de Kalman (FK). Já em H.J. Luinge (2007) é incorporada uma restrição de movimento na articulação do cotovelo, considerando um ângulo restrito e consideravelmente pequeno para a adução. S. Nogueira (2014) e A. Olivares (2016) utilizam de parâmetros do sistema para alterar a atuação do filtro, respectivamente através da frequência do movimento e de saltos entre estados Markovianos definidos. Neste último, são definidas restrições articulares que são modeladas de forma a necessitar apenas um acelerômetro a cada instante, o que possibilita a escolha do sensor mais confiável, com menor incidência de aceleração dinâmica, para correção com FK. Em F. Sado (2018) é proposta a utilização do UKF apresentando, segundo B.O.S. Teixeira (2010), um melhor desempenho em relação ao FKE por ser naturalmente projetado para sistemas não lineares.

O modelo proposto por S. Nogueira (2014) composto de um sistema colaborativo e um filtro de Kalman sujeito à saltos Markovianos (MKF) apresentou resultados promissores para sistemas com restrições articulares. Diferentemente dos filtros de Kalman modelados para sistemas de atitude, que utilizam modelos individuais para cada sensor, o MKF modela o sistema através de restrições articulares, fazendo uso de todos os sensores inerciais fixos no exoesqueleto enquanto os demais utilizam a estimativa isolada por elos. Assim, os estados da cadeia de Markov são representados pela IMU que possui a maior confiabilidade a cada instante, sendo a confiabilidade contabilizada pelo sensor com menor aceleração dinâmica. Ainda, a abordagem complementar, para o FK utilizada, possui uma rápida resposta dinâmica, pois atua somente na combinação dos erros dos sinais modelados com os erros dos sinais auxiliares, o que possibilita minimizar distorções e atrasos nos sinais modelados culminando em menor atraso no tempo de filtragem.

Os sinais coletados pelo acelerômetro de uma IMU possuem dados de aceleração gravitacional, utilizada para estimativa dos ângulos de orientação, acelerações dinâmicas decorrentes do movimento, *offset* e ruído branco gaussiano, sendo os que os três últimos interferem diretamente nos algoritmos de navegação inercial. Assim, fora o ruído de medida e *offset* que podem ser facilmente modelados, um sistema que identifique de forma mais precisa os sensores combinados com menor aceleração dinâmica, a cada instante, pode beneficiar a precisão das estimativas angulares.

Este artigo busca estabelecer mecanismos para elencar os acelerômetros com menor incidência de aceleração dinâmica, sendo estes combinados de um sistema Markoviano. Assim, identificamos a melhor condição de salto afim de realizar estimativas angulares de orientação e articulares

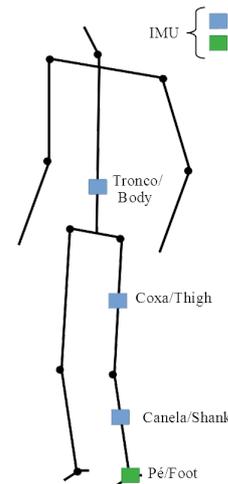


Figura 1. Posicionamento dos sensores inerciais (IMU) no corpo humano.

através de IMUs posicionadas em três segmentos consecutivos do corpo humano: tronco, coxa e canela. Para isso, é definida uma metodologia para identificação do salto baseada em *strapdown*, fusão de sinais e fases do caminhar aliada aos desenvolvimentos da estimativa angular realizados em Nogueira (2015), Francelino (2021) e E. Francelino (2022).

2. METODOLOGIAS E DESENVOLVIMENTOS

O estudo aqui apresentado utilizará sinais de três IMUs dispostas em três segmentos consecutivos do corpo humano com aquisição de dados em 50 Hz, como ilustrado na Figura 1. Vale ressaltar que um quarto sensor foi utilizado no segmento do pé, sendo este utilizado apenas para identificação dos ciclos de marcha, uma vez que a anatomia deste promove movimento majoritariamente biarticulado em função do tornozelo e dedos. Nas seções subsequentes, serão abordadas as principais metodologias utilizadas: *Strapdown* na Seção 2.1, Detecção de Marcha Humana na Seção 2.2, Sistema Markoviano Espacial Articular com *Strapdown* e Ciclos de Marcha proposto neste trabalho na Seção 2.3.

2.1 Navegação inercial e Strapdown

Metodologias de navegação inercial utilizam da combinação medidas de diferentes tipos de sensores, tais como giroscópio, acelerômetro, magnetômetro e GPS para realizar a estimativas de orientação e de posicionamento de corpos no espaço. Um dos processos contidos na navegação inercial denomina-se *strapdown* que é responsável pela separação de medidas inerciais compostas, como é o exemplo do acelerômetro que contém em sua medida acelerações dinâmicas e gravitacionais. Assim, nos casos de estimativa de orientação, o qual utiliza somente aceleração gravitacional, pode-se utilizar o *strapdown* como mecanismo de separação. Dessa forma, através de matrizes de rotação é possível alterar a referência dos eixos dos sensores inerciais utilizando predições de orientação pelo giroscópio corrigido com medidas de acelerômetros em movimento uniforme, ou seja, na ausência de acelerações dinâmicas do movimento,

para levar do referencial do corpo para o referencial global. Sendo os passos da metodologia apresentados na Figura 2.

Assim, a separação entre as acelerações gravitacionais e dinâmicas do movimento podem ser realizadas como:

- Cálculo da orientação atual predita pelo giroscópio, e definição da matriz rotação que leva do sistema do corpo para o sistema global, Equações (2) a (5),
- Rotação das medidas do acelerômetro do sistema do corpo para o global, Equação (1),
- Cálculo aceleração dinâmica, Equação (6).

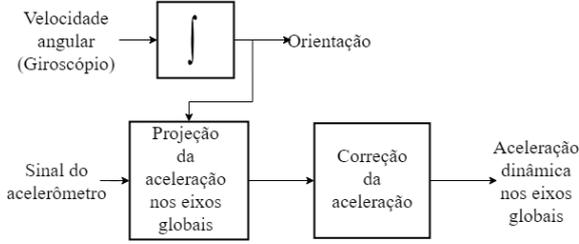


Figura 2. Processo de remoção da gravidade.

$$a_g(t) = C(t)a_b(t) \quad (1)$$

$$\Omega(t) = \begin{bmatrix} 0 & -\omega_{bz}(t) & \omega_{by}(t) \\ \omega_{bz}(t) & 0 & -\omega_{bx}(t) \\ -\omega_{by}(t) & \omega_{bx}(t) & 0 \end{bmatrix} \quad (2)$$

$$\int_t^{t+\delta t} \Omega(t)dt = B \quad (3)$$

$$C(t + \delta t) = C(t)e^{\int_t^{t+\delta t} \Omega(t)dt} \quad (4)$$

$$C(t + \delta t) = C(t)\left(I + \frac{\sin\sigma}{\sigma}B + \frac{1 - \cos\sigma}{\sigma^2}B^2\right) \quad (5)$$

$$a_{Dinmica}(t) = a_g(t) - g_g(t) \quad (6)$$

Sendo a_g a aceleração com referencial global, $C(t)$ a matriz de rotação, a_b a aceleração com referencial no corpo, $\Omega(t)$ a matriz de velocidades angulares em cada eixo do giroscópio e B a matriz de ângulos, $\sigma = |\omega_b \delta t|$, em que a Equação (5) representa a atualização da atitude a cada instante de tempo.

Neste estudo, estamos interessados em identificar os instantes de ocorrência da aceleração dinâmica com o intuito de evitá-lo. No entanto, como ficará evidente na seção resultado, o algoritmo de *strapdown* não é suficiente para remover completamente a aceleração dinâmica do sinal do acelerômetro.

Portanto, torna-se necessário o uso de estratégia adicionais para melhor delimitar os intervalos com menor incidência de aceleração dinâmica e, por consequência, a escolha do acelerômetro mais confiável. Assim, uma das formas de identificar a mudança de aceleração dinâmica ou mesmo a intensidade com a mesma incide sobre o sinal do acelerômetro, seria através da combinação da amplitude do sinal medido com variância média móvel.

A Equação (7) apresenta a variância amostral, sendo $x(k)$ o valor analisado, \bar{x} a média aritmética do conjunto e n a quantidade de elementos do conjunto.

Desse modo, utilizando a Equação (7), espera-se identificar os instantes de medida do acelerômetro que tenham baixa aceleração dinâmica. Uma vez que apenas utilizando valores limiares simples, é possível delimitar os valores de baixa aceleração e assim encontrar os intervalos de baixa aceleração dinâmica (veja Tabela 3). A Figura 3 ilustra como uma seleção por variância funcional em um sinal senoidal, no qual estamos interessados em encontrar o intervalo com menor valor de variância.

$$S^2 = \frac{\sum_{i=1}^n (x(k) - \bar{x})^2}{n - 1} \quad (7)$$

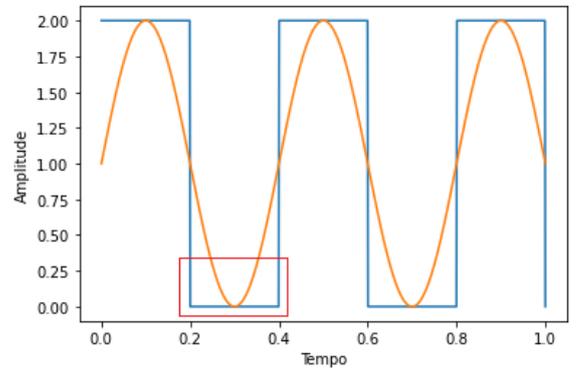


Figura 3. Exemplo de resultado esperado com a aplicação da variância.

2.2 Detecção de marcha

A estratégia abordada por Caltran and Siqueira (2010), para identificar os intervalos com baixa aceleração dinâmica, utiliza-se de sensores de força resistivos presentes no solado do pé e opera como uma chave para identificar os momentos em que o pé está tocando o solo (em repouso).

Park and Suh (2010) descreve o tempo de repouso do pé em um ciclo normal de marcha como um curto período (aproximadamente de 0.1 a 0.3s). Esse repouso é identificado através da identificação de velocidades próximas a zero no pé e consequentemente, acelerações também próximas de zero. Deste modo, será proposto uma metodologia para compor o sistema como um todo que identifique somente os momentos no qual o pé está em contato com o solo.

A Figura 4 mostra os dados do giroscópio no tempo representando aproximadamente 4 passos do paciente. Já na Figura 5, é apresentado o ciclo de marcha para cada passo sendo este dividido em quatro segmentos.

Como é possível observar nas figuras 4 e 5, trata-se de um padrão cíclico, sendo possível a utilização de uma máquina de estados com limiares para transição entre estados z_m , com $m = \{1, 2, 3, 4\}$ ao longo do tempo. O momento 1 descrito é de interesse para o sistema, sendo o momento com maior probabilidade de possuir aceleração dinâmica mínima. A Equação (8) defini o estado atual da máquina através da relação entre o estado presente z_m , o estado

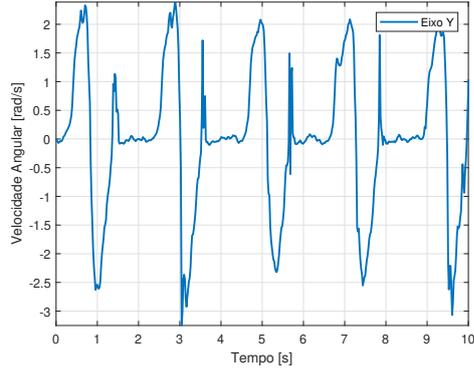


Figura 4. Padrão gráfico do eixo-y do giroscópio e o movimento do pé no ciclo de caminhada.

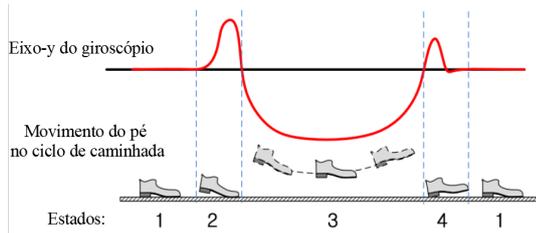


Figura 5. Padrão gráfico do eixo-y do giroscópio e o movimento do pé no ciclo de caminhada; Fonte: Obtido de Park and Suh (2010).

passado z_{m-1} e os valores limiares de aceleração α que devem ser definidos.

$$f(z_m) = \begin{cases} 1, & z_m < \alpha_1 \text{ e } f(z_{m-1}) = 4 \\ 2, & z_m > \alpha_2 \text{ e } f(z_{m-1}) = 1 \\ 3, & z_m < \alpha_3 \text{ e } f(z_{m-1}) = 2 \\ 4, & z_m > \alpha_4 \text{ e } f(z_{m-1}) = 3 \end{cases} \quad (8)$$

Para detectar os limiares é necessário evitar eventuais ruídos, assim, uma boa solução é aplicar um filtro média móvel nos dados do giroscópio, no entanto deve-se atentar para que a ordem do filtro média móvel não cause atraso significativo no sistema.

2.3 Sistema Markoviano Espacial Articular com Strapdown e Ciclos de Marcha (SMeA-SCM)

Em E. Francelino (2022) é proposto o Sistema Markoviano Espacial Articular (SMeA) que é responsável por efetuar a estimativa angular espacial entre dois segmentos consecutivos da perna. Neste são utilizados saltos Markovianos para transitar entre estados que possuem as IMUs com medidas mais confiáveis de acelerômetros a cada instante. No entanto, foram utilizadas condições de confiabilidade do acelerômetro simplificadas, através da norma mínima entre os acelerômetros do modelo e o vetor gravidade, representada pela Equação (9).

$$\Theta(t) := \begin{cases} 3, & \text{para } \lambda = 2 \\ \arg \min_i (||a_i|| - g_e), & \text{para } \lambda \leq 1 \end{cases} \quad (9)$$

Sendo os resultados $\{1, 2, 3\}$ correspondentes a $\{T, S, TS\}$, e λ igual ao número de acelerômetros com baixo nível de aceleração dinâmica a cada instante. Dentre as possibilidades, TS está presente como estado nominal do sistema.

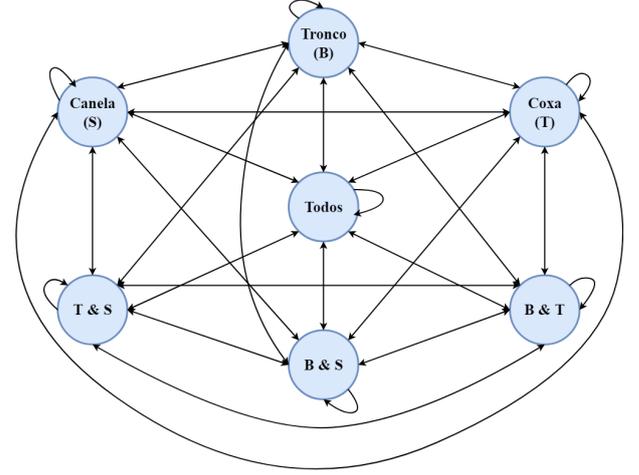


Figura 6. Diagrama de transição de estados SMeA-SCM.

Nessa seção, o modelo elaborado por Francelino (2021) será expandido para três segmentos e um sistema de identificação do estado Markoviano será proposto em substituição a Equação (9).

A Figura 6 apresenta os sete estados Markovianos, indicados pelas iniciais em inglês de cada segmento do corpo, como indicado na Figura 1, em que se encontram os sensores mais confiáveis (B, *Body*; T, *Thigh*; S, *Shank*; BT, *Body/Thigh*; BS, *Body/Shank*; TS, *Thigh/Shank*; BTS, *Body/Thigh/Shank*). Assim, as regras de salto entre sistemas para Francelino (2021), seriam:

$$\Theta(t) := \begin{cases} 7, & \text{para } \lambda = 3 \\ (||a_i|| - g_e) \leq \alpha_i & \text{para } \lambda = 2 \\ \arg \min_i (||a_i|| - g_e), & \text{para } \lambda \leq 1 \end{cases} \quad (10)$$

sendo os resultados $\{1, 2, 3, 4, 5, 6, 7\}$ correspondentes a $\{B, T, S, BT, BS, TS, BTS\}$, α_i correspondente ao limiar de aceleração dinâmica em cada segmento e λ igual ao número de acelerômetros com baixo nível de aceleração dinâmica a cada instante.

Já o funcionamento do Sistema Markoviano Espacial Articular com *Strapdown* e Ciclos de Marcha (SMeA-SCM), aqui proposto, é apresentado na Figura 7, que apresenta da esquerda para a direita, a variância do acelerômetro utilizada, a obtenção da aceleração dinâmica através do processo de *strapdown*, o tratamento dos dados do giroscópio através do filtro complementar para eliminar a deriva causada pelo mesmo e a identificação do estado do pé através da máquina de estados.

As condições de salto são definidas pelo Algoritmo 1, o qual substitui a Equação (10) e identifica a cada instante de tempo, quais estados são considerados confiáveis.

Assim, o equacionamento no espaço de estados para o SMeA-SCM, o qual seleciona os acelerômetros mais confiáveis através dos saltos Markovianos representados pelas matrizes $\Theta(t)$ afetam somente equação de saída do modelo o qual é definido como:

$$\dot{x}(t) = \bar{A}x(t) + \bar{B}w(t), \quad (11)$$

$$y(t) = \bar{C}(\Theta(t))x(t) + v(t), \quad (12)$$

sendo o vetor de estados $x(t)$ é definido conforme a Equação (13) e $x_i(t)$ para $i = \{B, T, S\}$ conforme a Equação (14).

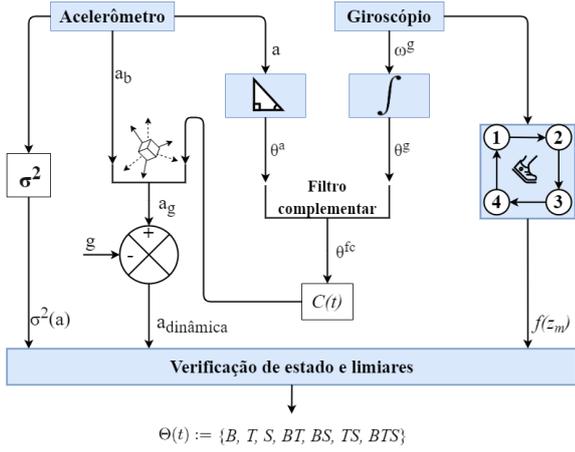


Figura 7. Diagrama do sistema identificador do estado Markoviano.

Algorithm 1 : VERIFICAÇÃO DE ESTADO E LIMIARES

Inicialize:

while corpo em movimento **do**

$segmn = []$

for $i \in \{B, T, S\}$ **do**

$z_m = \text{Equação (8)}$

if $(f(z_m) = 1 \ \& \ |a_{d_i}| \leq \alpha_i \ \& \ \sigma^2(|a_{d_i}|) \leq \beta_i)$ **then**

$segmn = [segmn \ i]$

end if

end for

if $segmn = []$ **then**

if $(f(z_m) = 1)$ **then**

$segmn = [B \ T \ S]$

else

$segmn = \arg \min_i (a_{d_i}) \quad \triangleright \text{Para } i := \{B, T, S\}$

end if

end if

$\Theta(t) = segmn$

end while

$$x(t) = [x_B(t) \ x_T(t) \ x_S(t)]^T \quad (13)$$

$$x_i(t) = [\Delta\theta_{i_R}(t) \ \Delta b_{i_R}(t) \ \Delta\theta_{i_P}(t) \ \Delta b_{i_P}(t) \ \Delta\theta_{i_Y}(t) \ \Delta b_{i_Y}(t)] \quad (14)$$

Na Equação (12) é acrescentado o erro de estimativa do ângulo relativo da articulação do quadril, do inglês *hip* (h), conforme apresentado abaixo:

$$y(t) = [\Delta\theta_{\Theta(t)_R} \ \Delta\theta_{\Theta(t)_P} \ \Delta\theta_{\Theta(t)_Y} \ \Delta h \ \Delta k], \quad (15)$$

$$\Delta\theta_{\Theta(t)_j} = \theta_{\Theta(t)_j} - \theta_{g_{\Theta(t)_j}}, \quad (16)$$

$$\Delta h = \alpha_{h_{acel+giro}}(t) - (\theta_{g_B}(t) - \theta_{g_T}(t)). \quad (17)$$

$$\Delta k = \alpha_{k_{acel+giro}}(t) - (\theta_{g_T}(t) - \theta_{g_S}(t)). \quad (18)$$

A seguir, é apresentado as matrizes no espaço de estados expandidas, em que \bar{C} depende da quantidade de segmentos confiáveis conforme a Tabela 1.

$$\bar{A} = \begin{bmatrix} A_B & 0_{6 \times 6} & 0_{6 \times 6} \\ 0_{6 \times 6} & A_T & 0_{6 \times 6} \\ 0_{6 \times 6} & 0_{6 \times 6} & A_S \end{bmatrix},$$

$$A_i = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & -\frac{1}{\tau_{g_{i_R}}} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & -\frac{1}{\tau_{g_{i_P}}} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -\frac{1}{\tau_{g_{i_Y}}} \end{bmatrix},$$

$$\bar{B} = I_{18},$$

Tabela 1. Matriz \bar{C} para os estados selecionados

nº segmentos confiáveis	$\bar{C}(\Theta(t))$
1	$\begin{bmatrix} M_B & M_T & M_S \\ r & -r & 0_{3 \times 6} \\ 0_{3 \times 6} & -r & r \end{bmatrix}$
2	$\begin{bmatrix} M_B & M_T & 0_{3 \times 6} \\ 0_{3 \times 6} & M_{T_2} & M_S \\ r & -r & 0_{3 \times 6} \\ 0_{3 \times 6} & -r & r \end{bmatrix}$
3	$\begin{bmatrix} M_B & 0_{3 \times 6} & 0_{3 \times 6} \\ 0_{3 \times 6} & M_T & 0_{3 \times 6} \\ 0_{3 \times 6} & 0_{3 \times 6} & M_S \\ r & -r & 0_{3 \times 6} \\ 0_{3 \times 6} & -r & r \end{bmatrix}$

Fonte: Autor

Finalmente, os modos de operação de acordo com o número de segmentos confiáveis da Tabela 1 são apresentados na Tabela 2, onde a matriz S_{RPY} descrito pela Equação (19) é comum a todos os segmentos.

$$S_{RPY} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \quad (19)$$

Tabela 2. Modos de operação do SMEA

Estados ($\Theta(t)$)	$M_B(t)$	$M_T(t)$	$M_S(t)$	M_{T_2}
B	S_{RPY}	$0_{3 \times 6}$	$0_{3 \times 6}$	-
T	$0_{3 \times 6}$	S_{RPY}	$0_{3 \times 6}$	-
S	$0_{3 \times 6}$	$0_{3 \times 6}$	S_{RPY}	-
BT	S_{RPY}	$0_{3 \times 6}$	$0_{3 \times 6}$	S_{RPY}
BS	S_{RPY}	$0_{3 \times 6}$	S_{RPY}	$0_{3 \times 6}$
TS	$0_{3 \times 6}$	S_{RPY}	S_{RPY}	$0_{3 \times 6}$
BTS	S_{RPY}	S_{RPY}	S_{RPY}	-

Fonte: Autor

3. RESULTADOS E IMPLEMENTAÇÕES

Nesta seção serão apresentados os resultados do Sistema Markoviano Articular com uso de *Strapdown* e Ciclos de Marcha (SMEA-SCM).

Filtragem e strapdown: A primeira etapa para uso do SMEA-SCM está em implementar o *strapdown* de forma a separar a aceleração dinâmica da estática, sendo realizado como descrito na Seção 2.1, Equações (1) a (6).

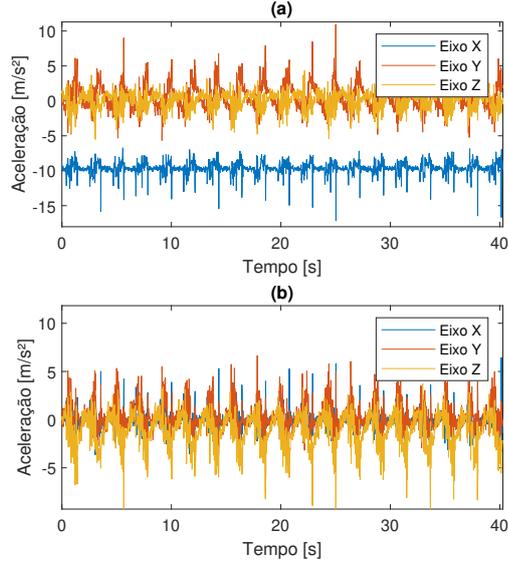


Figura 8. (a) informação triaxial do acelerômetro da coxa sem processamento, (b) informação triaxial do acelerômetro pós *strapdown*.

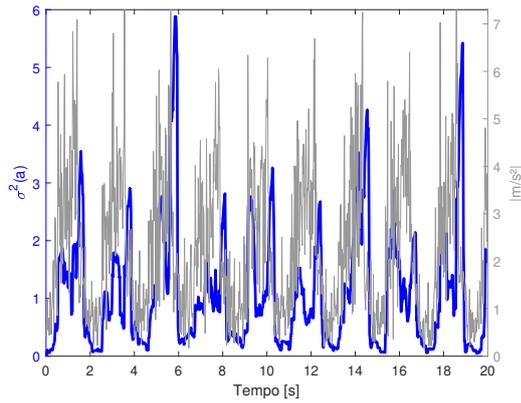


Figura 9. Gráficos da norma do acelerômetro pós processamento e da variância da norma.

Assim, para melhor visualização dos resultados do *strapdown*, será apresentado somente o processamento do segmento da coxa nas Figuras 8 e 9. Portanto, a partir da Figura 8 é possível visualizar a supressão do *offset* presente no eixo x do acelerômetro devido a interferência da gravidade. E na Figura 9 os períodos de menor aceleração dinâmica podem ser associados aos vales presentes neste, que são bem definidos pelo cálculo da variância média móvel do sinal.

Finalmente, para aplicação do Algoritmo 1, foram escolhidos empiricamente os limiares da norma da aceleração dinâmica e de sua variância como descrito abaixo.

Tabela 3. Limiares da norma da aceleração dinâmica e de sua variância.

α_{d_B}	α_{d_T}	α_{d_S}
4	2	2.5
β_{d_B}	β_{d_T}	β_{d_S}
1.5	1	0.6

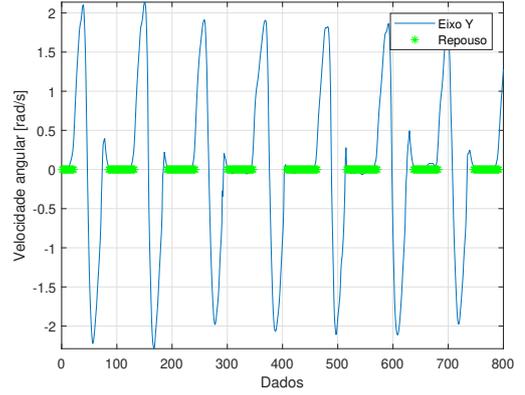


Figura 10. Gráfico do eixo-y do giroscópio do pé e momentos com o pé em repouso.

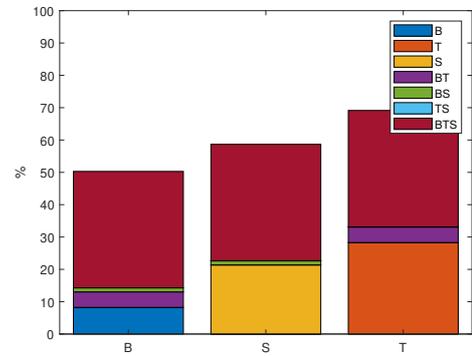


Figura 11. Quantidade de escolhas por segmento no SMeA-SCM.

Deteção de marcha: Para a implementação da máquina de estados na detecção dos ciclos de marcha, foram escolhidos os limiares, que são demonstrados nas Equações (20) a (23):

$$\alpha_1 = 0.05, \quad (20)$$

$$\alpha_2 = 0.45, \quad (21)$$

$$\alpha_3 = -1.1, \quad (22)$$

$$\alpha_4 = 0. \quad (23)$$

Na Figura 10, em azul, é apresentada a velocidade angular do giroscópio no segmento do pé para o eixo-y. Este valor foi processado por um filtro média móvel e, em verde, são os momentos em que o pé estava em repouso. Cabe ressaltar que foi utilizado um filtro média móvel com ordem máxima de 15, afim de mitigar o erro de atraso do filtro.

Sistema Markoviano Articular com uso de Strapdown e Ciclos de Marcha: após a definição dos parâmetros de *strapdown* e da máquina de estados, aplica-se o Algoritmo 1 para identificação dos estados Markovianos.

Os estados selecionados pelo SMeA-SCM apresentados nas Figuras 11 e 12, exibem uma maior seleção do estado T . Essa seleção é coerente, pois como o segmento da coxa (T) está entre o tronco (B) e a canela (S), apresentando melhor relação sinal ruído do que B e baixa intensidade de aceleração dinâmica se comparado com o segmento S para os instantes de impacto e movimento.

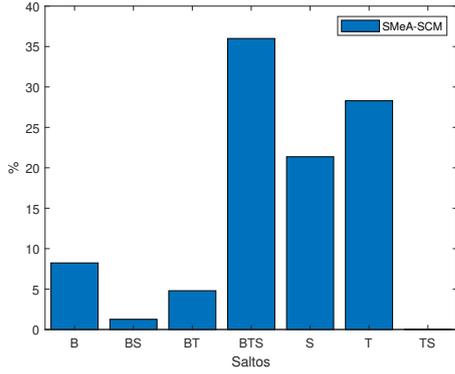


Figura 12. Porcentagem dos estados escolhidos pelos sistemas no período de análise.

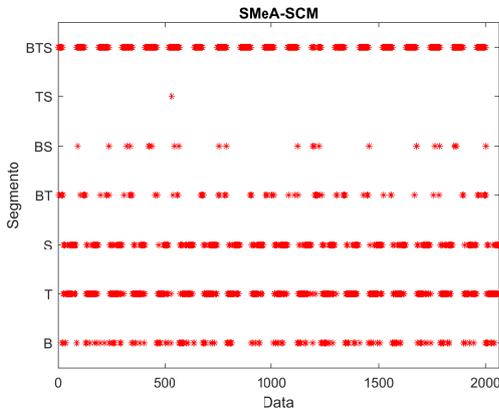


Figura 13. Escolha dos estados no tempo para o sistema.

A Figura 13 apresenta a seleção dos estados a cada instante para o sistema. Nela, verifica-se que o SMeA-SCM possui grande distribuição de escolha entre os estados. Este sistema não considerou o estado TS como uma escolha da salto viável, tendo sido escolhido pelo SMeA-SCM somente uma vez. No entanto a não escolha do estado TS está mais relacionada ao fato de que quase sempre que T e S são confiáveis o B também é confiável, não sobrando margem para o estado TS.

Finalmente, a Figura 14 apresenta a estimativa do ângulo no plano do movimento sagital, para o sistema em comparação com as referências ótica. Visualmente é possível verificar a convergência das estimativas do Filtro de Kalman proposto em relação às referências. Nas Figuras 15 e 16 verifica-se a estimativa dos ângulos articulares do quadril e do joelho, respectivamente, e o sinal do encoder como referência. Nestas, verifica-se um melhor acompanhamento dos ângulos estimados para a articulação do joelho, e um erro de amplitude nos ângulos do quadril.

Desse modo, foram calculados os erros médio (EM), quadrático médio (EQM) e a correlação de Pearson sobre a estimativa realizada com relação a referência ótica, sendo os mesmos apresentados na Tabela 4.

Como resultado, tem-se que o SMeA-SCM realizou estimativas angulares de forma satisfatória considerando que o maior valor de erro obtido foi no segmento do tronco,

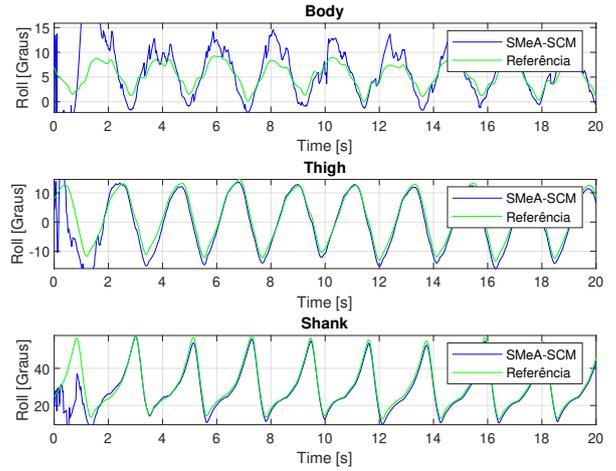


Figura 14. Ângulos absolutos nos segmentos.

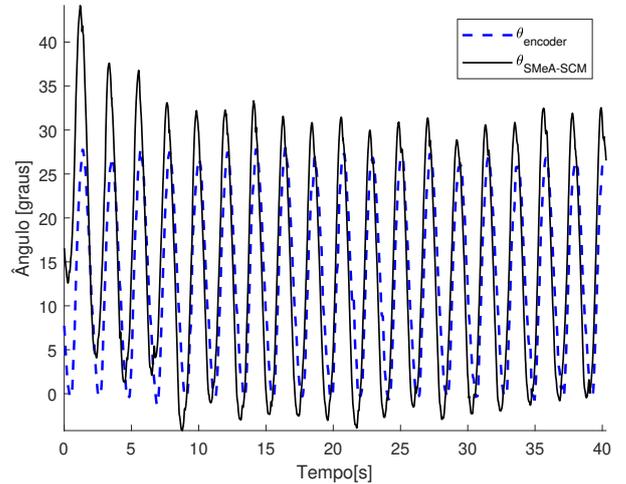


Figura 15. Ângulos articulares do quadril.

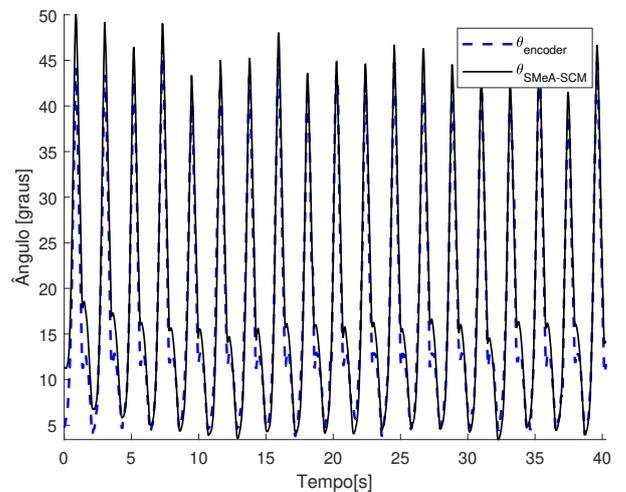


Figura 16. Ângulos articulares do joelho.

segmento este que possui baixa relação sinal-ruído e baixa amplitude de movimento.

4. CONCLUSÃO

Neste estudo foi proposto e desenvolvido uma abordagem para melhor seleção de estados Markovianos para sistemas de estimativa de ângulos de orientação e articulares. Sendo possível a identificação da escolha coerente de estados Markovianos relacionado aos momentos conhecidos de baixa aceleração dinâmica, além da menor escolha do sensor do tronco (B) como confiável, uma vez que o mesmo apresenta a menor relação sinal/ruído induzindo o sistema ao uso exagerado do segmento para o sistema Markoviano colaborativo.

Os resultado obtidos foram coerentes com o sistema de referência ótico utilizado, apresentando correlação de Pearson acima de 0.996 e erros médios para os segmentos T e S abaixo de $EM=1.26$ e $EMQ=1.43$, para os ângulos no plano sagital do movimento. Como era esperado os erros médios para o segmento B foram mais significativos, no entanto, a correlação deste também foi coerente, ficando acima de 0.80. Além disso, também foram obtidos valores coerentes da estimativa de ângulos articulares tanto para a articulação do quadril com correlação de 0.88 como para o joelho com 0.99, e como era esperado a influência do segmento do tronco também impactou a negativamente a estimativa do ângulo articular do quadril, produzindo EM e EQM significativos da ordem de 4.95 e 6.99, enquanto que o joelho obteve-se $EM=1.27$ e $EQM=3.20$. Assim, pode-se dizer o resultado de estimativas articulares com dois segmentos de boa precisão de orientação, como coxa e canela, fornecem estimativas precisas e confiáveis para o ângulo da articulação. No enquanto, que a mistura de um segmento com estimativa de orientação precisa com um outro de baixa precisão, ainda assim poderá fornecer estimativas razoáveis de precisão para o ângulo articular.

Por fim, acredita-se que escolha dos estados Markovianos com maior coerência torne o sistema mais robusto para estimativas de longo prazo. Estudos futuros serão realizados para confirmar a viabilidade e robustez do sistema para estimativas de longo prazo de execução.

AGRADECIMENTOS

Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) Projeto 128770/2020 – 1, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) Projeto 88882.441241/2019 – 01, Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo 2020/13936 – 8.

Tabela 4. Margens.

Estimativa _{segmento}	EM	EQM	Corr. Pearson
sagital _B	1.7469	2.1659	0.8038
sagital _T	1.1815	1.3950	0.9957
sagital _S	1.2559	1.4347	0.9983
articular _h	4.9540	5.8128	0.8843
articular _k	1.2651	1.9751	0.9934

REFERÊNCIAS

- A. Olivares, J.M. Górriz, J.R.e.G.O. (2016). Using frequency analysis to improve the precision of human body posture algorithms based on kalman filters. *Computers in Biology and Medicine*, 72, 229–238. doi:10.1016/j.compbiomed.2015.08.007.
- B.O.S. Teixeira, L.A. Aguirre, L.T. (2010). Filtragem de kalman com restrições para sistemas não-lineares: Revisão e novos resultados. *Revista Controle Automação*, 21(2), 127–146. doi:10.1590/s0103-17592010000200003.
- Caltran, C. and Siqueira, A.A.G. (2010). Position estimation of an active ankle-foot orthosis using sensor fusion. In *International Conference on Applied Bionics and Biomechanics - ICABB*.
- E. Francelino, e.a. (2022). Markov system with self-aligning joint constraint to estimate attitude and joint angles between two consecutive segments. *J Intell Robot Syst*, 104(3), 43. doi:10.1007/s10846-022-01572-w.
- F. Sado, H.J. Yap, R.G.N.A. (2018). Exoskeleton robot controlfor synchronous walking assistance in repetitive-manual handling works based on dual unscented kalmanfilter. *PLOS ONE*, 13(7). doi:10.1371/journal.pone.0200193.
- Francelino, E.H. (2021). Sistema markoviano espacial autoalinhável para estimativa angular de atitude e articular entre dois segmentos consecutivos.
- H.J. Luinge, P.H. Veltink, C.B. (2007). Ambulatory measurement of arm orientation. *Journal of Biomechanics*, 40(40), 78–85. doi:10.1016/j.jbiomech.2005.11.011.
- H.J. Luinge, P.V. (2004). Inclination measurement of human movement using a 3-d accelerometer with autocalibration. *IEEE Transactions on neural systems and rehabilitation engineering*, 12(1). doi:10.1109/tnsre.2003.822759.
- Laut, J., Porfiri, M., and Raghavan, P. (2016). The present and future of robotic technology in rehabilitation. *PubMed*, 4(11). doi:10.1007/s40141-016-0139-0.
- Nogueira, S. (2015). *Sistemas Markovianos para estimativa de ângulos absolutos em exoesqueletos de membros inferiores*. phdthesis, Universidade de São Paulo, São Carlos.
- Park, S.K. and Suh, Y.S. (2010). A zero velocity detection algorithm using inertial sensors for pedestrian navigation systems. *Sensors*, 10(10), 9163–9178. doi:10.3390/s101009163. URL <https://www.mdpi.com/1424-8220/10/10/9163>.
- R.E.Kalman (1960). A new approach to linear filteringand prediction problems. *ASME–Journal of Basic Engineering*, 82, 35–45. doi:10.1115/1.3662552.
- S. Nogueira, A. Siqueira, R.I.e.M.T. (2014). Markov jump linear systems-based position estimationfor lower limb exoskeletons. *Sensors*, 14(1), 1835–1849. doi:10.3390/s140101835.
- T. Watanabe, H. Saito, E.K.e.K.N. (2011). A preliminary test of measurement of joint anglesand stride length with wireless inertial sensors for wearable gait evaluation system. *Hindawi Publishing Corporation Computational Intelligence and Neuroscience*, 12. doi:10.1155/2011/975193.