

Sistema de estimativa de ângulo articular com correção de posicionamento de sensores

Mateus José P. Pereira*, Samuel Lourenço Nogueira[†]

Resumo— Neste trabalho é apresentado o desenvolvimento de um sistema capaz de estimar o ângulo articular utilizando apenas sensores inerciais. O trabalho foi proposto para a estimativa de segmentos do corpo humano, contudo ainda pode também ser aplicado em estruturas rígidas como exoesqueletos e robôs articulados.

Para sistema proposto foi considerado o desalinhamento dos sensores durante as atividades do paciente, nesse caso o sistema realiza o autoalinhamento dos mesmos, resultando em uma maior robustez durante medições de longo prazo, e evitando a perda das informações de atitude e ângulo do sistema.

No estudo foram desenvolvidos dois sistemas de filtragem baseados em filtros de Kalman para atingir a estimativa do ângulo articular, 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.

Palavras Chaves— Sensores inerciais, autoalinhamento, filtro de Kalman estendido, filtro de Kalman complementar, sistema markoviano, exoesqueleto, fusão de sensores



1 Introdução

O desenvolvimento de metodologias voltadas para adquirir informações de movimento são de interesse de diversas áreas de pesquisa tanto em biomecânica e fisioterapia quanto em robótica. Essas informações podem ser utilizadas para realizar o controle de atuadores, na área da robótica, ou mesmo para acompanhamento de pacientes com alguma dificuldade de movimento na área da medicina, como descrito em [1].

Dessa forma, a análise do ângulo articular é uma tarefa chave para essas áreas de pesquisa. No contexto da reabilitação motora, análise de ângulos articulares podem ser auxiliadas com o emprego de exoesqueletos artificiais, que são estruturas resistentes posicionadas externamente ao corpo do ser vivo, [2]. 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, veja [3], [4].

Uma abordagem para a captura de movimentos que chamou atenção nos últimos anos foram utilizando sensores inerciais, devido à dimensão de tais dispositivos, que podem ser facilmente acoplados aos segmentos rígidos, à possibilidade de custo reduzido e fácil disponibilidade no mercado, veja [5], [6], [7]. Aplicações dessas abordagens podem ser vista em [8] no qual acelerômetros triaxiais foram fixados em segmentos do corpo humano para o monitoramento de movimentos afim de avaliar o gasto energético em atividades cotidianas, e em [9] no qual foi empregado magnetômetros e acelerômetros para o monitoramento 3D da posição de um braço mecânico.

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, veja [10].

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, [11]. 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, [12], [13]. Tal processo combina, por exemplo, sinais oriundos de sensores, tais 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, veja [5], [12]. Em [14], [15], um filtro de Kalman Markoviano, estabeleceu regras de fusão 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 [16], utilizou-se uma abordagem semelhante, realizando a fusão de sinais de

-
- *Graduando*: *M. Pereira do Departamento de Engenharia Elétrica da Universidade Federal de São Carlos
E-mail: mateusjp332@gmail.com
 - *Orientador*: †S. Nogueira docente do Departamento de Engenharia Elétrica da Universidade Federal de São Carlos.

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.

Em [17] o autor relaciona as atitudes dos segmentos consecutivos para obtenção de ângulos articulares. Quando se trata de identificar os ângulos articulares em humanos, um dos desafios que se apresenta é a fixação correta dos sensores, por isso, novas metodologias constantemente são desenvolvidas para lidar com esta limitação, veja [18], [19].

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, veja [20]. Tal ocorrência deve-se, principalmente, aos tecidos presentes da região da articulação além da saúde e composição ligamentar do membro em análise, [21]. Para tais situações, buscam-se métodos de calibração visando-se compensar estas ocorrências, veja [22], [23], [24].

Em [23], 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. Posteriormente, os sinais as atitudes determinadas por acelerômetros e giroscópios foram combinadas em um filtro complementar de modo a se obter o ângulo articular. Esta metodologia se torna conveniente pois não é necessário uma disposição correta dos sensores.

Em [25] uniu-se os métodos Markovianos para estimativa de atitude anteriormente propostos em [14], [15], [16], [26] com o método desenvolvido por [23] 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 selecionar simultaneamente 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.

Dessa forma, este trabalho propôs 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 [25] e [23], sendo o mesmo robusto as alterações de posicionamento dos sensores. Cabe salientar 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.

Diante daquilo que foi exposto, as próximas seções, que visam explicar com maiores detalhes o sistema de estimativa angular articular da Figura 3, serão compostas da seguinte maneira: seção 2, Aspectos metodológicos, que será constituída da subseção 2.2, 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 ao eixo de referência. Na subseção 2.3, 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 2.4, Ajuste *online* de parâmetros, será apresentado o Filtro de Kalman com Restrições na abordagem de [27], bem como as funções, equacionamentos, parâmetros e algoritmo associados ao processo de otimização dos versores que promoverão o alinhamento dos sensores. Na seção 3, Discussão e Resultados, serão apresentados o algoritmo implementado para o sistema de estimativas bem como os resultados obtidos, tendo como base o *encoder* como sistema de referência. Ainda nesta sessão serão apresentadas as análises e respostas do sistema a mudanças de parâmetros do mesmo. Por fim, nas seções 4 e 5 serão discutidas futuras melhores no trabalho proposto, assim como a avaliação final e análise da factibilidade de tal sistema perante aos atualmente estabelecidos, *encoder* e goniômetros, para determinação de ângulos articulares.

2 Aspectos metodológicos

Nesta seção será apresentado o embasamento teórico utilizado para o entendimento do problema, sendo assim: dispositivos, restrições, equacionamentos e modelo da articulação do joelho. Ademais, é apresentado o método de minimização proposto por [27], o qual utiliza o filtro de Kalman e as restrições do modelo para encontrar os parâmetros necessários para a estimativa. Essa abordagem é diferente da proposta por [28] para obtenção do modelo, porém ela se mostrou bastante adequada para a solução do problema, principalmente por utilizar as restrições previamente modeladas, ser aplicável para sistemas não lineares como o descrito neste trabalho, e apresentar baixo custo computacional.

2.1 Dispositivos utilizados

2.1.1 Exoesqueleto

O sistema em estudo empregou os dados provenientes do exoesqueleto H2 proposto por [29] com a finalidade de auxiliar na aquisição de medidas da parte inferior do corpo durante as marcha de pacientes. Este é uma estrutura rígida que possui seis articulações e foi projeto para a reabilitação de adultos de 1.5m a 1.95m com dificuldades motoras, podendo ser observado na Figura 1.

Em cada segmento do exoesqueleto é acoplado uma IMU, totalizando oito sensores, e em cada uma das articulações



Figura 1: Arranjo experimental. Fonte: [29]

possui um *encoder* para obtenção do ângulo articular, totalizando seis sensores de alta precisão para obtenção do ângulo articular.

2.1.2 Disposição dos sensores

Para este trabalho foram apenas utilizados os sensores inerciais da coxa e da canela para obtenção do ângulo articular do joelho. Além disso, as medidas da *encoder* da articulação foram empregadas como sinal de referência. Na Figura 2 é mostrado a representação do sistema estudado, no qual α é o ângulo relativo ao joelho no plano sagital, corresponde ao ângulo articular a ser estimado.

A IMU de cada segmento pertence a um conjunto $i = \{T, S\}$, onde cada letra representa o segmento ao qual o IMU esta inserida, T corresponde ao segmento da coxa (do inglês *thigh*) e S o segmento da canela (do inglês *shank*). Desta forma, cada IMU fornece medidas de aceleração $a_i(t)$ e de velocidade angular $g_i(t)$ que são utilizadas tanto no sistema de obtenção de parâmetros para as constantes do modelo, quanto para o cálculo de estimativa angular do joelho α .

2.2 Modelo articular do joelho

A modelagem articular proposta por [23] tem objetivo obter o ângulo de flexão/extensão da articulação do joelho sem assumir a posição ou orientação dos sensores inerciais, ou que usuário necessite realizar movimentos específico para a calibração. A articulação é modelada matematicamente em coordenadas esféricas, e visa 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 4.

A metodologia assume tanto a posição quanto a orientação dos sensores são inicialmente desconhecidas, e elas

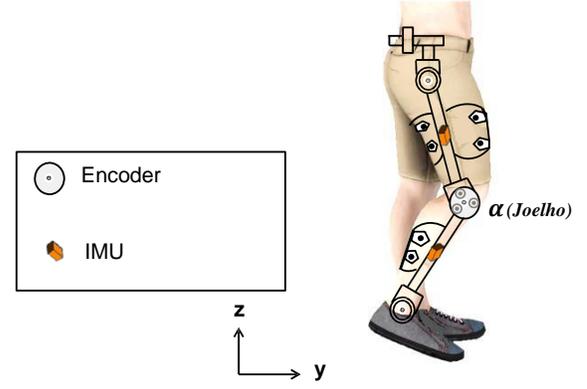


Figura 2: Arranjo experimental. Fonte: Adaptado de [26].

podem ser determinadas explorando as restrições da articulação. Assim é realizado uma amostragem inicial dos sensores enquanto a articulação se movimenta. Nesta, 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.

2.2.1 Identificação dos eixos j_i

O $j_i = (j_{x_i}, j_{y_i}, j_{z_i})$ é o versor de posição dos sensores em relação ao joelho, ele é responsável por projetar o sistema de coordenadas do corpo (giroscópio) para o sistema de coordenadas da articulação, como pode ser observado na Figura 4(c). Considerando cada um dos segmentos consecutivos i , temos os versores j_i definidos em coordenadas esféricas, como:

$$j_i = [\cos(\phi_i)\cos(\theta_i) \quad \cos(\phi_i)\sin(\theta_i) \quad \sin(\phi_i)]^T. \quad (1)$$

Os valores de $\phi_i \in [-\pi/2, \pi/2]$ e $\theta_i \in [0, 2\pi]$ da equação (1), para $i = \{T, S\}$, representam, a inclinação e orientação do giroscópio em relação ao eixo articular. O versor j_i é constante, dependendo apenas da montagem dos sensores, e ele é tal que a norma da projeção dos valores do giroscópio sobre o plano sagital é a mesmo para sensores consecutivos. Estes são encontrados através da minimização da função custo apresentadas na Equação (2), na qual, o erro de alinhamento entre os giroscópios de dois segmentos consecutivos é modelado. Para maiores detalhes veja a Subseção 2.4 e Seção 3 deste trabalho.

$$e_j(k) = \|g_T(k) \times j_T\|_2 - \|g_S(k) \times j_S\|_2, k = 1, \dots, N. \quad (2)$$

no qual o simbolo $\|\cdot\|_2$ representa a norma Euclidiana.

2.2.2 Identificação dos deslocamentos o_i

Os vetores $o_i = (o_{i_x}, o_{i_y}, o_{i_z})$ representam o deslocamento do sensores em relação à articulação, estes também são constantes considerados constantes e dependem apenas da montagem. A identificação dos deslocamentos o_i são determinados pelas acelerações devido ao movimento entorno da articulação, explorando a comportamento da articulação

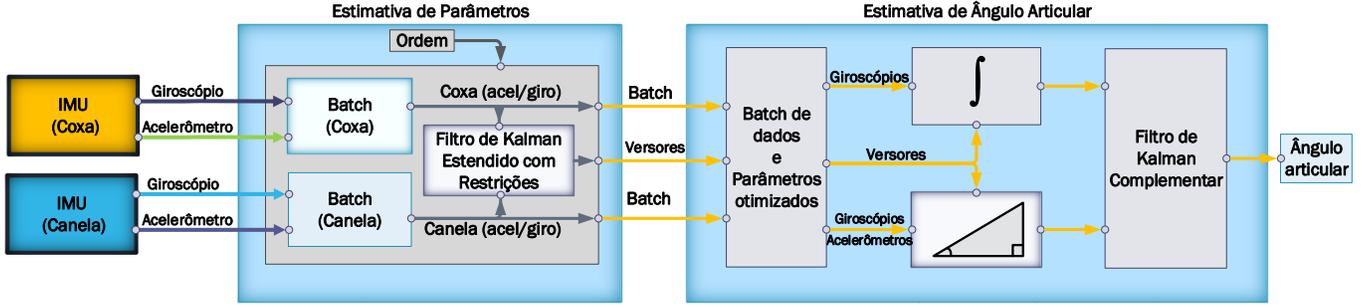


Figura 3: Diagrama geral do sistema. Neste, as IMU's fornecem um lote (*Batch*) de dados para a etapa de estimativa de parâmetros, onde o Filtro de Kalman com Restrições ajusta os versores associados ao alinhamento dos sensores com base em um número de repetições definidos pelo parâmetro *Ordem*. Posteriormente, 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.

com uma junta rotacional, Figura 4(b). Esta aceleração é descrita por $\Gamma_{g_i(k)}(o_i)$, que é aceleração radial e tangencial devido à rotação em torno do centro da articulação, e pode ser calculada da seguinte forma

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

em que $g_i(k)$ é a medida registrada pelo giroscópio fixado no segmento i , e $o_i = (o_{ix}, o_{iy}, o_{iz}) \in [-1, 1]$ é o vetor deslocamento desejado.

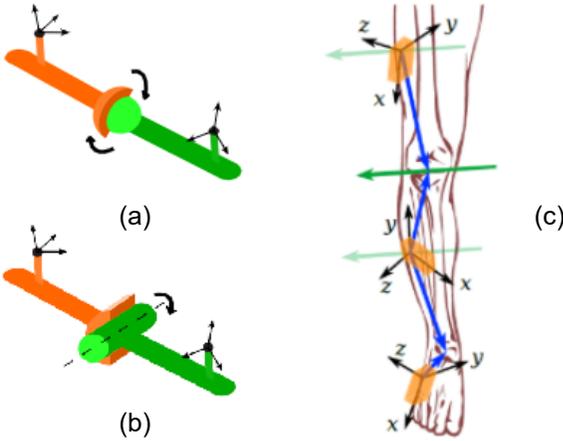


Figura 4: (a) Aproximação articular mais próxima de um joelho real. (b) Restrição articular adotada para estimativa angular no plano sagital. (c) Versores de posição dos sensores em relação as articulações (azul) e articulação projetada no plano sagital (verde). Fonte: [23].

O vetor o_i é encontrado através da minimização da função custo apresentada na Equação (3), 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 2.4 e Seção 3 deste trabalho.

$$e_o(k) = \|a_T(k) - \Gamma_{g_T(k)}(o_T)\|_2 + \|a_S(k) - \Gamma_{g_S(k)}(o_S)\|_2 \quad (3)$$

Por fim, é utilizado as estimativas obtidas de j_i para correção dos valores de deslocamentos o_i , como mostrado na equação

$$o_T = o_T - j_T \frac{o_T \cdot j_T + o_S \cdot j_S}{2},$$

$$o_S = o_S - j_S \frac{o_T \cdot j_T + o_S \cdot j_S}{2}$$

A partir destes vetores é possível estimar o ângulo articular apenas utilizando as medidas do giroscópio e acelerômetro.

2.2.3 Cálculo do ângulo articular

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

$$\alpha_{giro}(k) = \int_{t_0}^{t_1} (g_T(\tau) \cdot j_T - g_S(\tau) \cdot j_S) d\tau, k = 1, \dots, N \quad (4)$$

sendo $g_i(\tau)$, para $i = \{T, S\}$, a informação do giroscópio em seu respectivo segmento i , τ é a constante de tempo de integração associada ao período de amostragem.

Como é esperado essa integração possui um inclinação (*drift*) devido ao erro do sensor, e com o tempo essa estimativa diverge cada vez mais do resultado desejado. Então é necessário utilizar a medida do acelerômetro para realizar a mesma estimativa, afim de compensar esse desvio.

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

$$\alpha_{acel}(k) = \arccos\left(\frac{u_T(k) \cdot u_S(k)}{\|u_T(k)\|_2 \cdot \|u_S(k)\|_2}\right), k = 1, \dots, N \quad (5)$$

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

$$u_i(k) = (\tilde{a}_i(k) \cdot x_i, \tilde{a}_i(k) \cdot y_i), \quad (6)$$

em que $x_i = j_i \times c$ com $c \nparallel j_i$ 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 (6) é a projeção do acelerômetro $a_i(k)$ no centro da articulação e é calculada da seguinte maneira

$$\tilde{a}_i(k) = a_i(k) - \Gamma_{g_i(k)}(o_i), \quad (7)$$

sendo $a_i(k)$ a informação do acelerômetro triaxial do segmento i .

Por fim, é necessário combinar ambos resultados para obter a estimativa do ângulo da articulação. Para tal foi utilizado um filtro de Kalman Complementar para realizar a fusão dos sinais.

2.3 Filtro de Kalman Complementar (FKC)

2.3.1 Fusão de sensores

A fusão de sensores é um método utilizado para combinar sinais de diferentes fontes em apenas um sinal ou informação. Essas fontes são geralmente sensores ou dispositivos capazes de mensurar as mudanças no ambiente [30]. O intuito desse método é compensar as características negativas de cada uma das fontes com características desejadas das outras, afim de obter o resultado esperado.

2.3.2 Filtro

A utilização do filtro de Kalman na abordagem complementar (FKC) fornece um alto grau de generalidade, com isso sendo capaz de realizar a integração/fusão de uma variedade de sinais de sensores auxiliares. Outro fator importante é sua rápida resposta dinâmica para as variáveis de estado, evitando assim problemas com grandes atrasos, que é uma das desvantagens na utilização de algoritmos de filtragem principalmente para sistemas que operam em tempo real. Essas características existem porque ele opera apenas a combinação dos erros dos sinais modelados com os erros dos sinais auxiliares.

Na sequência, o FKC foi utilizado para realizar a fusão dos ângulos articulares obtidos através do giroscópio (α_{giro}), Equação (4), e acelerômetro (α_{accel}), Equação (5). É gerado o erro entre as duas estimativas ($\Delta\alpha(k)$) como um fator de correção do *drift* devido a integração do erro de medida.

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 [15], [25].

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

Assim, a saída estimada $\Delta\hat{\alpha}_K(t)$, foi somada ao ângulo articular do giroscópio $\alpha_{K_{giro}}(t)$ 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 $z_k = \Delta\alpha$.

Algorithm 1 : Filtro de Kalman Complementar

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

Predição:

$$\begin{aligned} \hat{x}_{k+1} &= A\hat{x}_{k|k} \\ \hat{P}_{k+1} &= AP_{k|k}A_k^T + BQ_kB^T \end{aligned}$$

Correção:

$$\begin{aligned} K_{k+1} &= P_{k+1}H^T(HP_{k+1}H^T + R)^{-1} \\ \hat{x}_{k+1|k+1} &= \hat{x}_{k+1} + K_{k+1}(z_k - H\hat{x}_{k+1}) \\ P_{k+1|k+1} &= (I - K_{k+1}H)P_{k+1} \end{aligned}$$

2.4 Ajuste online dos parâmetros

Diferentemente do ajuste de parâmetros proposto por [23], no qual um algoritmo de otimização baseado em Gauss-Newton era executado de forma *offline*, primeiro os parâmetros eram obtidos e depois o sistema de estimativa era executado, neste trabalho nós propomos o ajuste *online* por pacotes de dados, sendo utilizado um filtro de Kalman como estimador de parâmetros.

Em [23], 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 conseqüente comprometeria o valor real da estimativa angular em tal situação.

Neste trabalho foi 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, $batch_D$, foi realizado a minimização das equações (2) e (3) através de um número mínimos de iterações definido como *ordem*, para o algoritmo de minimização escolhido. Sendo que neste trabalho, foi optado por utilizar um Filtro de Kalman Estendido com pontos fixos como restrições, na abordagem de [27], que reduz consideravelmente o custo computacional e promove sua aplicação em processamentos *online*, conseqüência da fatoração da equação de diferença de Ricatti que é naturalmente inserida na dedução do filtro, [31] e [27].

O objetivo é encontrar parâmetros que minimizem as funções custos (2) e (3), por meio de aproximações sucessivas empregando-se um Filtro de Kalman Estendido. Desta forma, os valores estimados, iterativamente, aproximam-se dos custos mínimos e satisfazendo as restrições impostas.

Assim, seguindo modelo proposto por [27], utilizado a

dinâmica do erro dado pelas derivadas das equações (2) e (3), 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 (2) e (3).

Uma vez que e_l é 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

$$\frac{\partial e_j(k)}{\partial \Psi_j} = \frac{\partial(g_T(k) \times j_{T2})}{\partial j_T} \frac{\partial j_T}{\partial \Psi_{j_T}} - \frac{\partial(g_S(k) \times j_{S2})}{\partial j_S} \frac{\partial j_S}{\partial \Psi_{j_S}} \quad (10)$$

sendo

$$\frac{\partial(g_i(k) \times j_{i2})}{\partial j_i} = \frac{(g_i(k) \times j_i) \times g_i(k)}{g_i(k) \times j_{i2}} \in \mathbb{R}^{1 \times 3}, \quad (11)$$

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 (7).

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 $N = batch_D$, $F_o = P_{0_o} = I_6$, $Q_o = 10^{-3} \cdot I_6$, $R_j = 10^{-3} \cdot I_N$.

3 Resultados e Discussões

Nesta sessão é apresentado os resultados obtidos com o sistema proposto neste trabalho. O foco das discussões e resultados é a comparação entre a saída do sistema com o

Algorithm 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:

$$\begin{aligned}\hat{x}_{k+1} &= F \hat{x}_{k|k} \\ \hat{P}_{k+1} &= F P_{k|k} F^T + Q_k\end{aligned}$$

Erro e matriz Jacobiana:

para $k = 1$ até $batch_D$ **faça**

$$\begin{aligned}\text{Calcule } r_l &= -e_l(k) &> \text{Equações (2) ou (3)} \\ \text{Calcule } H_l(k) &&> \text{Equação (9)}\end{aligned}$$

fim para

Correção:

$$\begin{aligned}K_{k+1} &= P_{k+1} H_l(k)^T (H_l(k) P_{k+1} H_l(k)^T + R)^{-1} \\ \hat{x}_{k+1|k+1} &= \hat{x}_{k+1} + K_{k+1} r_k \\ P_{k+1|k+1} &= (I - K_{k+1} H_l(k)) P_{k+1}\end{aligned}$$

fim para

Saída:

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

signal de referência do *encoder*, sendo este considerado um sensor de alta precisão. Ademais, é apresentado as análises quanto ao tamanho do janelamento do sinal, bem como o número de iterações necessárias para se obter resultados equivalentes ao do *encoder*.

3.1 Obtenção dos dados

As amostras de dados utilizados no trabalho foram obtidos de um paciente saudável com 33 anos de idade, 1.72m de altura vestindo o exoesqueleto H2. Durante a coleta de dados o paciente se moveu a 1.5Km/h sobre uma esteira durante 1 minuto.

Nas Figuras 5 e 6 são apresentados uma janela dos dados obtidos pelo EXOH2 e foram utilizados para o teste dos algoritmos.

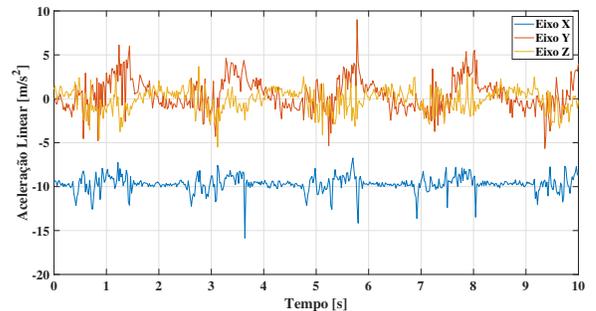


Figura 5: Sinais do acelerômetro fixado em exoesqueleto para captura de movimentos da coxa esquerda. Fonte: [32]

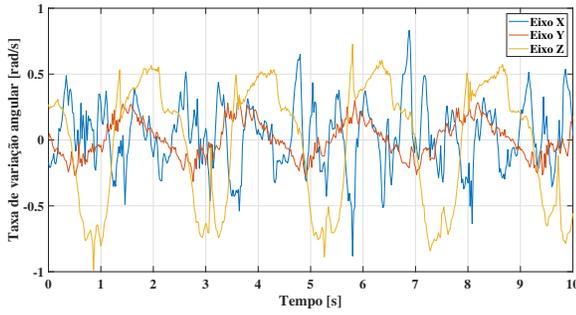


Figura 6: Sinais do giroscópio fixado em exoesqueleto para captura de movimentos da coxa esquerda. Fonte: [32]

3.2 Janelamento e minimização dos dados

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. O sistema proposto pode ser observado na Figura 3, enquanto o janelamento das medidas dos sensores através e a estimativa do ângulo articular do joelho são descritas no Algoritmo 3.

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.

Algorithm 3 : Algoritmo do sistema para estimativa do ângulo articular

```

para  $k = 1$  até tamanho( $dados_{sensor}$ ) faça
    contador ++
    se contador ==  $s_w$  então
        contador = 1
    para  $k \leftarrow 1$  até ordem faça
         $j_i = \text{minimize}$  Equação (2)           ▷ Algoritmo 2
         $o_i = \text{minimize}$  Equação (3)         ▷ Algoritmo 2
    fim para
    fim se
     $\alpha_{giro}(k) = \text{Equação (4)}$   $\alpha_{acel}(k) = \text{Equação (5)}$   $\alpha(k) = \text{FKC}(\alpha_{giro}, \alpha_{acel})$    ▷ Algoritmo 1
    fim para
    
```

3.3 Análise do erro de estimativa

Como o número de iterações e comprimento da janela afetam diretamente o resultado da estimativa, foram realizados estudos quanto ao efeito deles sobre os vetores j_i e o_i . Com isso, 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 (2) e (3), através das Figuras 7 e 8, respectivamente.

Nas Figuras 7 e 8 é possível observar um comportamento semelhante. Os efeitos da ordem sobre o erro de estimativa dos vetores j_i e o_i são rapidamente estabilizados, dessa forma se tornando praticamente constante a partir de determinado valor. Para o erro do vetor de posição esse valor é 2, já para o erro do vetor de deslocamento é 4. Com isso, é possível concluir que o efeito para obter boas estimativas para ambos os parâmetros é necessário um pequeno número de iterações, mostrando assim a rápida convergência do filtro de Kalman como estimador.

Quanto ao efeito do tamanho do janelamento sobre o erro de estimativa também apresenta um comportamento semelhante tanto para j_i quanto para o_i . Quando os valores de *batch* são inferiores a 100 os valores de erro apresentam os menores valores, e para valores superiores ele apresenta um comportamento oscilatório entorno de um *setpoint*.

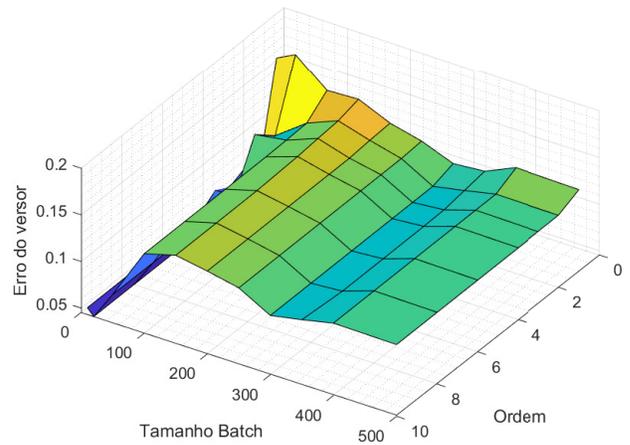


Figura 7: Efeito da variação do *batch* e da ordem sobre o erro do vetor de posição. Fonte: Autor

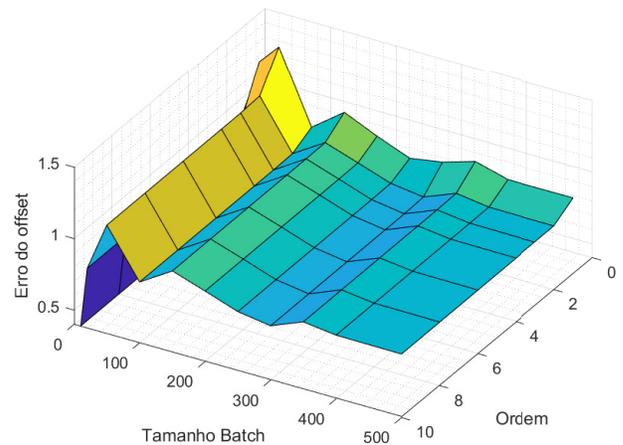


Figura 8: Efeito da variação do *batch* e da ordem sobre o erro da estimativa do vetor de deslocamento. Fonte: Autor

Porém apenas essas duas análises não descrevem totalmente o problema de escolha para os valores da *ordem* e tamanho do *batch*, porque ainda é necessário observar a

estimativa final do ângulo articular. Então, foi realizada a análise do efeito da variação desses parâmetros sobre o coeficiente de correlação de Person entre a estimativa do sistema e o sinal do *encoder*. O dessa análise é mostrado na Figura 9, e nela é possível observar que para valores a baixo de 100 do tamanho do *batch* a correlação é baixa. Com isso, apesar dos erros de estimativas das Figuras 2 e 3 serem baixos, para que a estimativa dos parâmetros se aproxime do resultado esperado, é necessário ter um conjunto de dados com um tamanho mínimo.

Portanto, de posse dos resultados apresentados pelas Figuras 7, 8 e 9, propomos que a escolha dos parâmetros s_w e *ordem* sejam realizados desconsiderando as regiões com baixa correlação delimitadas pela Figura 9, 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 (2) e (3).

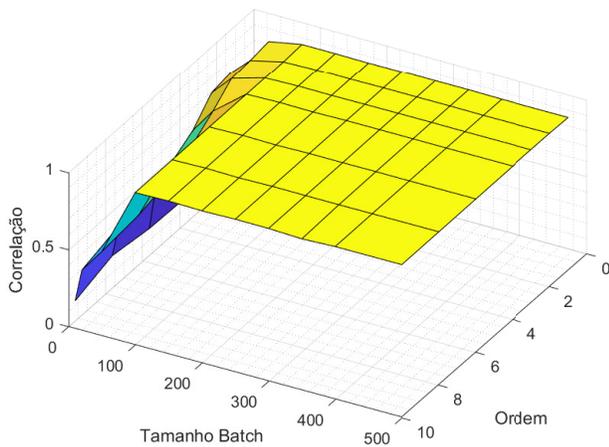


Figura 9: Efeito sobre a correlação entre a estimativa do ângulo articular do joelho obtido pelo sistema proposto e pelo sistema de referência. Fonte: Autor

3.4 Efeito da *ordem* e s_w sobre o tempo de processamento

Além da análises sobre a qualidade da estimativa foi também calculado o tempo de processamento dos dados utilizados. Lembrando que como os dados já foram previamente obtidos, então essa análise é referente ao tempo de processamento de todo o conjunto de dados utilizados. No caso dessa análise mais importante que os valores exato é o comportamento, pois esses valores podem variar e não são absolutos. O algoritmo foi executado diversas vezes, em cada uma delas os valores apresentavam variações, porém a tendência era a mesma.

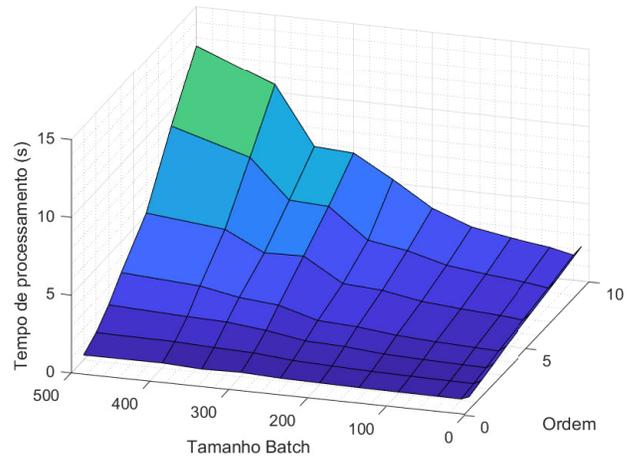


Figura 10: Efeito sobre o tempo de processamento da janela utilizada. Fonte: Autor

3.5 Resultados para a estimativa do joelho

A partir da análise apresentadas anteriormente foram realizadas estimativas para diferentes combinações de s_w e *ordem*. Utilizando o sistema apresentado foram obtido os resultados que pode ser observado na Figura 11 e na Tabela 1. Na Figura 11 os traços verticais separam três janelas. Para esses resultados foi utilizado $s_w = 500$ e *ordem* = 6. Nele a estimativa apresenta um $RMSE = 1.0044^\circ$ e Correlação = 0.9976.

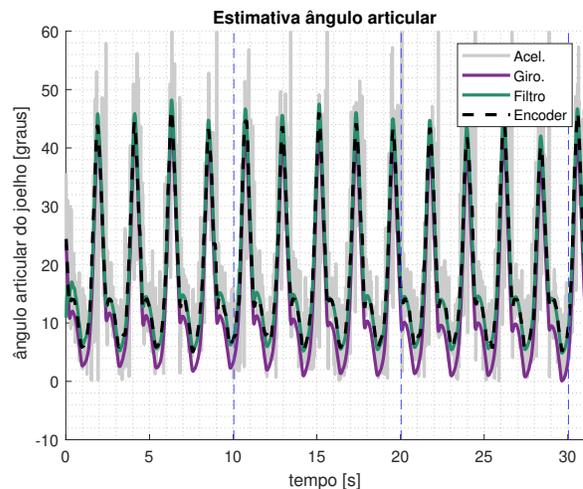


Figura 11: Comparação das estimativas do ângulo articular joelho com a referência (*encoder*). Fonte: Autor

Na Tabela 1 são mostradas outros resultados para estimativa do ângulo articular. Como é possível observar pelos valores de correlação e $RMSE$, eles são diretamente proporcionais aos valores de *ordem* e s_w . Porém, a variação do resultado pode ser ou não significativa dada a aplicação ao qual ela está associada, isso quer dizer, se ela precisa ou não de alta precisão do ângulo articular, visto que que quanto maior os valores de *ordem* e s_w maior será o seu tempo de processamento, como pode ser observado na Figura 10.

Tabela 1: Variação da correlação e *RMSE* para dadas combinações de *ordem* e *s_w*

<i>ordem</i>	<i>s_w</i>	Correlação	<i>RMSE</i>
2	50	0.9948	3.3946
2	100	0.9953	1.4108
2	400	0.9972	1.2714
2	600	0.9978	1.1468
4	200	0.9968	1.1022
8	600	0.9980	0.9749

3.6 Análise de robustez do sistema

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 12(a). 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.

Porém com isso entra mais um questão para o problema: o tempo para a estimativa voltar a ser confiável. Na Figura 12 foi utilizado um *s_w* menor que o da Figura 11, isso porque quanto menor o valor de *s_w* maior é a frequência em que os dados são atualizados, com isso a convergência para os parâmetros de *j_i* e *o_i*. Quando é utilizado o *s_w* = 400 o resultado é o que pode ser observado na Figura 12(b).

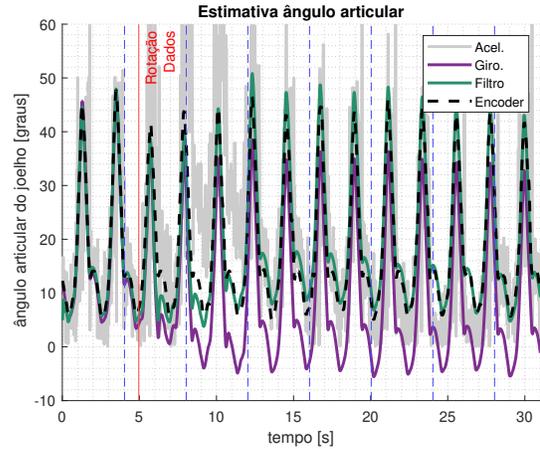
Portanto, pode se notar duas etapas para o sistema. A primeira é até a primeira estimação dos parâmetros, nela quanto maior o valor de *s_w* melhor será a estimativa dos parâmetros com isso teremos melhores resultados, como pode ser observado na Tabela 1. A segunda etapa é quando o sistema já esta funcionando e a principal função dele é responder rápido a possíveis mudanças dos sensores, nesta etapa o valor de *s_w* deve ser menor para convergir para os novos valores de *j_i* e *o_i*.

4 Expectativas de resultados futuros

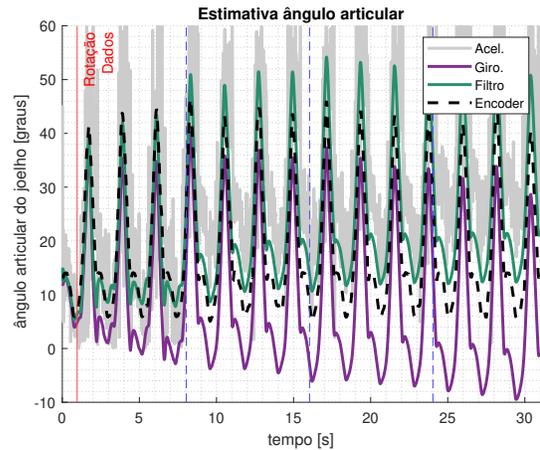
Para trabalhos futuros o objetivo seria a aplicação do método proposto para outras articulações do corpo. Diferentemente do joelho as articulações do quadril e do calcanhar possuem peculiaridades que dificultam a implementação, pois articulação do joelho é a que mais se aproxima do modelo proposto.

Na articulação do quadril temos o sensor do tronco, o qual possui pouco movimento, com isso os dados do acelerômetro são muito próximos do ruído. E para a articulação do calcanhar temos o sensor do pé, o qual é posicionado num plano diferente dos demais. Então para realizar estimativas precisas desta articulações é necessário um filtro robusto para a fusão dos sinais do acelerômetro e do giroscópio.

Foram realizados testes em outras articulações, porém o resultado não chegou na mesma qualidade do apresentado neste trabalho. Com isso, estudos visando a melhoria no



(a)



(b)

Figura 12: (a) Estimativa do ângulo articular com dados rotacionados para *s_w* = 200 e *ordem* = 6. (b) Estimativa do ângulo articular com dados rotacionados para *s_w* = 400 e *ordem* = 6. Fonte: Autor

sistema fusão dos sinais poderia ser promissora, visto que foi utilizado um filtro de Kalman simples. Então futuros trabalhos poderiam ser realizados quanto a mudança dessa técnica, podendo utilizar outros filtros de Kalman como o extendido, o *uncented*, ou outro método que seja robusto para tais estimativas.

Além disso, a aplicação da metodologia em um sistema embarcado poderia ser outro trabalho para o futuro, visto que foram apenas utilizados dados já obtidos. Nesse caso, seria observado a resposta do sistema com o processamento dos dados em tempo real, principalmente a correção de posição dos sensores.

Outra vertente para futuras pesquisas seria a classificação de atividades utilizando as estimativas de ângulo articular e atitude de cada membro inferior do corpo. Na Figura 11 apresenta um padrão para o movimento de marcha, então poderia-se estudar outros padrões de movimento.

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

A metodologia promove também outras formas de se vestir o sensor, sem a necessidade de alinhamento entre os sensores, é possível realizar medições apenas vestindo o sensor, e o sistema será responsável pela localização dos sensores em relação a articulação, podendo assim estudar o movimento do paciente sem que tenha alguma restrição de movimento, sendo assim mais adequado para medidas de longas durações em um gama maior de atividades diárias.

Outro ganho do sistema é referente ao custo para se realizar a medida, a remoção do *encoder* do exoesqueleto torna o mesmo mais barato. Desta forma, facilitando o acesso a esse tipo de análise para mais paciente que necessitam de reabilitação motora. Ademais, é facilidade também o pré processamento dos dados, isso porque é um sensor ameno para se realizar a sincronização dos dados no tempo.

Por fim, 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.

6 Apêndice

Agradecimentos

Agradeço aos meus pais que sempre me incentivaram e apoiaram nos meus estudos, sendo eles peças fundamentais para as minhas conquistas. Agradeço também ao meu irmão que foi um companheiro durante todos os meus anos de vida, inclusive durante a faculdade.

E por fim, agradeço as pessoas que participam do grupo de pesquisa ao qual esse trabalho esta vinculado, pois elas foram responsáveis por me guiar e ajudar nas dificuldades que se apresentaram durante todo o processo.

Referências

[1] H. Zhou and H. Hu, “Human motion tracking for rehabilitation—a survey,” *Biomedical Signal Processing and Control*, vol. 3, pp. 1–18, 01 2008.

[2] A. M. Dollar and H. Herr, “Lower extremity exoskeletons and active orthoses: Challenges and state-of-the-art,” *IEEE Transactions on Robotics*, vol. 24, no. 1, pp. 144–158, feb 2008.

[3] M. P. de Looze, T. Bosch, F. Krause, K. S. Stadler, and L. W. O’Sullivan, “Exoskeletons for industrial application and their potential effects on physical work load,” *Ergonomics*, vol. 59, no. 5, pp. 671–681, oct 2015.

[4] I. Pacifico, A. Parri, S. Taglione, A. M. Sabatini, F. S. Violante, F. Molteni, F. Giovacchini, N. Vitiello, and S. Crea, “Exoskeletons for workers: A case series study in an enclosures production line,” *Applied Ergonomics*, vol. 101, pp. 1–12, may 2022.

[5] H. Luinge and P. Veltink, “Measuring orientation of human body segments using miniature gyroscopes and accelerometers,” *Medical biological engineering computing*, vol. 43, pp. 273–82, 04 2005.

[6] V. Bonnet, C. Mazza, P. Fraisse, and A. Cappozzo, “Real-time estimate of body kinematics during a planar squat task using a single inertial measurement unit,” *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 7, pp. 1920–1926, jul 2013.

[7] H. Ahmed and M. Tahir, “Improving the Accuracy of Human Body Orientation Estimation With Wearable IMU Sensors,” *IEEE Transactions on Instrumentation and Measurement*, vol. 66, no. 3, pp. 535–542, mar 2017.

[8] C. Bouten, K. Koekkoek, M. Verduin, R. Kodde, and J. Janssen, “A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity,” vol. 44, pp. 136–147, 1997.

[9] B. Kemp, A. J. Janssen, and B. [van der Kamp], “Body position can be monitored in 3d using miniature accelerometers and earth-magnetic field sensors,” *Electroencephalography and Clinical Neurophysiology/Electromyography and Motor Control*, vol. 109, no. 6, pp. 484 – 488, 1998. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0924980X98000538>

[10] O. J. Woodman, “An introduction to inertial navigation,” University of Cambridge, Computer Laboratory, Tech. Rep. UCAM-CL-TR-696, Aug. 2007. [Online]. Available: <https://www.cl.cam.ac.uk/techreports/UCAM-CL-TR-696.pdf>

[11] N. El-Sheimy, H. Hou, and X. Niu, “Analysis and modeling of inertial sensors using allan variance,” *IEEE Transactions on Instrumentation and Measurement*, vol. 57, no. 1, pp. 140–149, 2008.

[12] D. Roetenberg, H. Luinge, C. Baten, and P. Veltink, “Compensation of magnetic disturbances improves inertial and magnetic sensing of human body segment orientation,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 13, no. 3, pp. 395–405, sep 2005.

[13] M. Kok, J. D. Hol, and T. B. Schön, “Using inertial sensors for position and orientation estimation,” *Foundations and Trends® in Signal Processing*, vol. 11, no. 1-2, pp. 1–153, 2017.

[14] 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>

[15] S. L. Nogueira, S. Lambrecht, R. S. Inoue, M. Bortole, A. N. Montagnoli, J. C. Moreno, E. Rocon, M. H. Terra, A. A. G. Siqueira, and J. L. Pons, “Global kalman filter approaches to estimate absolute angles of lower limb segments,” *BioMedical Engineering OnLine*, vol. 16, no. 1, p. 58, May 2017. [Online]. Available: <https://doi.org/10.1186/s12938-017-0346-7>

[16] R. S. Inoue, V. Guizilini, M. H. Terra, and F. Ramos, “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, sep 2017.

[17] T. Watanabe, H. Saito, E. Koike, and K. Nitta, “A preliminary test of measurement of joint angles and stride length with wireless inertial sensors for wearable gait evaluation system,” *Computational Intelligence and Neuroscience*, vol. 2011, pp. 1–12, 2011.

[18] T. Seel, M. Kok, and R. S. McGinnis, “Inertial sensors—applications and challenges in a nutshell,” *Sensors*, vol. 20, no. 21, p. 6221, oct 2020.

[19] L. Pacher, C. Chatellier, R. Vauzelle, and L. Fradet, “Sensor-to-segment calibration methodologies for lower-body kinematic analysis with inertial sensors: A systematic review,” *Sensors*, vol. 20, no. 11, p. 3322, jun 2020.

[20] B. Fan, Q. Li, T. Tan, P. Kang, and P. B. Shull, “Effects of IMU sensor-to-segment misalignment and orientation error on

- 3-d knee joint angle estimation,” *IEEE Sensors Journal*, vol. 22, no. 3, pp. 2543–2552, feb 2022.
- [21] J. Favre, B. Jolles, R. Aissaoui, and K. Aminian, “Ambulatory measurement of 3d knee joint angle,” *Journal of Biomechanics*, vol. 41, no. 5, pp. 1029–1035, 2008.
- [22] A. Forner-Cordero, M. Mateu-Arce, I. Forner-Cordero, E. Alcántara, J. C. Moreno, and J. L. Pons, “Study of the motion artefacts of skin-mounted inertial sensors under different attachment conditions,” *Physiological Measurement*, vol. 29, no. 4, pp. N21–N31, apr 2008.
- [23] T. Seel, J. Raisch, and T. Schauer, “Imu-based joint angle measurement for gait analysis,” *Sensors (Basel, Switzerland)*, vol. 14, pp. 6891–909, 04 2014.
- [24] F. Olsson, M. Kok, T. Seel, and K. Halvorsen, “Robust plug-and-play joint axis estimation using inertial sensors,” *Sensors*, vol. 20, no. 12, p. 3534, jun 2020.
- [25] E. Francelino, M. Pereira, R. Inoue, M. Terra, A. Siqueira, and S. Nogueira, “Markov system with self-aligning joint constraint to estimate attitude and joint angles between two consecutive segments,” *Journal of Intelligent & Robotic Systems*, vol. 104, no. 3, p. 43, Feb 2022. [Online]. Available: <https://doi.org/10.1007/s10846-022-01572-w>
- [26] P. R. Albuquerque, E. H. Francelino, and S. L. Nogueira, “Orientação espacial em exoesqueletos de membros inferiores utilizando filtros markovianos,” in *Falta Preencher*. unpublished, Jan. 2021.
- [27] D. M. Walker, “Parameter estimation using Kalman filters with constraints,” *International Journal of Bifurcation and Chaos*, vol. 16, no. 04, pp. 1067–1078, apr 2006.
- [28] T. Seel, T. Schauer, and J. Raisch, “Joint axis and position estimation from inertial measurement data by exploiting kinematic constraints,” 10 2012, pp. 45–49.
- [29] M. Bortole, A. Venkatakrisnan, F. Zhu, J. Moreno, G. Francisco, J. Pons, and J. Contreras-Vidal, “The h2 robotic exoskeleton for gait rehabilitation after stroke: Early findings from a clinical study wearable robotics in clinical testing,” *Journal of neuroengineering and rehabilitation*, vol. 12, p. 54, 06 2015.
- [30] J. Sasiadek, “Sensor fusion,” *Annual Reviews in Control*, vol. 26, no. 2, pp. 203–228, 2002. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1367578802000457>
- [31] M. Birgmeier, “A fully Kalman-trained radial basis function network for nonlinear speech modeling,” in *Proceedings of ICNN’95 - International Conference on Neural Networks*, vol. 1, 1995, pp. 259–264 vol.1.
- [32] E. H. Francelino, “Sistema markoviano espacial autoalinhável para estimativa angular de atitude e articular entre dois segmentos consecutivos,” Master’s thesis, Programa de Pós-Graduação em Engenharia Elétrica da UFSCar, 2021.