

## Sistema de correção automática para posicionamento de sensores inerciais na estimativa de ângulo articular<sup>\*</sup>

Mateus Pereira<sup>\*</sup> Edson Francelino<sup>\*\*</sup> Lucca B. Castro<sup>\*</sup>  
Roberto S. Inoue<sup>\*\*\*</sup> Samuel Nogueira<sup>\*</sup>

<sup>\*</sup> Programa de Pós-Graduação em Engenharia Elétrica, Universidade  
Federal de São Carlos, São Carlos, SP.

<sup>\*\*</sup> Programa de Pós-Graduação em Engenharia Elétrica, Universidade  
São Paulo, São Carlos, SP.

<sup>\*\*\*</sup> Departamento de Computação, Universidade Federal de São Carlos,  
São Carlos, SP.

---

**Abstract:** This paper proposes the use of consecutive inertial sensors to estimate joint angles in the human body, as well as in rigid devices such as exoskeletons and articulated robots, considering the occurrence of possible online misalignments and automatic adaptation, promoting the system's robustness to such uncertainties. The proposal consists of modeling the problem as a spherical joint with projection of movements in the plane of greater angular amplitude, defining a minimization problem for the automatic virtual alignment of the inertial sensors. In the study, two filtering systems based on Kalman were developed to achieve the proposal, the first being used as a tool for online optimization and adjustment of the virtual alignment parameters of the sensors, while the second was responsible for the fusion of the signals in order to estimate the joint angle of the molded joint. The results obtained were promising, with a Pearson correlation of around 0.99 and RMSE close to 1° when compared with measurements from an encoder, and the system adaptation to sudden changes in orientation took a few seconds after the occurrence, this being dependent on the size of the fitting data window.

**Resumo:** Neste artigo é proposto o uso de sensores inerciais consecutivos para estimativa de ângulos articulares no corpo humano, bem como em dispositivos rígidos como exoesqueletos e robôs articulados, sendo considerado a ocorrência de possíveis desalinhamentos *online* e adaptação automática, promovendo a robustez do sistema a tais incertezas. A proposta consiste modelar o problema como uma articulação esférica com projeção dos movimentos no plano de maior amplitude angular, sendo definido um problema de minimização para o alinhamento virtual automático dos sensores inerciais. No estudo foram desenvolvidos dois sistemas de filtragem baseados em Kalman para atingir a proposta, sendo o primeiro utilizado como ferramenta de otimização e ajuste *online* dos parâmetros de alinhamento virtual dos sensores, já o segundo foi responsável pela fusão dos sinais afim de estimar o ângulo articular da junta modelada. Os resultados obtidos foram promissores, sendo obtido correlação de Pearson em torno de 0.99 e RMSE próximo de 1° quando comparados com medidas de um *encoder*, e a adaptação do sistema às mudanças bruscas de orientação foram de poucos segundos após a ocorrência, sendo esta dependente do tamanho da janela de dados de ajuste.

**Keywords:** Self-aligning sensors; unstable fixed points; Extended Kalman Filter with Constraints; Complementary Kalman Filter; exoskeleton; non-linear systems; sensor fusion.

**Palavras-chaves:** Sensores autoalinháveis; pontos fixos instáveis; Filtro de Kalman Estendido com Restrições; Filtro de Kalman Complementar; Exoesqueleto; sistemas não lineares; fusão de sensores.

---

## 1. INTRODUÇÃO

A análise de ângulos articulares pode envolver áreas de estudo multidisciplinares, tais como robótica, biomecânica e fisioterapia, entre outras. Estas podem ser auxiliadas com o emprego de exoesqueletos artificiais, que são estruturas resistentes posicionadas externamente ao corpo do ser vivo, Dollar and Herr (2008). Estas estruturas podem auxiliar tanto em tarefas diárias possibilitando o emprego de forças muito maiores que as suportadas pelos seres vivos quanto no aspecto de reabilitação motora em indivíduos que possuam restrições de movimento, para mais detalhes, leia os trabalhos de de Looze et al. (2015); Pacifico et al. (2022).

No contexto da reabilitação motora, os exoesqueletos podem auxiliar pacientes e terapeutas durante a reabilitação de lesão vertebro-medular (LVM) por meio da aplicação de exercícios repetitivos, supervisionados por equipes médicas especializadas e apoiadas por exoesqueletos de modo a aumentar a mobilidade funcional, Postol et al. (2021).

Já o emprego de sensores inerciais torna-se viável, atualmente, devido à dimensão de tais dispositivos, que podem ser facilmente acoplados aos segmentos rígidos, à possibilidade de custo reduzido e fácil disponibilidade no mercado, conforme Luinge and Veltink (2005); Bonnet et al. (2013); Ahmed and Tahir (2017). Ao empregar sensores inerciais como acelerômetros, giroscópios e magnetômetros, torna-se imprescindível a aplicação de abordagens que visam corrigir erros de leitura, que são inerentes ao processo construtivo e materiais empregados, o que vincula a qualidade dos resultados de processamento às medidas de correção e compensação de erros adotadas, de acordo com Woodman (2007).

Devido às fontes de ruídos e perturbações que afetam os sensores (acelerômetros, giroscópios e magnetômetros), os erros de medidas relacionados a cada tipo de dispositivo geram erros de processos que, por consequência, aumentam o grau de incerteza na etapa de pós processamento, El-Sheimy et al. (2008). Estes fatores levam os pesquisadores a desenvolverem novas técnicas e abordagens que compensem estas ocorrências.

As abordagens que visam mitigar o aumento das incertezas de medidas, levam em consideração fatores que degradam os sinais tais como ruídos, perturbações, aumento de temperaturas e o processo de integração numérica. Uma possível solução, frequentemente adotada, envolve a combinação de sinais de múltiplos sensores com características distintas entre si, num processo denominado fusão de sensores, Roetenberg et al. (2005); Kok et al. (2017). Tal processo combina, por exemplo, sinais oriundos de sensores, como acelerômetros, giroscópios e magnetômetros, de modo a constituir um novo sinal, com menor grau de incerteza e ruído.

Frequentemente, a combinação do filtro complementar com o filtro de Kalman é empregada quando se deseja maior robustez na determinação de ângulos, como em Luinge and Veltink (2005); Roetenberg et al. (2005). Em Nogueira et al. (2014, 2017), um filtro de Kalman Markoviano, estabeleceu regras de fusão de para um sistema

de multisensores posicionados em segmentos de um exoesqueleto, analisando os momentos de maior linearidade dos acelerômetros, com base em índices individuais de incidência de acelerações. Em Inoue et al. (2017), utilizou-se uma abordagem semelhante, realizando a fusão de sinais de giroscópios, acelerômetros e magnetômetros em um Sistema de Posicionamento Global (Global Position System) (GPS) com câmeras monoculares, utilizando saltos Markovianos para chavear entre os sistemas de sensores em seus instantes de maior confiabilidade para a estimativa de trajetórias.

Os ângulos articulares podem ser encontrados relacionando-se as atitudes de segmentos consecutivos unidos por juntas moveis, como em Watanabe et al. (2011). Nas tarefas de identificação dos ângulos articulares em seres humanos, um dos maiores desafios é determinar a correta fixação dos sensores em relação ao eixo significativo do sistema de coordenadas do corpo rígido de interesse, sendo que diversas novas metodologias constantemente são desenvolvidas para lidar com esta limitação, assim como descrito pelos autores Seel et al. (2020); Pacher et al. (2020).

Em sistemas robóticos, pode-se determinar os ângulos articulares (juntas), de acordo com o propósito de fabricação, restringindo-se a movimentação dos elos a um grau de liberdade e projetando toda a movimentação a um plano específico. Levando-se em consideração que as articulações, em biomecânica, não se comportam como juntas rígidas, o alinhamento dos sensores é comprometido quando os segmentos rígidos de interesse são submetidos à movimentações e esforços, consulte Fan et al. (2022). Tal ocorrência deve-se, principalmente, aos tecidos presentes da região da articulação além da saúde e composição ligamentar do membro em análise, Favre2008. Para tais situações, buscam-se métodos de calibração visando-se compensar estas ocorrências, Forner-Cordero et al. (2008); Seel et al. (2014); Olsson et al. (2020).

Em Seel et al. (2014), um método de posicionamento de sensores inerciais para determinação dos ângulos de flexão e extensão do joelho, estabeleceu atitudes fixas para sensores posicionados nos segmentos adjacentes à articulação. Os sensores foram, primeiramente, alinhados e deslocados matematicamente em direção ao centro da articulação, de modo a reduzir os erros de leitura, por um processo de otimização de *Gauss-Newton*. Posteriormente, os sinais das atitudes determinadas pelos sinais obtidos de acelerômetros e giroscópios foram combinados em um filtro complementar de modo a se obter o ângulo articular.

Em Francelino et al. (2022) uniu-se os métodos Markovianos para estimativa de atitude anteriormente propostos em Nogueira et al. (2014, 2017); Inoue et al. (2017); Albuquerque et al. (2021) com o método desenvolvido por Seel et al. (2014) para propor um sistema de estimativa angular e de atitude para membros inferiores do corpo humano sem o emprego de um *encoder*. Neste, o sistema Markoviano foi modelado em condições onde havia a possibilidade de seleção simultânea de dois estados Markovianos. No entanto, erros de posicionamento ocorridos após o procedimento inicial de ajuste dos sensores não foram modelados. Isto pode causar imprecisão de estimativa em situações com coletas longas ou com baixa rigidez de fixação, como exemplo no monitoramento do corpo humano.

\* FAPESP projeto Mateus e Capes projeto Edson.

Dessa forma, este trabalho propõe o estudo e desenvolvimento de um sistema de correção automática de alinhamento e posicionamento online de dois sensores inerciais dispostos em segmentos consecutivos, que possuam restrição articular entre si. Assim, teremos um sistema de estimativa de ângulo articular, utilizando os métodos adotados em Francelino et al. (2022) e Seel et al. (2014), sendo o mesmo robusto às alterações de posicionamento dos sensores.

Diante do objetivo exposto, as próximas seções, que visam explicar com maiores detalhes o sistema de estimativa angular articular, serão compostas da seguinte maneira: na seção 2 é apresentado o problema e como este foi abordado. Na seção 3, Modelagem, será constituída da subseção 3.1, Articulação do joelho, que definirá as equações relacionadas ao cálculo do ângulo articular, ao alinhamento dos sensores em relação ao eixo articular estimado e das funções custo relacionadas ao erro entre as projeções dos sensores com relação ao eixo de referência. Na subseção 3.2, é apresentado o Filtro de Kalman na abordagem complementar (FKC) que será responsável por combinar as informações fornecidas após a etapa de alinhamento dos sensores, para a correção final. Na subseção 3.3, Ajuste on-line de parâmetros, será apresentado o Filtro de Kalman com Restrições na abordagem de Walker (2006), bem como a funções, equacionamentos, parâmetros e algoritmo associados ao processo de otimização dos versores que promoverão o alinhamento dos sensores. Na seção 4, Implementação e Resultados, serão apresentados o processo de implementação do algoritmo para o sistema de estimativas bem como os resultados obtidos, tendo como base o *encoder* como sistema de referência. Por fim, na seção 5 será feita a avaliação final e análise da factibilidade de tal sistema perante aos atualmente estabelecidos, *encoder* e goniômetros, para determinação de ângulos articulares.

## 2. DESENHO EXPERIMENTAL

O sistema em estudo proposto empregou um exoesqueleto com dois sensores inerciais e um *encoder* como sinal de referência. Sendo este ilustrado na Figura 1, onde  $\alpha$ , ângulo relativo ao joelho, corresponde ao ângulo articular a ser estimado.




Figura 1. Arranjo experimental. Fonte: Adaptado de Albuquerque et al. (2021).

Na sequência, é apresentado o esquema funcional com as IMU's através do diagrama de blocos ilustrado na Figura

3. Os segmentos da coxa e canela serão referenciados como pertencentes a um conjunto  $i = \{T, S\}$ , onde  $T$  corresponde ao segmento da coxa e  $S$  ao da canela. Neste, as medidas dos acelerômetros  $a_i(t)$  e giroscópios  $g_i(t)$  de ambos os segmentos, são utilizadas tanto para o sistema de estimativa de parâmetros de alinhamento  $j_i$  e deslocamento  $o_i$  virtuais dos mesmos, quanto para a estimativas angulares das orientações e da articulação. Como pode ser visto, à cada janela de dados  $batch_k(coxa)$  e  $batch_k(canela)$  dos sensores, um novo conjunto de parâmetros é estimado de forma online, tornando o sistema robusto às possíveis mudanças de alinhamento e posicionamento.

## 3. MODELAGEM

Nesta seção serão apresentadas as restrições e equacionamentos empregados para obtenção do modelo utilizado para estimativa do ângulo articular do joelho. Ademais, é apresentado o método de minimização proposto por Walker (2006), o qual utiliza essas restrições para encontrar os parâmetros necessários para a estimativa. Esta abordagem é considerada adequada para identificação dos parâmetros de sistemas não lineares com comportamentos caóticos, devido à simplicidade de implementação das restrições e custo computacional reduzido.

### 3.1 Articulação do joelho

Assim como em Seel et al. (2014), a articulação do joelho será modelada matematicamente em coordenadas esféricas, com a projeção de movimentos restrita ao plano sagital, que refere-se aos movimentos de flexão e extensão do joelho reduzindo-se o problema a 1 grau de liberdade, veja a Figura 2.




Figura 2. (a) Aproximação articular mais próxima de um joelho real. (b) Restrição articular adotada para estimativa angular no plano sagital. Fonte: Seel et al. (2014).

As estimativas do ângulo articular do joelho, pelos giroscópios, são realizadas através de integração numérica. E estas determinadas como:

$$\alpha_{giro}(k) = \int_{t_0}^{t_1} (g_T(\tau) \cdot j_T - g_S(\tau) \cdot j_S) d\tau, k = 1, \dots, N \quad (1)$$

sendo  $g_i(\tau)$ , para  $i = \{T, S\}$ , a informação do giroscópio em seu respectivo segmento  $i$ ,  $\tau$  é a constante de tempo de integração associada ao período de amostragem. Já o  $j_i = (j_{x_i}, j_{y_i}, j_{z_i})$  é o versor que projeta o sistema de coordenadas do corpo (giroscópio) para o sistema de coordenadas da articulação. Considerando cada um dos segmentos consecutivos  $i$ , temos os versores  $j_i$  definidos em coordenadas esféricas, como:

$$j_i = [\cos(\phi_i)\cos(\theta_i) \quad \cos(\phi_i)\sin(\theta_i) \quad \sin(\phi_i)]^T. \quad (2)$$

Os valores de  $\phi_i \in [-\pi/2, \pi/2]$  e  $\theta_i \in [0, 2\pi]$  da equação (2), para  $i = \{T, S\}$ , representam, a inclinação e orientação do giroscópio em relação ao eixo articular. Estes são encontrados através da minimização da função custo apresentadas na Equação (3), na qual, o erro de alinhamento entre os giroscópios de dois segmentos consecutivos é modelado. Para maiores detalhes veja a Subseção 3.3 e Seção 4 deste trabalho.

$$e_j(k) = \|g_T(k) \times j_T\|_2 - \|g_S(k) \times j_S\|_2, k = 1, \dots, N. \quad (3)$$

Já a estimativa do ângulo articular pelo emprego do acelerômetro pode ser obtida por meio de transformação trigonométrica:

$$\alpha_{accel}(k) = \arccos\left(\frac{u_T(k) \cdot u_S(k)}{\|u_T(k)\|_2 \cdot \|u_S(k)\|_2}\right), k = 1, \dots, N \quad (4)$$

sendo  $u_i(k)$ , para  $i = \{T, S\}$ , o par ordenado das projeções da medida  $\tilde{a}_i(t)$  no plano articular, definido como

$$u_i(k) = (\tilde{a}_i(k) \cdot x_i, \tilde{a}_i(k) \cdot y_i), \quad (5)$$

em que  $x_i = j_i \times c$  com  $c \perp j_i$  e  $y_i = j_i \times x_i$ , para  $i = \{T, S\}$ , são os versores responsáveis por formarem o par ordenado das projeções no plano sagital, com  $j_i$  sendo o versor relacionado ao sensor do segmento  $i$  e  $c = [1, 0, 0]$ . A parcela  $\tilde{a}_i(k)$  da Equação (5) é a projeção do acelerômetro  $a_i(k)$  no centro da articulação e é calculada da seguinte maneira

$$\tilde{a}_i(k) = a_i(k) - \Gamma_{g_i(k)}(o_i), \quad (6)$$

sendo  $a_i(k)$  a informação do acelerômetro triaxial do segmento  $i$  e  $\Gamma_{g_i(k)}(o_i)$  a aceleração radial e tangencial devido à rotação em torno do centro da articulação calculada da seguinte forma

$$\Gamma_{g_i(k)}(o_i) = \underbrace{g_i(k) \times (g_i(k) \times o_i)}_{accel.radial} + \underbrace{\dot{g}_i(k) \times o_i}_{accel.tangencial},$$

em que  $g_i(k)$  é a medida registrada pelo giroscópio fixado no segmento  $i$ ,  $o_i = (o_{ix}, o_{iy}, o_{iz}) \in [-1, 1]$  é o versor de coordenada de posição ao longo do eixo da articulação no sistema de coordenada do sensor.

Por fim, o versor  $o_i$  é encontrado através da minimização da função custo apresentada na Equação (7), e o  $\dot{g}_i(k)$  é o derivativo da taxa de variação angular do giroscópio, sendo calculado por uma aproximação de terceira ordem simétrica. Para maiores detalhes, veja a Subseção 3.3 e Seção 4 deste trabalho.

$$e_o(k) = \left\| a_T(k) - \Gamma_{g_T(k)}(o_T) \right\|_2 - \left\| a_S(k) - \Gamma_{g_S(k)}(o_S) \right\|_2. \quad (7)$$

### 3.2 Filtro de Kalman Complementar (FKC)

Na sequência, utilizamos o filtro de Kalman na abordagem complementar (FKC) para realizar a fusão dos ângulos articulares obtidos através do giroscópio ( $\alpha_{giro}$ ), Equação (1), e acelerômetro ( $\alpha_{accel}$ ), Equação (4).

A formulação do filtro apresentada abaixo, modela erro de medida entre o acelerômetro e giroscópio, utilizando o FKC para estimativa do erro de medida. Para maiores detalhes, veja Nogueira et al. (2017); Francelino et al. (2022).

$$\Delta\alpha(k) = \alpha_{accel}(k) - \alpha_{giro}(k).$$

Assim, a saída estimada  $\Delta\hat{\alpha}_K(t)$ , será somada ao ângulo articular do giroscópio  $\alpha_{Kgiro}(t)$  de forma a corrigir o ângulo calculado:

$$\alpha(k) = \alpha_{giro}(k) + \Delta\hat{\alpha}(k).$$

O FKC para esta etapa é definido segundo o Algoritmo 1. Sendo, definidos  $A = B = H = 1$ ,  $Q = 5 \cdot 10^{-6}$ ,  $R = 0.2$ , e  $z_k = \Delta\alpha$ .

---

#### Algoritmo 1 : Filtro de Kalman Complementar

---

**Inicialize:**  $\hat{x}_0 = 0$ ,  $\hat{P}_0 = 1$

**Predição:**

$$\hat{x}_{k+1} = A\hat{x}_k|k$$

$$\hat{P}_{k+1} = AP_k|kA^T + BQ_kB^T$$

**Correção:**

$$K_{k+1} = P_{k+1}H^T(H P_{k+1}H^T + R)^{-1}$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1}(z_k - H\hat{x}_{k+1})$$

$$P_{k+1|k+1} = (I - K_{k+1}H)P_{k+1}$$


---

### 3.3 Ajuste online dos parâmetros

Diferentemente do ajuste de parâmetros proposto por Seel et al. (2014), no qual um algoritmo de otimização baseado em Gauss-Newton era executado de forma *offline*, neste trabalho nós propomos o ajuste *online* por pacotes de dados, sendo utilizado um filtro de Kalman como estimador de parâmetros.

Em Seel et al. (2014), o processo de otimização e ajuste de parâmetros utilizou uma janela de tempo expressiva, considerando diversas situações e posições reais que os sensores estariam dispostos no corpo humano. No entanto, neste não foi considerado mudanças de orientação ou deslocamento dos sensores após a calibração inicial, o que consequente comprometeria o valor real da estimativa angular em tal situação.

Neste trabalho será considerado a possibilidade de mudanças de posicionamento dos sensores inerciais utilizados, sendo estimados os parâmetros de alinhamento  $j_i$  e de deslocamento  $o_i$  dos sensores a cada nova janelas de dados, como ilustrado na Figura 3.

Assim, os sinais dos sensores serão segmentados em blocos de tamanho fixo, como apresentado na Equação (8).

$$batch_D = dados_{k-s_w \text{ até } k}, \quad (8)$$

sendo o  $batch_D$  definido como uma janela de dados das unidades inerciais contemplando o intervalo  $k - s_w$  até  $k$ , com  $s_w$  o tamanho das janelas e  $D = 1$ , até a quantidade possível de janelas de dados da coleta.

De posse dos dados de janelamento,  $batch_D$ , realizarmos a minimização das equações (3) e (7) através de um número mínimos de iterações definido como *ordem*, para o algoritmo de minimização escolhido. Sendo que neste trabalho, optamos por utilizar um Filtro de Kalman Estendido com pontos fixos como restrições, na abordagem de Walker (2006), que reduz consideravelmente o custo computacional e promove sua aplicação em processamentos *on-line*, consequência da fatoração da equação de diferença de Ricatti que é naturalmente inserida na dedução do filtro, Birgmeier (1995) e Walker (2006).

O objetivo é encontrar parâmetros que minimizem as funções custos (3) e (7), por meio de aproximações sucessivas empregando-se um Filtro de Kalman Estendido. Desta

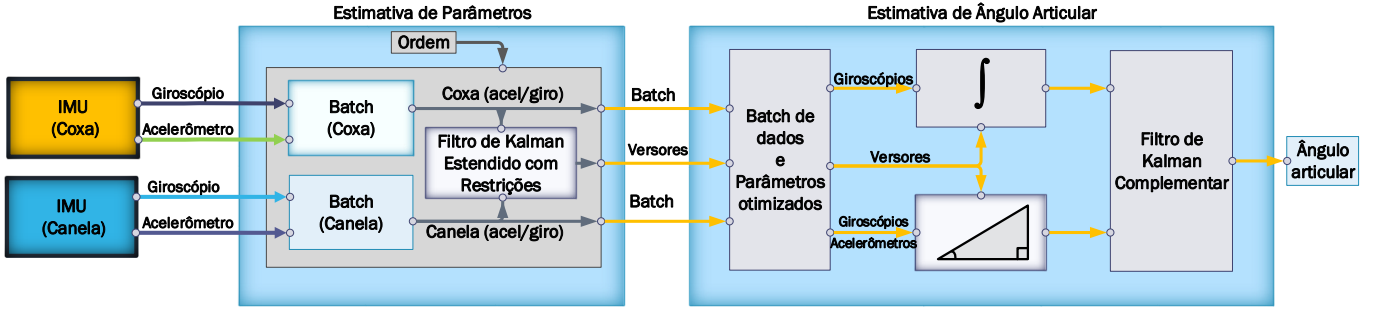


Figura 3. Diagrama geral do sistema. Neste, as IMU's fornecem um lote (*Batch*) de dados para a etapa de estimativa de parâmetros, onde o Filtro de Kalman com Restrições ajusta os versores associados ao alinhamento dos sensores com base em um número de repetições definidos pelo parâmetro *Ordem*. Posteriormente, o versores ajustados juntamente com o lote atual de dados são encaminhados à etapa de estimativa angular, sendo combinadas em um Filtro de Kalman Complementar para a determinação final do ângulo articular.

forma, os valores estimados, iterativamente, aproximam-se dos custos mínimos e satisfazendo as restrições impostas.

Assim, seguindo modelo proposto por Walker (2006), utilizando a dinâmica do erro dado pelas derivadas das equações (3) e (7), temos as equações para o filtro de Kalman Estendido com restrições dadas por:

$$\begin{aligned}\hat{x}_{k+1} &= x_{k|k}, \\ 0 &= z_k - h(x_k, y_k) + v_k,\end{aligned}$$

sendo  $x_k$  o vetor de parâmetros,  $h_k$  a métrica de medida não linear,  $y_k$  o vetor de medida e  $v_k$  o erro branco Gaussiano com matriz de covariância  $R_k$ .

Para o nosso problema,  $x_k = \Psi_l$ , sendo  $l = \{j, o\}$ ,  $\Psi_{l=j} = [\phi_T \ \theta_T \ \phi_S \ \theta_S]^T$  e  $\Psi_{l=o} = [o_T \ o_S]^T$ . O vetor  $h(x_k, y_k) = e_l$ , sendo  $y_k$  a medida do giroscópio e  $e_l$  dado pelas Equações (3) e (7).

Uma vez que  $e_l$  será zero quando os parâmetros  $J_T$  e  $J_S$  forem encontrados, podemos definir o valor de  $z_k = 0$ . Portanto:

$$z_k - h(x_k, y_k) = r_k = -e_l,$$

sendo que a matriz de observação  $H_l(k)$  pode ser obtida através da linearização de  $h(x_k, y_k)$  pelo estado  $x_k$ . Assim temos:

$$H_l(k) = \frac{\partial e_l(k)}{\partial \Psi_l}, \quad k = 1, \dots, N, \quad (9)$$

com  $H_{l=j} \in \mathbb{R}^{N \times 4}$ ,  $H_{l=o} \in \mathbb{R}^{N \times 6}$  e  $N = batch_D$ .

Os derivativos da Equação (9) para  $l = j$  podem ser calculados conforme

$$\frac{\partial e_j(k)}{\partial \Psi_j} = \frac{\partial(\|g_T(k) \times j_T\|_2)}{\partial j_T} \frac{\partial j_T}{\partial \Psi_{j_T}} - \frac{\partial(\|g_S(k) \times j_S\|_2)}{\partial j_S} \frac{\partial j_S}{\partial \Psi_{j_S}} \quad (10)$$

sendo

$$\frac{\partial(\|g_i(k) \times j_i\|_2)}{\partial j_i} = \frac{(g_i(k) \times j_i) \times g_i(k)}{\|g_i(k) \times j_i\|_2} \in \mathbb{R}^{1 \times 3}, \quad (11)$$

e  $\frac{\partial j_i}{\partial \Psi_i} \in \mathbb{R}^{3 \times 4}$ .

Já os derivativos da Equação (9) para  $l = o$  podem ser calculados conforme

$$\frac{\partial e_o(k)}{\partial \Psi_o} = \frac{\partial(\|\tilde{a}_T(k)\|_2)}{\partial \Psi_{o_T}} - \frac{\partial(\|\tilde{a}_S(k)\|_2)}{\partial \Psi_{o_S}} \in \mathbb{R}^{1 \times 6} \quad (12)$$

sendo

$$\frac{\partial(\|\tilde{a}_i(k)\|_2)}{\partial \Psi_{o_i}} = \left( \left( [g_i(k)]_{\times}^2 - [\dot{g}_i(k)]_{\times} \right) \frac{\tilde{a}_i(k)}{\|\tilde{a}_i(k)\|_2} \right)^T \quad (13)$$

em que o operador  $[(\cdot)]_{\times}$  indica uma matriz antissimétrica da função  $(\cdot)$  e  $\tilde{a}_i$  é definido conforme a Equação (6).

Desta forma, fica estabelecido o Filtro de Kalman Estendido com restrições conforme o Algoritmo 2, sendo  $F_j = P_{0_j} = I_4$ ,  $Q_j = 10^{-3} \cdot I_4$ ,  $R_j = 10^{-3} \cdot I_N$  com  $N = batch_D$ ,  $F_o = P_{0_o} = I_6$ ,  $Q_o = 10^{-3} \cdot I_6$ ,  $R_j = 10^{-3} \cdot I_N$ .

---

#### Algoritmo 2 Filtro de Kalman Estendido com Restrições

---

##### Entrada:

$\Psi_l, batch_D, ordem$

##### Inicialize:

$\hat{x}_0 = \Psi_l$

##### para $k = 1$ até $ordem$ faça

###### Predição:

$\hat{x}_{k+1} = F \hat{x}_{k|k}$

$\hat{P}_{k+1} = F P_{k|k} F^T + Q_k$

###### Erro e matriz Jacobiana:

##### para $k = 1$ até $batch_D$ faça

Calcule  $r_l = -e_l(k)$   $\triangleright$  Equações (3) ou (7)

Calcule  $H_l(k)$   $\triangleright$  Equação (9)

##### fim para

###### Correção:

$K_{k+1} = P_{k+1} H_l(k)^T (H_l(k) P_{k+1} H_l(k)^T + R)^{-1}$

$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1} r_k$

$P_{k+1|k+1} = (I - K_{k+1} H_l(k)) P_{k+1}$

##### fim para

##### Saída:

$\Psi_l^* = \hat{x}_{k+1|k+1}$

---

## 4. IMPLEMENTAÇÃO E RESULTADOS

Para a implementação do sistema proposto na seção anterior é necessário atualizar as estimativas dos parâmetros  $j_T$ ,  $j_S$ ,  $o_T$  e  $o_S$  a cada determinado período de tempo,

para que o cálculo dos ângulos articulares pelos giroscópios e acelerômetros represente posicionamento atual dos sensores. Foi proposto um janelamento das medidas dos sensores através da Equação (8), e o Algoritmo 3 para estimativa do ângulo articular do joelho.

Como pode ser visto no Algoritmo 3, a *ordem* representa o número de iterações do algoritmo de minimização, enquanto que o  $s_w$  representa o tamanho da janela de dados utilizada em cada iteração. Assim, quanto menor o  $s_w$  maior a frequência de atualização dos parâmetros e quanto maior a combinação  $s_w \times ordem$  maior complexidade computacional do algoritmo, impactando diretamente no tempo de processamento.

---

**Algoritmo 3** : Algoritmo do sistema para estimativa do ângulo articular

---

para  $k = 1$  até tamanho( $dados_{sensor}$ ) faça

  contador ++

  se contador == batch então

    contador = 1

    para  $k \leftarrow 1$  até ordem faça

$j_i = \text{minimize}$  Equação (3)           ▷ Algoritmo 2

$o_i = \text{minimize}$  Equação (7)           ▷ Algoritmo 2

    fim para

  fim se

$\alpha_{giro}(k) =$  Equação (1)

$\alpha_{accel}(k) =$  Equação (4)

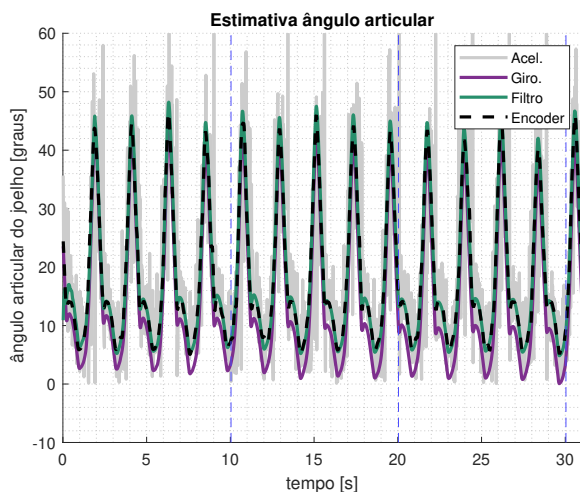
$\alpha(k) = \text{FKC}(\alpha_{giro}, \alpha_{accel})$            ▷ Algoritmo 1

fim para

---

Assim, utilizando o sistema apresentado no Algoritmo 3, foi obtido o resultado que pode ser observado na Figura 4, na qual os traços verticais separam três janelas. Para esses resultados foi utilizado  $s_w = 500$  e *ordem* = 6. Nele a estimativa apresenta um RMSE = 1.0044° e Correlação = 0.9976.

Figura 4. Ângulo articular do joelho



Fonte: Autor

Afim de verificarmos a resposta do sistema a diferentes valores de  $s_w$  e *ordem*, os mesmos foram variados e seus efeitos observados sobre as Equações (3) e (7), através das Figuras 5 e 6, respectivamente.

A observação direta das Figuras 5 e 6, sugere que a melhor escolha dos parâmetros seriam o  $s_w$  abaixo de 100 e *ordem* acima de 2. No entanto, os resultados obtidos para tal faixa de valores apresentaram resultados com baixa correlação ao se comparar o valor da estimativa do ângulo articular com a referência obtida pelo *encoder*, como pode ser visto na Figura 7.

Portanto, de posse dos resultados apresentados pelas Figuras 5, 6 e 7, propomos que a escolha dos parâmetros  $s_w$  e *ordem* sejam realizados desconsiderando as regiões com baixa correlação delimitadas pela Figura 7, com objetivo de encontrar a menor combinação  $s_w \times ordem$  que nos apresente um erro aceitável. Além disso, foi possível concluir que o  $s_w$  (tamanho dos dados utilizados para estimar os parâmetros) tem um maior efeito sobre os erros do versor e do *offset* do que a *ordem* (número de interações sobre os dados). E pelos resultados apresentados é possível observar que para tamanhos de *ordem* superiores a 5 não temos efeitos significativos sobre erro, dado pelas Equações (3) e (7).

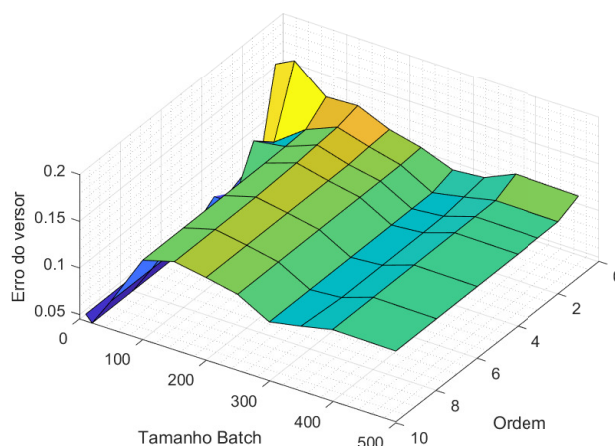


Figura 5. Efeito da variação do *batch* e da ordem sobre o erro do versor. Fonte: Autor

Contudo, afim de verificar a capacidade do sistema adaptar-se a variações de posicionamento dos sensores, foi inserido uma rotação artificial ao sensor fixado no segmento da coxa  $T$ , sendo o mesmo rotacionado em 50° no plano transversal que é perpendicular ao plano do movimento, com o resultado visto na Figura 8. Como esperado, o sistema se adapta a mudança e em poucos segundos volta a realizar estimativas do ângulo articular com a mesma qualidade de antes da rotação.

## 5. CONCLUSÃO

Este estudo modela e implementa um sistema de estimativa para ângulos articulares, sendo o mesmo adaptável a variações de posicionamento dos sensores inerciais. O método proposto, apresentou bons valores de estimativa

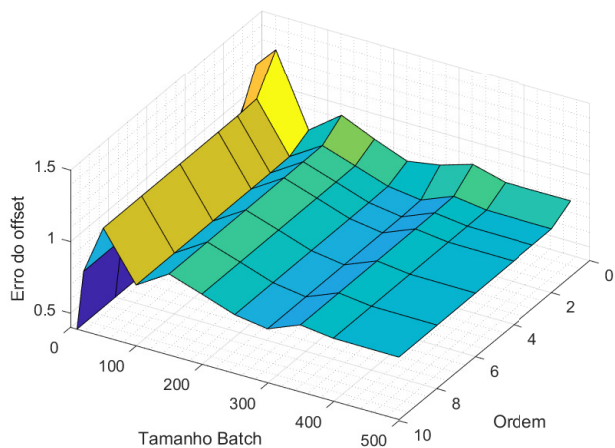


Figura 6. Efeito da variação do *batch* e da ordem sobre o erro do *offset*. Fonte: Autor

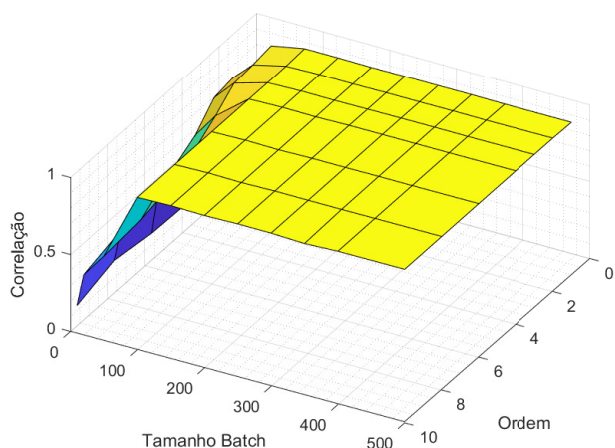


Figura 7. Efeito sobre a correlação entre a estimativa do ângulo articular do joelho obtido pelo sistema proposto e pelo sistema de referência. Fonte: Autor

quando comparado com o sistema de referência composto pelo *encoder*, alcançando correlação superior a 0.99 e um RMSE próximo à 1°. Assim, podemos considerar a substituição de *encoders* e goniômetros por sensores inerciais em medidas articulares, como viável, e portando pode-se evitar a necessidade de estruturas rígidas que limitam o movimento humano.

Além disso, a maior contribuição deste trabalho está na proposição de um sistema capaz de se adaptar a variações de posicionamento dos sensores e realizar estimativas precisas após poucos segundos dessas variações. Sendo assim, capaz de realizar coletas longas e robustas para diferentes tipos de atividades diárias do paciente.

#### AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Projeto 88882.441241/2019 - 01, da Fundação de Amparo à Pesquisa do Estado de São Paulo




Figura 8. Estimativa do ângulo articular com dados rotacionados. Fonte: Autor

(FAPESP), processo 2020/13936 - 8 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico, (CNPq) Projeto 128770/2020 - 1.

#### REFERÊNCIAS

- Ahmed, H. and Tahir, M. (2017). Improving the Accuracy of Human Body Orientation Estimation With Wearable IMU Sensors. *IEEE Transactions on Instrumentation and Measurement*, 66(3), 535–542.
- Albuquerque, P.R., Francelino, E.H., and Nogueira, S.L. (2021). Orientação espacial em exoesqueletos de membros inferiores utilizando filtros markovianos. In *2021 14th IEEE International Conference on Industry Applications (INDUSCON)*, 862–867.
- Birgmeier, M. (1995). A fully Kalman-trained radial basis function network for nonlinear speech modeling. In *Proceedings of ICNN'95 - International Conference on Neural Networks*, volume 1, 259–264 vol.1.
- Bonnet, V., Mazza, C., Fraisse, P., and Cappozzo, A. (2013). Real-time estimate of body kinematics during a planar squat task using a single inertial measurement unit. *IEEE Transactions on Biomedical Engineering*, 60(7), 1920–1926.
- de Looze, M.P., Bosch, T., Krause, F., Stadler, K.S., and O’Sullivan, L.W. (2015). Exoskeletons for industrial application and their potential effects on physical work load. *Ergonomics*, 59(5), 671–681.
- Dollar, A.M. and Herr, H. (2008). Lower extremity exoskeletons and active orthoses: Challenges and state-of-the-art. *IEEE Transactions on Robotics*, 24(1), 144–158.
- El-Sheimy, N., Hou, H., and Niu, X. (2008). Analysis and modeling of inertial sensors using allan variance. *IEEE Transactions on Instrumentation and Measurement*, 57(1), 140–149. doi:10.1109/TIM.2007.908635.
- Fan, B., Li, Q., Tan, T., Kang, P., and Shull, P.B. (2022). Effects of IMU sensor-to-segment misalignment and orientation error on 3-d knee joint angle estimation. *IEEE Sensors Journal*, 22(3), 2543–2552.
- Forner-Cordero, A., Mateu-Arce, M., Forner-Cordero, I., Alcántara, E., Moreno, J.C., and Pons, J.L. (2008). Study of the motion artefacts of skin-mounted inertial

- sensors under different attachment conditions. *Physiological Measurement*, 29(4), N21–N31.
- Francelino, E., Pereira, M., Inoue, R., Terra, M., Siqueira, A., and Nogueira, S. (2022). Markov system with self-aligning joint constraint to estimate attitude and joint angles between two consecutive segments. *Journal of Intelligent & Robotic Systems*, 104(3).
- Inoue, R.S., Guizilini, V., Terra, M.H., and Ramos, F. (2017). Markovian jump linear systems-based filtering for visual and GPS aided inertial navigation system. In *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE.
- Kok, M., Hol, J.D., and Schön, T.B. (2017). Using inertial sensors for position and orientation estimation. *Foundations and Trends® in Signal Processing*, 11(1-2), 1–153.
- Luinge, H.J. and Veltink, P.H. (2005). Measuring orientation of human body segments using miniature gyroscopes and accelerometers. *Medical & Biological Engineering & Computing*, 43(2), 273–282.
- Nogueira, S., Siqueira, A., Inoue, R., and Terra, M. (2014). Markov jump linear systems-based position estimation for lower limb exoskeletons. *Sensors*, 14(1), 1835–1849. doi:10.3390/s140101835.
- Nogueira, S.L., Lambrecht, S., Inoue, R.S., Bortole, M., Montagnoli, A.N., Moreno, J.C., Rocon, E., Terra, M.H., Siqueira, A.A.G., and Pons, J.L. (2017). Global Kalman filter approaches to estimate absolute angles of lower limb segments. *BioMedical Engineering OnLine*, 16(1). doi:10.1186/s12938-017-0346-7.
- Olsson, F., Kok, M., Seel, T., and Halvorsen, K. (2020). Robust plug-and-play joint axis estimation using inertial sensors. *Sensors*, 20(12), 3534.
- Pacher, L., Chatellier, C., Vauzelle, R., and Fradet, L. (2020). Sensor-to-segment calibration methodologies for lower-body kinematic analysis with inertial sensors: A systematic review. *Sensors*, 20(11), 3322.
- Pacifico, I., Parri, A., Taglione, S., Sabatini, A.M., Violante, F.S., Molteni, F., Giovacchini, F., Vitiello, N., and Crea, S. (2022). Exoskeletons for workers: A case series study in an enclosures production line. *Applied Ergonomics*, 101, 1–12.
- Postol, N., Spratt, N.J., Bivard, A., and Marquez, J. (2021). Physiotherapy using a free-standing robotic exoskeleton for patients with spinal cord injury: a feasibility study. *Journal of NeuroEngineering and Rehabilitation*, 18(1).
- Roetenberg, D., Luinge, H., Baten, C., and Veltink, P. (2005). Compensation of magnetic disturbances improves inertial and magnetic sensing of human body segment orientation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 13(3), 395–405.
- Seel, T., Kok, M., and McGinnis, R.S. (2020). Inertial sensors—applications and challenges in a nutshell. *Sensors*, 20(21), 6221.
- Seel, T., Raisch, J., and Schauer, T. (2014). IMU-based joint angle measurement for gait analysis. *Sensors*, 14(4), 6891–6909.
- Walker, D.M. (2006). Parameter estimation using Kalman filters with constraints. *International Journal of Bifurcation and Chaos*, 16(04), 1067–1078.
- Watanabe, T., Saito, H., Koike, E., and Nitta, K. (2011). A preliminary test of measurement of joint angles and stride length with wireless inertial sensors for wearable gait evaluation system. *Computational Intelligence and Neuroscience*, 2011, 1–12.
- Woodman, O.J. (2007). An introduction to inertial navigation. Technical Report UCAM-CL-TR-696, University of Cambridge, Computer Laboratory. doi:10.48456/tr-696. URL <https://www.cl.cam.ac.uk/techreports/UCAM-CL-TR-696.pdf>.