

Identificação do estado Markoviano para salto em abordagens colaborativas de estimativa angular¹

Lucca Baldocchi Castro*, Samuel Lourenço Nogueira⁺

Resumo— Este trabalho de conclusão de curso propõe uma metodologia para aperfeiçoar a identificação de saltos Markovianos em sistemas colaborativos, afim de aprimorar a estimativa angular articular e de orientação em segmentos consecutivos do corpo humano e em dispositivos robóticos articulados. A metodologia proposta consiste na aplicação combinada das estratégias de *strapdown*, máquinas de estados finitos e estatística com o intuito de identificar simultaneamente os sensores com menor aceleração dinâmica e maior relação com o movimento. Para tanto, foi implementado um Sistema Markoviano Espacial Articular utilizando *strapdown* e Ciclos de Marcha. A acurácia do modelo foi avaliada analisando os resultados obtidos através da correlação de Pearson e do Erro Quadrático Médio (EQM). Dessa forma, para os ângulos de movimentos no plano sagital foram obtidas as correlações de Pearson de 0,80 para o tronco e de mais de 0,996 para os demais segmentos, com EQM de 2,17 para o tronco e abaixo de 1,43 para os demais. A correlação obtida para o ângulo articular do joelho foi de 0,99 com EQM de 1,27, o que demonstra a eficiência do método para segmentos que possuem estimativa confiável de orientação, de forma que não ocorre com a mesma acurácia para articulação do quadril, uma vez que esta depende do segmento do tronco.

Palavras Chaves— Navegação; Filtro; exoesqueleto; solidário; IMU.



1 Introdução

O uso da robótica como tecnologia aplicada a favor da reabilitação de pacientes tem se difundido diariamente desde o início século XXI. Esta tecnologia pode promover a eficiência terapêutica, principalmente em reabilitação da marcha de lesionados medulares e de pós-acidente vascular encefálico, através de treinamentos consistentes por longos períodos. Ainda, possibilita coletas constantes de dados que permite diagnosticar comorbidades e avaliar o progresso do tratamento [1].

Via de regra, os dispositivos robóticos devem ser anexados ao corpo do paciente para coletar informações e atuar de forma colaborativa. Consequentemente, devem se integrar de forma complacente ao paciente de forma a não exercer a força máxima suportada pelo usuário e não ultrapassar os movimentos angulares possíveis. Para evitar que o WR (do inglês, *Wearable Robotics*) gere danos ao usuário, desencadeado pela propagação de pequenas falhas de medição e estimativa, seu sensoriamento deve ser extremamente cuidadoso [2].

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. A obtenção desses dados pode ser feita através da aplicação de Unidades de Medição Inercial, do inglês *Inertial Measurement Units* (IMU) como demonstrado em [3] e [4]. Unidades de Medição Inercial são dispositivos que agregam dois ou mais sensores inerciais, sendo normalmente compostos por

giroscópio, acelerômetro e magnetômetro montados em um triedro ortogonal definido por três eixos, onde cada sensor é alinhado a um eixo. Desse modo, as IMUs normalmente fornecem as informações de velocidade angular, aceleração e campo magnético em relação a um referencial inercial.

Sistemas de navegação inerciais que fazem uso de sensores de baixo custo são consideravelmente afetados por erros de medição. Dessa forma, torna-se necessária a aplicação de metodologias que considerem as possíveis incertezas paramétricas e dinâmicas do sistema. Regularmente são aplicadas metodologias de fusão e filtragem dos sinais para tratar esses dados, como a clássica abordagem proposta por Kalman [5] e suas derivações *Unscented Kalman Filter* (UKF), *Markovian Kalman Filter* (MKF) e o Filtro de Kalman Estendido (FKE).

Diversos estudos demonstram a melhoria da estimativa dos ângulos de orientação para segmentos do corpo através do uso de um Filtro de Kalman frente a um filtro passa-baixa [4]. O sistema apresentado em [6] incorpora restrições geométricas articulares no cotovelo que consideram o ângulo de adução consideravelmente pequeno. Os estudos realizados em e [7] e [8], utilizam de parâmetros do sistema para alterar a atuação do filtro, respectivamente através de saltos entre estados Markovianos definidos e da frequência do movimento. No primeiro, são definidas restrições articulares modeladas para que o sistema necessite apenas de um acelerômetro a cada instante, possibilitando melhorar a correção do FK ao escolher, a cada instante, o sensor mais confiável definido pela menor incidência de aceleração dinâmica. A utilização do UKF em [9] provoca um melhor desempenho em relação ao FKE por ter sido inicialmente desenvolvido para atender sistemas não lineares [10]. Ainda, sistemas com base fixa e junção bola-soquete apresentam modelos de filtro independente da aceleração externa sofrida

- *Graduando*: *L.B. Castro do Departamento de Engenharia Elétrica da Universidade Federal de São Carlos
E-mail: lc.baldocchi@gmail.com
- *Orientador*: +S. Nogueira docente do Departamento de Engenharia Elétrica da Universidade Federal de São Carlos.

¹ Pesquisa realizada com apoio do CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil.

pelo sensor [11].

A modelagem colaborativa de um filtro de Kalman sujeito à saltos Markovianos (MKF), apresentada em [7], demonstrou resultados promissores em sistemas com restrições articulares. Esse modelo se diferencia por, aplicar restrições articulares munido de todos os sensores inerciais fixados no corpo, enquanto outros sistemas geralmente performam estimativas isoladas por articulação. Desse modo, a cadeia de Markov é composta pelas IMU onde cada estado é definido como o sensor mais confiável a cada instante. A confiabilidade do sensor é quantizada através da menor incidência de aceleração dinâmica. A metodologia ainda apresenta rápida resposta dinâmica em virtude da utilização do FK complementar que atua somente na combinação dos erros dos sinais modelados com os erros dos sinais auxiliares, o que proporciona minimizar distorções e atrasos nos sinais modelados e menos atraso no tempo de filtragem.

As acelerações coletadas pelos sensores são compostas por elementos dinâmicos, gravitacionais, ruído branco gaussiano e *offset*, no qual os três últimos elementos performam influência direta nos algoritmos de navegação inercial. Somente o ruído de medida e o *offset* podem ser facilmente modelados, de forma que um sistema pode se beneficiar com o aumento de precisão das estimativas angulares através da identificação mais precisa dos sensores com menor aceleração dinâmica.

Cabe ressaltar que este trabalho de conclusão de curso foi submetido e aceito para ser apresentado no XXIV Congresso Brasileiro de Automática (CBA), sendo esta monografia de conclusão de curso uma versão estendida do trabalho submetido. Esta monografia estima estabelecer metodologias para classificar os acelerômetros com menor incidência de aceleração dinâmica, combinando-as a um sistema Markoviano. Assim, a melhor condição de salto identificada a cada instante proporciona realizar estimativas angulares de orientação e articulação por meio de IMUs posicionadas em três segmentos consecutivos do corpo humano: tronco, coxa e canela. Com a finalidade de obter o resultado esperado, a metodologia de identificação de salto foi elaborada com os fundamentos de *strapdown*, fusão de sinais e fases do caminhar e aliada aos desenvolvimentos de estimativa angular realizados em [12] e [13].

2 Aspectos Metodológicos

Este estudo faz uso dos sinais coletados por três IMUs dispostas em três segmentos consecutivos do corpo humano, como ilustrado na Figura 1. Vale ressaltar que um quarto sensor foi utilizado no segmento do pé apenas para a identificação dos ciclos de marcha, posto que a anatomia deste promove movimento majoritariamente biarticulado em função do tornozelo e dedos, o que dificulta o seu uso para estimar os ângulos do tornozelo. Nas seções subsequentes, serão abordadas as principais metodologias utilizadas: *Strapdown* na Seção 2.1, Detecção de Marcha Humana na Seção 2.4, Sistema Markoviano Espacial Articular com *Strapdown* e Ciclos de Marcha proposto neste trabalho na Seção 2.5.

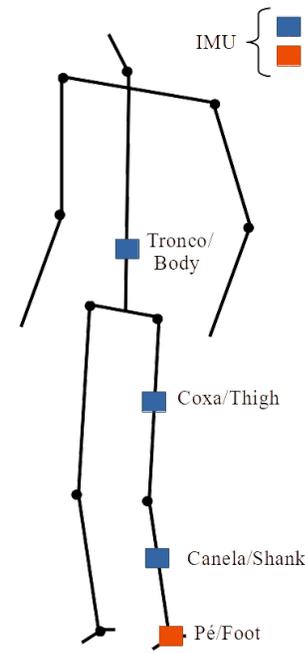


Figura 1: Posicionamento dos sensores inerciais (IMU) no corpo humano.

2.1 Navegação inercial e Strapdown

A navegação inercial possibilita rastrear a posição e orientação de um objeto em relação a um ponto de partida. Assim, a situação ideal para o cálculo da velocidade e posição ocorre quando o corpo realiza somente movimentos de translação de forma que a atuação da gravidade seja conhecida e facilmente identificada sobre os eixos do acelerômetro. Dessa forma, a posição do corpo poderia ser obtida através da integração sucessiva da aceleração e velocidade.

Metodologias de navegação inercial utilizam a combinação de sensores inerciais e de posicionamento para realizar a estimativas de orientação e de posicionamento de corpos no espaço.

O processo da navegação inercial de interesse denomina-se *strapdown* e é responsável por separar a componente gravitacional das componentes de aceleração dinâmica. Assim, através de matrizes de rotação é possível alterar a referência dos eixos dos sensores inerciais utilizando predições de orientação dadas pelo giroscópio corrigido através dos dados do acelerômetros em movimento uniforme. Os passos dessa metodologia são apresentados na Figura 2.

Dessa forma, a separação do sinal em componentes de aceleração gravitacional e dinâmica pode ser visualizada na Equação (1), onde o referencial do acelerômetro passa a ser global e na Equação (2), onde obtém-se somente as componentes dinâmicas. O cálculo da orientação atual predita pelo giroscópio através da integração da velocidade angular, amostrada em períodos iguais a δt , e a obtenção da matriz de rotação estão presentes na Equação (3).

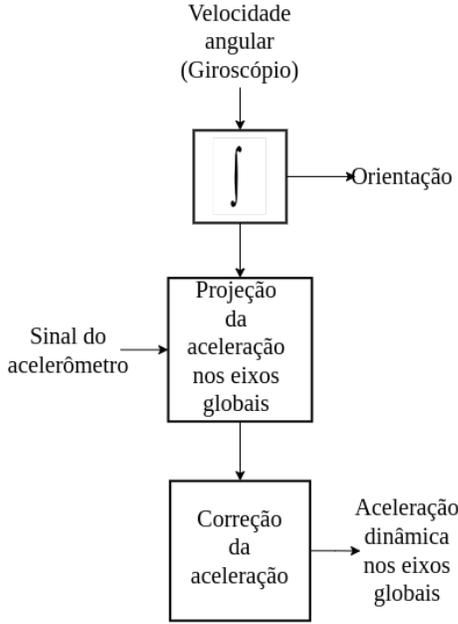


Figura 2: Processo de remoção da gravidade.

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

$$a_{Dinmica}(t) = a_g(t) - g_g(t) \quad (2)$$

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

Para pequenos intervalos de tempo, podemos aproximar a integração numericamente através de retângulos. Dessa forma, o resultado da integração na Equação (4) pode ser aproximado pela Equação (5), onde através da expansão de Taylor é obtida a implementação final do calculo periódico da matriz de rotação contida na Equação (6).

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

$$B = \begin{bmatrix} 0 & -\omega_{bz}\delta t & \omega_{by}\delta t \\ \omega_{bz}\delta t & 0 & -\omega_{bx}\delta t \\ -\omega_{by}\delta t & \omega_{bx}\delta t & 0 \end{bmatrix} \quad (5)$$

$$C(t + \delta t) = C(t)\left(I + \frac{\sin\sigma}{\sigma}B + \frac{1 - \cos\sigma}{\sigma^2}B^2\right) \quad (6)$$

As variáveis acima são apresentadas como sendo $\omega_b = (\omega_{bx}, \omega_{by}, \omega_{bz})^T$ as velocidades angulares do giroscópio em cada eixo, 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, B a matriz de ângulos e $\sigma = |\omega_b\delta t|$.

Ainda, em posse dos dados nos eixos globais, poderiam ser retiradas outras interferências dos dados dos sensores, como a aceleração de Coriolis e a aceleração Centrifuga, como abordado em [14].

2.2 Filtro complementar

As integrações realizadas pelo processo de *strapdown* sofrem, com o passar do tempo, com a propagação do erro ocasionado pelo ruído do giroscópio, culminando em um padrão denominado *drift* ou deriva. Dessa forma, muito rapidamente, torna-se perceptível uma inclinação angular no gráfico de acelerações dinâmicas obtidas após o processo de *strapdown*.

Filtros que realizam fusão de sinais são bastante utilizados na literatura para tratar a deriva do sinal em sensores inerciais. Conhecido pela facilidade de aplicação e baixo custo computacional, o filtro complementar é recorrentemente utilizado para este fim.

Um filtro complementar funciona, basicamente, combinando um filtro passa-baixa aplicado a um sinal ruidoso em altas frequências e um filtro passa-alta aplicado a outro sinal com ruído em baixas frequências. Desse modo, a Figura 3 demonstra a aplicação do filtro no problema em questão, com $\beta = 0.02$, onde θ^g é o ângulo calculado através do giroscópio, θ^a é o ângulo calculado trigonometricamente através do acelerômetro e θ^{fc} é o ângulo estimado pelo filtro complementar.

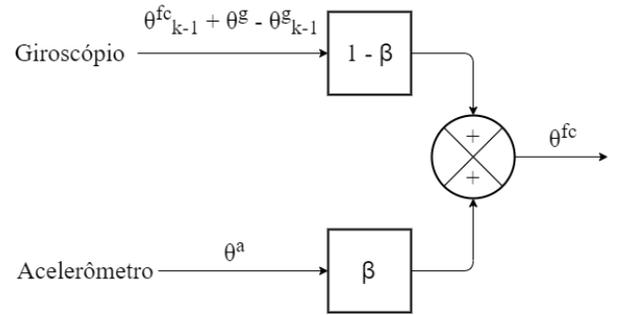


Figura 3: Filtro complementar para o processo de *strapdown*

Abaixo, na Equação (7), está o equacionamento utilizado para obter o ângulo corrigido θ^{fc} a cada instante k .

$$\theta_k^{fc} = (1 - \beta)(\theta_{k-1}^{fc} + \theta^g - \theta_{k-1}^g) + \beta\theta^a \quad (7)$$

Dessa forma, a deriva é eliminada ao substituir no processo de *strapdown* os ângulos dos dados do giroscópio pelos ângulos estimados pelo filtro complementar.

2.3 Variância do acelerômetro

Este estudo tem como interesse identificar os instantes onde ocorrem aceleração dinâmicas com o intuito de evita-las. Entretanto, como ficará evidente na seção 3, o algoritmos de

strapdown e filtro complementar implementados não foram suficientes para remover por completo a aceleração dinâmica dos dados do acelerômetro, restando um pequeno resíduo.

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 que a mesma incide sobre o sinal do acelerômetro, seria através da combinação da amplitude do sinal medido com a variância média móvel.

A variância, por definição, é uma medida de dispersão que mostra o quão distante cada valor do conjunto está do valor médio. Esse conceito se mostra aplicável ao problema na identificação dos momentos de baixa aceleração dinâmica, pois pode ser utilizado como um filtro para determinar o espaço de tempo com menores acelerações.

Equação (8) 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. Assim, a cada período δt , um novo valor $k + 1$ é analisado.

$$S^2 = \frac{\sum_{i=1}^n (x(k) - \bar{x})^2}{n - 1} \quad (8)$$

Deste modo, pode-se comparar o resultado esperado com a Figura 4 que apresenta duas ondas, uma senoidal e outra quadrada. Espera-se que a variância delimite os vales de baixa aceleração assim como a onda quadrada recorta o vale da onda senoidal.

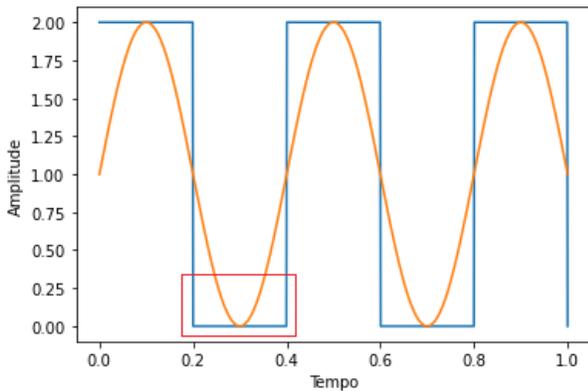


Figura 4: Exemplo de resultado esperado com a aplicação da variância.

2.4 Detecção de marcha

Estratégias que empregam sensores de força resistivos presentes no solado do pé operando como uma chave para identificar os momentos em que o pé está em repouso, também possibilitam avaliar os momentos com baixa aceleração dinâmica [15]. Dessa forma, quando o pé está em contato com o solo, a movimentação da perna como um todo é baixa.

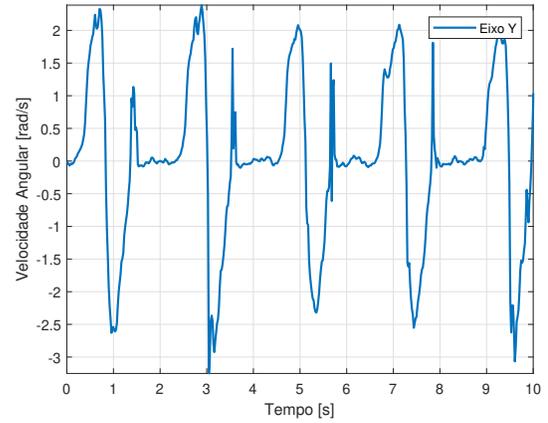


Figura 5: Padrão gráfico do eixo-y do giroscópio e o movimento do pé no ciclo de caminhada.

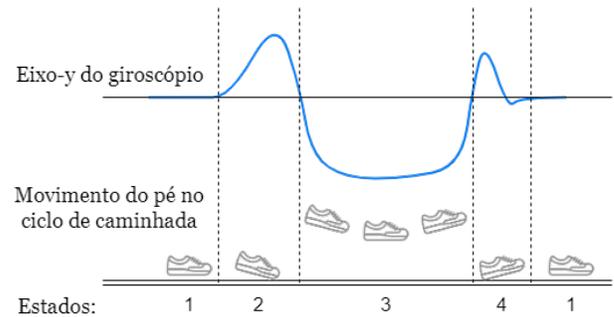


Figura 6: Padrão gráfico do eixo-y do giroscópio e o movimento do pé no ciclo de caminhada; Fonte: Obtido de [16].

O tempo de repouso do pé em um ciclo normal de marcha como um curto período (aproximadamente de 0.1 a 0.3s) [16]. Esse repouso é identificado através da detecção 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 análise é beneficiada pela escolha do sensor que melhor represente o movimento, sendo este o com maior amplitude de sinal. Assim, o eixo do giroscópio deve ser o mais próximo do eixo perpendicular ao plano sagital do movimento. De acordo com o posicionamento dos sensores no problema em questão, o eixo-y foi tomado como o eixo de rotação dominante da caminhada.

A Figura 5 mostra os dados do giroscópio no tempo representando aproximadamente 4 passos do paciente. Já na Figura 6, é apresentado os estados de uma passada, sendo este dividido em quatro segmentos detalhados na Tabela 1.

Como é possível observar nas figuras 5 e 6, existe um padrão cíclico na marcha, o que possibilita o uso 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 (9) defini o estado atual da máquina através da relação entre o estado presente $f(z_m)$, o estado passado $f(z_{m-1})$ e os limiares de velocidade angular com valores α_i que devem ser definidos.

$$f(z_i) = \begin{cases} 1, z_m < \alpha_1 \text{ e } f(z_{i-m}) = 4 \\ 2, z_m > \alpha_2 \text{ e } f(z_{i-m}) = 1 \\ 3, z_m < \alpha_3 \text{ e } f(z_{i-m}) = 2 \\ 4, z_m > \alpha_4 \text{ e } f(z_{i-m}) = 3 \end{cases} \quad (9)$$

Para detectar os limiares é necessário evitar eventuais ruídos ou picos para que a transição de estado não seja realizada de forma incorreta, assim, uma boa solução é aplicar um filtro média móvel nos dados do giroscópio de forma a manter a tendência do sinal sem que ocorra a perda de informação.

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

Nesta seção será apresentada a abordagem proposta neste trabalho para a estimativa de ângulos de orientação e articulares por meio de um Sistema Markoviano Espacial Articular com *Strapdown* e Ciclos de Marcha (SMeA-SCM), sendo este baseado inicialmente no Sistema Markoviano Espacial Articular (SMeA).

O SMeA apresentado em [13] é responsável por realizar a estimativa angular espacial entre dois segmentos consecutivos da perna. Neste são utilizados saltos Markovianos para transitar entre os estados representados pelas IMUs mais confiáveis, com menor aceleração dinâmica, a cada instante. No entanto, o SMeA se fundamenta em condições simplificadas para determinar a confiabilidade do sensor, sendo essas condições dependentes da norma mínima entre os acelerômetros presentes no modelo e da gravidade local. Tais requisitos de confiabilidade estão representados na Equação (10).

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

Através da Figura 7 e da Equação (10), torna-se visível que o modelo elaborado até o momento baseou-se apenas no uso dos segmentos consecutivos da coxa e da canela, sendo os resultados $\{1, 2 \text{ e } 3\}$ respectivamente $\{T, S \text{ e } TS\}$ e λ correspondente ao número de acelerômetros com baixo nível de aceleração dinâmica a cada instante. Dentre as possibilidades, TS está presente como o estado nominal do sistema.

Tabela 1: Estados do ciclo de caminhada.

Estado	Posição do pé	Valor do giroscópio
1	Repouso	0
2	Decolagem	> 0
3	Balanço	< 0
4	Contato	> 0

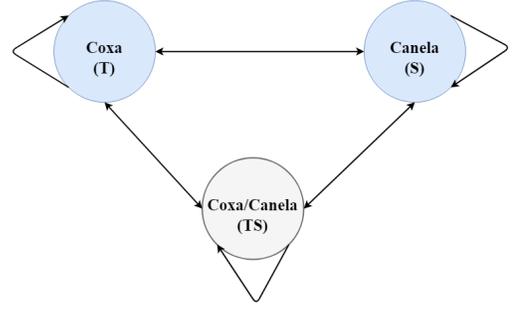


Figura 7: Diagrama de transição de estados SMeA.

Nessa seção, o modelo elaborado em [13] será expandido para três segmentos e um sistema de identificação do estado Markoviano será proposto em substituição a Equação (10).

A Figura 8 apresenta os sete estados Markovianos, indicados pelas iniciais em inglês de cada segmento do corpo, como determinado 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, caso o sistema proposto em [13] fosse expandido utilizando os mesmos requisito iniciais, as regras para salto seriam:

$$\Theta(t) := \begin{cases} 7, & \text{para } \lambda = 3 \\ (||a_i|| - g_e) \leq \alpha_i & \text{para } \lambda = 2 \\ \arg \min_i (||a_i|| - g_e), & \text{para } \lambda \leq 1 \end{cases} \quad (11)$$

sendo os resultados $\{1, 2, 3, 4, 5, 6, 7\}$ correspondentes a $\{B, T, S, BT, BS, TS, BTS\}$, α_i correspondente a um determinado limiar de aceleração dinâmica em cada segmento e λ igual ao número de acelerômetros com baixa 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 9, que exhibe no fluxo em verde a variância do acelerômetro, em vermelho e em azul o processo de *strapdown* sendo o primeiro, a rotação e remoção da gravidade do acelerômetro e o segundo, o cálculo da matriz de rotação com uso do filtro complementar. Ainda, em laranja tem-se a identificação dos estados do pé através da máquina de estados.

As condições de salto são definidas pelo Algoritmo 1, o qual substitui a Equação (11) 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:

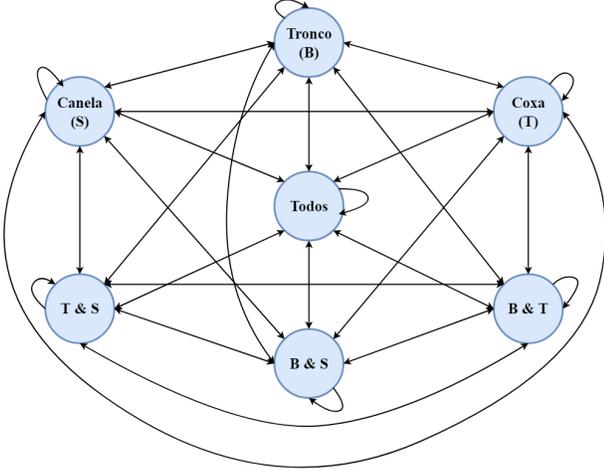


Figura 8: Diagrama de transição de estados SMEA-SCM.

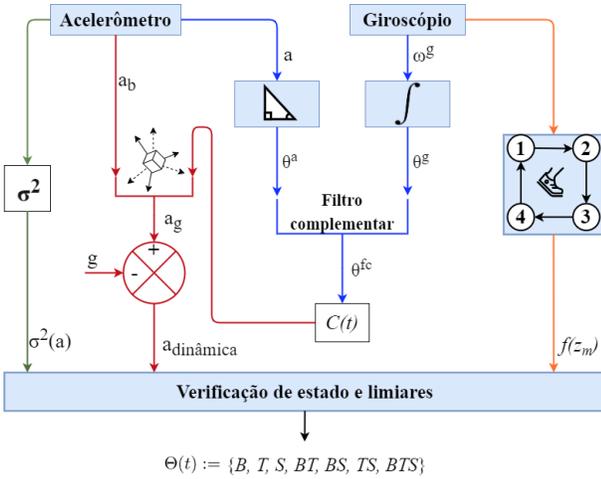


Figura 9: Diagrama do sistema identificador do estado Markoviano.

Algorithm 1 : VERIFICAÇÃO DE ESTADO E LIMIARES

Inicialize:

while corpo em movimento **do**

$segmn = []$

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

$z_m = \text{Equação (9)}$

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

$$\dot{x}(t) = \bar{A}x(t) + \bar{B}w(t), \quad (12)$$

$$y(t) = \bar{C}(\Theta(t))x(t) + v(t), \quad (13)$$

sendo o vetor de estados $x(t)$ é definido conforme a Equação (14) e $x_i(t)$ para $i = \{B, T, S\}$ conforme a Equação (15).

As variáveis $\Delta\theta_{i_j}$ e Δb_{i_j} são, respectivamente, os erros de medida angular e de polarização de cada eixo dos sensores, sendo que $j = \{R, P, Y\}$ representa os ângulos de rolagem (*Roll*), arfagem (*Pitch*) e guinada (*Yaw*) sobre os eixos x , y e z de cada sensor.

$$x(t) = [x_B(t) \ x_T(t) \ x_S(t)]^T \quad (14)$$

$$x_i(t) = [\Delta\theta_{i_R}(t) \ \Delta b_{i_R}(t) \ \Delta\theta_{i_P}(t) \ \Delta b_{i_P}(t) \ \Delta\theta_{i_Y}(t) \ \Delta b_{i_Y}(t)] \quad (15)$$

Na Equação (13) é acrescentado o erro de estimativa do ângulo relativo da articulação do quadril, do inglês *hip* (h), conforme apresentado abaixo:

$$y(t) = [\Delta\theta_{\Theta(t)_R} \ \Delta\theta_{\Theta(t)_P} \ \Delta\theta_{\Theta(t)_Y} \ \Delta h \ \Delta k], \quad (16)$$

$$\Delta\theta_{\Theta(t)_j} = \theta_{\Theta(t)_j} - \theta_{g_{\Theta(t)_j}}, \quad (17)$$

$$\Delta h = \alpha_{h_{acel+giro}}(t) - (\theta_{g_B}(t) - \theta_{g_T}(t)). \quad (18)$$

$$\Delta k = \alpha_{k_{acel+giro}}(t) - (\theta_{g_T}(t) - \theta_{g_S}(t)). \quad (19)$$

A Equação (17) corresponde ao erro entre a medida do ângulo proveniente do acelerômetro mais confiável $\theta_{\Theta(t)_j}$ e o giroscópio correspondente $\theta_{g_{\Theta(t)_j}}$.

As Equações (18) e (19) exibem o cálculo do erro de medida entre, respectivamente, o ângulo articular da bacia e do joelho obtidos a partir do método [13] de estimativa de ângulos articulares utilizando sensores inerciais auto alinháveis $\alpha_{h_{acel+giro}}(t)$ e $\alpha_{k_{acel+giro}}(t)$ subtraindo com o plano de maior movimento da articulação.

A seguir, são apresentadas as matrizes no espaço de estados expandidas, em que \bar{C} depende da quantidade de segmentos confiáveis conforme a Tabela 2.

$$\bar{A} = \begin{bmatrix} A_B & 0_{6 \times 6} & 0_{6 \times 6} \\ 0_{6 \times 6} & A_T & 0_{6 \times 6} \\ 0_{6 \times 6} & 0_{6 \times 6} & A_S \end{bmatrix}, \quad (20)$$

$$A_i = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & -\frac{1}{\tau_{g_{iR}}} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & -\frac{1}{\tau_{g_{iP}}} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -\frac{1}{\tau_{g_{iY}}} \end{bmatrix}, \quad (21)$$

$$\bar{B} = I_{18}, \quad (22)$$

A Equação (21) apresenta o termo $\tau_{g_{ij}}$, compreendido como a constante de tempo ou tempo de correlação de Gauss-Markov de cada eixo.

Tabela 2: Matriz \bar{C} para os estados selecionados

n ^o 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 2 são apresentados na Tabela 3, onde a matriz S_{RPY} descrito pela Equação (23) é comum a todos os segmentos.

$$S_{RPY} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \quad (23)$$

Tabela 3: 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

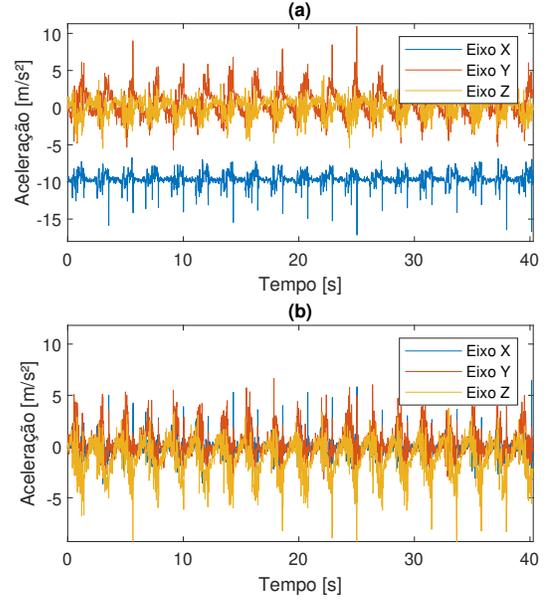


Figura 10: (a) informação triaxial do acelerômetro da coxa sem processamento, (b) informação triaxial do acelerômetro pós *strapdown*.

3 Resultados e Discussões

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

3.1 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).

Assim, para melhor visualização dos resultados do *strapdown*, será apresentado somente o processamento do segmento da coxa nas Figuras 10 e 11. Portanto, a partir da Figura 10 é possível visualizar a supressão do *offset* presente no eixo x do acelerômetro devido a interferência da gravidade. Já na Figura 11 os períodos de menor aceleração dinâmica podem ser associados aos vales presentes no sinal, sendo bem delimitados 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 4: Limiares da norma da aceleração dinâmica e de sua variância.

α_{dB}	α_{dT}	α_{dS}
4	2	2.5
β_{dB}	β_{dT}	β_{dS}
1.5	1	0.6

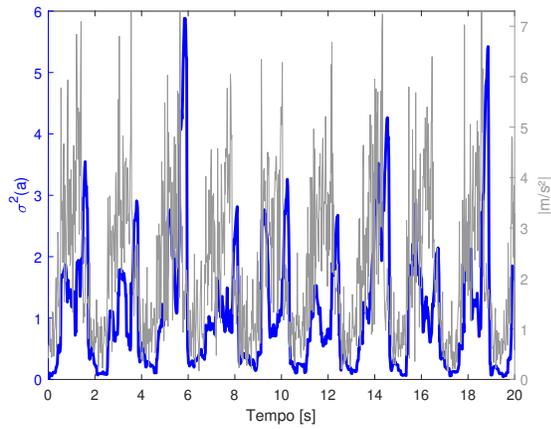


Figura 11: Gráficos da norma do acelerômetro pós processamento e da variância da norma.

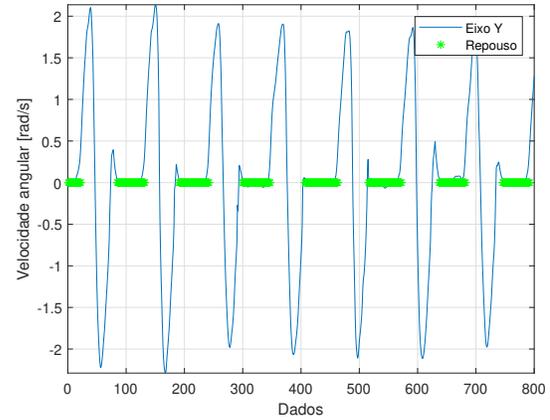


Figura 12: Gráfico do eixo-y do giroscópio do pé e momentos com o pé em repouso.

3.2 Detecção de marcha:

Para a implementação da máquina de estados na detecção dos ciclos de marcha, foram escolhidos os limiares demonstrados nas Equações (24) a (27):

$$\alpha_1 = 0.05, \quad (24)$$

$$\alpha_2 = 0.45, ; \quad (25)$$

$$\alpha_3 = -1.1, ; \quad (26)$$

$$\alpha_4 = 0. \quad (27)$$

Na Figura 12, 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, estão presentes os momentos identificados em que o pé estava em repouso.

Dessa forma, após o movimento de *strike* com o calcanhar a velocidade angular do sensor do pé alcança valores inferiores a $0,05 \left[\frac{rad}{s} \right]$, referente a α_1 . Assim, através do estado anterior identificado como o pé em balanço e os valores de velocidade angular inferiores ao limiar, a máquina de estados passa a identificar o pé em repouso. Este processo acontece de forma cíclica e similar para as demais fases do caminhar de acordo com as regras estabelecidas.

3.3 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 13 e 14, 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.

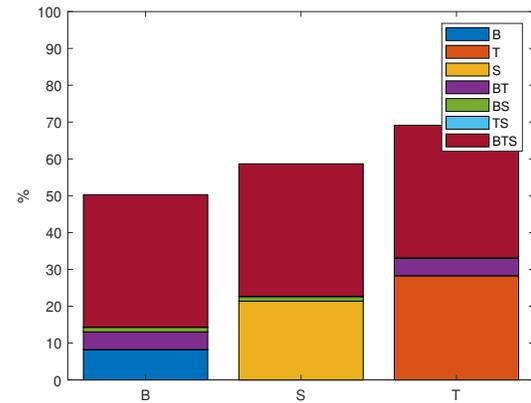


Figura 13: Quantidade de escolhas por segmento no SMeA-SCM.

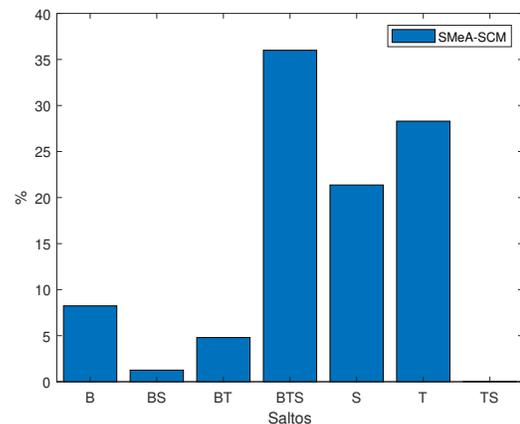


Figura 14: Porcentagem dos estados escolhidos pelos sistemas no período de análise.

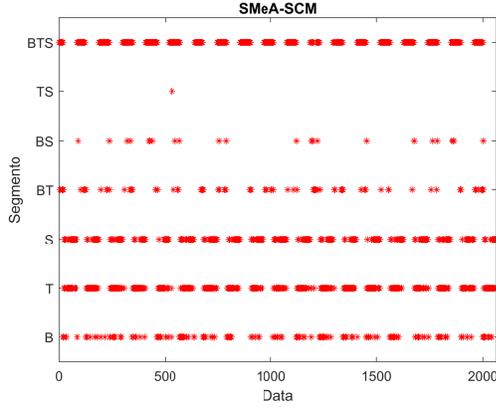


Figura 15: Escolha dos estados no tempo para o sistema.

A Figura 15 apresenta a seleção dos estados a cada instante para o sistema. Nela, verifica-se que o SMeA-SCM possui um elevado grau de 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 que quase sempre que T e S são confiáveis o B também é confiável, não sobrando margem para o estado TS.

Finalmente, a Figura 16 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 17 e 18 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 as estimativas realizadas com relação à referência ótica para os ângulos de orientação e com relação ao encoder para os ângulos articulares, sendo os mesmos apresentados na Tabela 5.

Tabela 5: 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

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

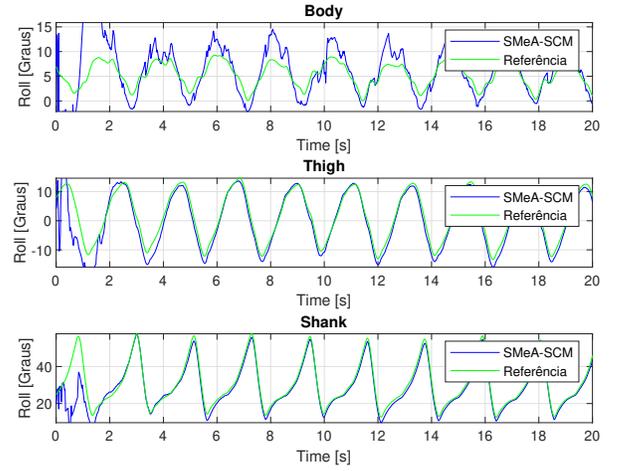


Figura 16: Ângulos absolutos nos segmentos.

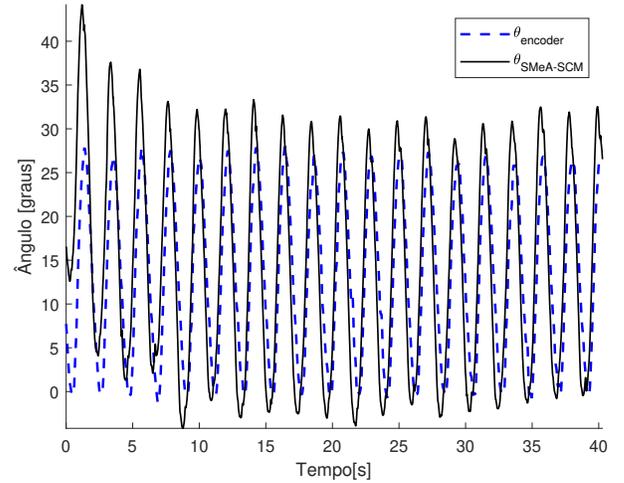


Figura 17: Ângulos articulares do quadril.

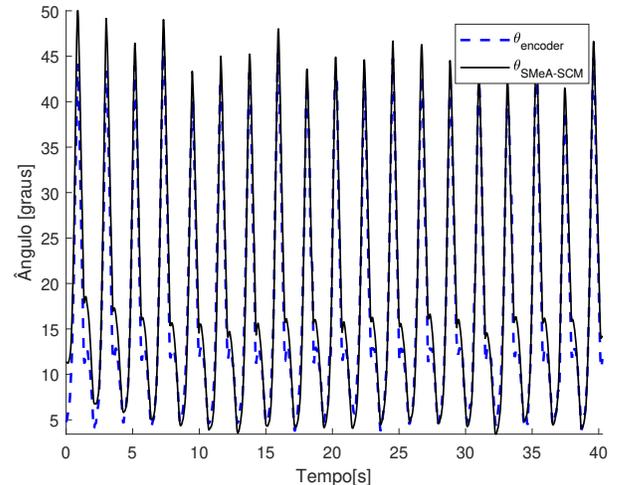


Figura 18: Ângulos articulares do joelho.

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 resultados 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 entanto, 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.

5 Expectativas de resultados futuros

Para trabalhos futuros, espera-se validar o modelo com uma larga escala de pacientes com o intuito de verificar a variabilidade e confiabilidade do sistema. Outra expectativa é a implementação do sistema para um hardware embarcado para uso em tempo real. No entanto, essas etapas podem tornar necessário otimizar os limiares e constantes, como o tempo de correlação de Gauss-Markov presente na Equação (21) que são utilizadas na predição dos ângulos para o sistema proposto de modo a obter ainda mais avanços na assertividade do método perante às referências utilizadas. Ainda, buscar sanar a dificuldade de se estimar os ângulos do tronco através da aplicação de outros equipamentos ou métodos. Dessa forma, em posse do sistema mais otimizado, performar testes para os demais planos de movimento.

Uma questão intrigante a ser estudada é a variação no padrão de movimento entre indivíduos e seu impacto no sistema. Neste sentido, pode ser necessária a elaboração de

um sistema de calibração das constantes e limiares de forma a obter o mesmo nível de precisão mesmo com a variação das características específicas no movimento de cada usuário. Para tanto, cabe neste estudo a análise das constantes que são dependentes do usuário de forma a otimizar o processo de calibração.

Agradecimentos

Gostaria de agradecer a minha família pelo apoio em todos os meus anos de estudo. Em especial, meu Pai, Iran por estar sempre ao meu lado. Também ao meu orientador, Samuel, pelos ensinamentos, amizade, oportunidades e com destaque pela enorme admiração que tenho pelo seu interesse em transmitir conhecimento. Por fim, gostaria de agradecer a quem foi minha maior base, estímulo e fonte de força a minha namorada Letícia.

Referências

- [1] J. Laut, M. Porfiri, and P. Raghavan, "The present and future of robotic technology in rehabilitation," *PubMed*, vol. 4, no. 11, dez 2016.
- [2] J. L. Pons, *Wearable Robots : Biomechatronic Exoskeletons*, J. L. Pons, Ed. Madrid, Spain: John Wiley & Sons, Ltd, 2008. [Online]. Available: <http://books.google.com/books?id=VdQeAQAIAAJ&pgis=1>
- [3] E. K. e. K. N. T. Watanabe, H. Saito, "A preliminary test of measurement of joint angles and stride length with wireless inertial sensors for wearable gait evaluation system," *Hindawi Publishing Corporation Computational Intelligence and Neuroscience*, p. 12, 2011.
- [4] P. V. H.J. Luinge, "Inclination measurement of human movement using a 3-d accelerometer with autocalibration," *IEEE Transactions on neural systems and rehabilitation engineering*, vol. 12, no. 1, Mar. 2004.
- [5] R.E.Kalman, "A new approach to linear filtering and prediction problems," *ASME-Journal of Basic Engineering*, vol. 82, pp. 35–45, 1960.
- [6] H. J. Luinge, P. H. Veltink, and C. T. M. Baten, "Ambulatory measurement of arm orientation," *Journal of Biomechanics*, vol. 40, no. 1, pp. 78–85, 2007.
- [7] S. L. Nogueira, A. A. G. Siqueira, R. S. Inoue, and M. H. Terra, "Markov jump linear systems-based position estimation for lower limb exoskeletons," *Sensors*, vol. 14, no. 1, pp. 1835–1849, 2014. [Online]. Available: <http://www.mdpi.com/1424-8220/14/1/1835>
- [8] J. R. e. G. O. A. Olivares, J.M. Górriz, "Using frequency analysis to improve the precision of human body posture algorithms based on kalman filters," *Computers in Biology and Medicine*, vol. 72, pp. 229–238, 2016.
- [9] R. G. N. A. F. Sado, H.J. Yap, "Exoskeleton robot control for synchronous walking assistance in repetitive manual handling works based on dual unscented kalman filter." *PLOS ONE*, vol. 13, no. 7, 2018.
- [10] L. T. B.O.S. Teixeira, L.A. Aguirre, "Filtragem de kalman com restrições para sistemas não-lineares: Revisão e novos resultados," *Revista Controle Automação*, vol. 21, no. 2, pp. 127–146, 2010.
- [11] M. C. J.K. Lee, "Robust inertial measurement unit-based attitude determination kalman filter for kinematically constrained links," *Sensors*, vol. 19, p. 768, 2019.
- [12] S. Nogueira, "Sistemas markovianos para estimativa de ângulos absolutos em exoesqueletos de membros inferiores," phdthesis, Universidade de São Paulo, São Carlos, 2015.
- [13] E. H. Francelino, "Sistema markoviano espacial autoalinhável para estimativa angular de atitude e articular entre dois segmentos consecutivos," 2021.

- [14] D. Santana, “Navegação terrestre usando unidade de medição inercial de baixo desempenho e fusão sensorial com filtro de kalman adaptativo suavizado,” phdthesis, Escola Politécnica da Universidade de São Paulo, São Paulo, Jul. 2011.
- [15] C. Caltran and A. A. G. Siqueira, “Position estimation of an active ankle-foot orthosis using sensor fusion,” in *International Conference on Applied Bionics and Biomechanics - ICABB*, 2010.
- [16] S. K. Park and Y. S. Suh, “A zero velocity detection algorithm using inertial sensors for pedestrian navigation systems,” *Sensors*, vol. 10, no. 10, pp. 9163–9178, 2010. [Online]. Available: <https://www.mdpi.com/1424-8220/10/10/9163>