

# ESTIMAÇÃO DE MOVIMENTOS DO PUNHO EM TEMPO REAL COM FILTRO DE KALMAN PARA CONTROLE DE PRÓTESES ATIVAS FUNCIONAIS.

BRUNO GOMES DUTRA\*, LUÍS AUGUSTO MESQUITA DE CASTRO\*, GABRIELA SOUZA DE AMORIM\*, ANTONIO DA SILVA SILVEIRA\*

*\*Laboratório de Controle e Sistemas, Universidade Federal do Pará  
Belém, Pará Brasil*

*E-mails: brunodutra@ufpa.br, luismesquita@ufpa.br, gaby\_amorim@outlook.com, asilveira@ufpa.br*

**Abstract**—The functionality of myoelectric prostheses, available for people who have suffered some type of amputation or congenital defect, still need to be improved enough. For, the purpose of the prosthesis is to replace the disability its user and give back the functions of the lost member. This paper proposes a method of estimating movement from myoelectric signals for the control of electrical prostheses. In the estimation method the Kalman filter is used to optimize the pre-processing of the myoelectric signal. The carpal radial flexor muscles and carpal ulnar extensor are used for validation of the method for estimation of flexion and extension of the wrist and the control of opening and closing a robotic gripper proportionally to the levels of estimated contractions of the muscles investigated. The Real-time experimental tests for motion estimation and control of a robotic jaw prove the effectiveness of the motion estimation method developed.

**Keywords**—Myoelectric signals, motion estimation, Kalman filter, control of robotic gripper, real time processing.

**Resumo**—A funcionalidade de próteses mioelétricas, disponíveis para pessoas que sofreram algum tipo de amputação ou defeitos congênitos, ainda precisam ser bastante aprimoradas. Pois, o objetivo da prótese é substituir a deficiência do seu usuário e devolver as funções do membro perdido. Este artigo propõe um método de estimação de movimento a partir de sinais mioelétricos para controle de próteses elétricas. No método de estimação utiliza-se o filtro de Kalman para otimizar o pré-processamento do sinal mioelétrico. Para validação do método são utilizados os músculos flexor radial do carpo e extensor ulnar do carpo para estimação do movimento de flexão e extensão do punho e realiza-se o controle de abrir e fechar uma garra robótica proporcionalmente aos níveis de contrações estimados dos músculos investigados. Os testes experimentais realizados em tempo real para estimação de movimentos e controle de uma garra robótica comprovam a eficácia do método de estimação de movimento desenvolvido.

**Palavras-chave**—Sinais mioelétricos, estimação de movimentos, filtro de Kalman, controle de garra robótica, processamento em tempo real.

## 1 Introdução

O estudo e a utilização de sinais mioelétricos (SMEs) são de grande importância para o avanço em pesquisas que utilizam próteses elétricas (Menegaldo, 2012, Geethanjali, 2016). No entanto, a funcionalidade ainda é um desafio que requer maior exploração científica, pois no desenvolvimento de membros robóticos o objetivo do produto é poder substituir a deficiência do seu usuário da maneira mais semelhante à fisiológica, com o objetivo de proporcionar ao usuário, por meio da utilização da prótese, movimentos funcionais que cheguem o mais próximo dos normais, e não utilizar a prótese como meramente um membro estético sem função.

Os sinais mioelétricos de superfície, que são adquiridos com a coleta a partir de eletrodos em contato com a pele, são preferidos por serem acessados de forma mais fácil, pois para sua medição não se utiliza de um procedimento invasivo (Geethanjali, 2016). Porém, a utilização dos SMEs de superfície apresentam grandes entraves em relação às aplicações em tempo real, dos quais se destacam a grande quantidade de ruído estocástico presente após a fase de amplificação, pois o sinal tem cerca de 50  $\mu$ V a 5 mV de amplitude (Hakonen et al., 2015), a inferência de fibras

musculares secundárias na contração do músculo registrado, conexões de eletrodos com micro curtos ou quebrados e a entrada direta de ruído por artefatos causado pelos movimentos do usuário ou contato fraco entre a pele e o sensor. Com isso, dificultando o processamento online do sinal e a geração de referências para controle de próteses.

Existem muitos métodos para eliminar esses problemas, como o uso demasiados filtros de pré e pós-processamento, janelamentos do sinal e a utilização de técnicas para determinar a ativação do músculo registrado. Porém, a maioria dos métodos utilizados acabam atrasando a resposta desejada (Menegaldo, 2012) e em sua maior parte envolvem grande carga computacional, pois apresentam filtros de ordens elevadas e a utilização de classificadores, assim comprometendo a estabilidade do sistema de controle e o desempenho de atuadores mecatrônicos envolvidos nesse processo (López, et al., 2009). Para processos online, a técnica utilizada para identificação da intenção de movimento precisa funcionar com fluidez, de forma que seja rápida e recursiva, pois existe um compromisso entre a exatidão e o tempo de resposta, já que, por exemplo, para uma frequência de amostragem de 500 Hz, um atraso entre 40 ms e 50 ms é o máximo aceito sem que a prótese apresente falta de resposta do sinal de

comando (Hakonen et al., 2015). Dentro de um loop de controle mioelétrico, o tempo de reposta tolerável depende das propriedades de estabilidade, como as margens de ganho e fase. De acordo com (Moraes, 2016), desde a medição até o comando de ação do atuador, o tempo de resposta deve ser menor ou igual a 300 ms, para que o usuário não perceba os atrasos dos atuadores.

Frente a esse cenário, este trabalho utiliza a técnica de filtragem com filtro de Kalman (FK) para otimizar e melhorar a medição dos SMEs com o objetivo de filtrar componentes de alta frequência nos sinais, atenuar ruídos de artefatos de movimento (López, et al., 2009) e corrigir a sensibilidade às mudanças de amplitude, devido aos altos níveis de amplificação requeridos (Delis, 2011), de maneira que o processamento seja rápido, de baixo custo computacional e eficaz. É utilizada a técnica de mínimos quadrados recursivos (MQR) para obter o modelo auto regressivo (AR) do sistema relacionado ao sinal mioelétrico (SME), devido a sua natureza estocástica, para filtragem em tempo real com o filtro de Kalman com o objetivo de evitar atrasos no processamento dos sinais e otimizar o processo de geração de referências para as malhas de controle. Utiliza-se neste estudo o músculo flexor radial do carpo e o músculo extensor ulnar do carpo, responsáveis pela flexão e extensão do punho, respectivamente. Para validar o método proposto, o resultado do processamento é utilizado para estimar referências de extensão e flexão em tempo real para a malha de controle proporcional, integral e derivativo (PID) de uma garra mecatrônica, de forma que possa ter um movimento natural e de fácil aprendizado relacionando os níveis de contração dos músculos registrados com os movimentos da prótese.

As próximas seções deste artigo estarão organizadas da seguinte forma: inicialmente, na Seção 2 apresenta-se o modelo autoregressivo do SME. Na seção 3 é apresentado o Filtro de Kalman. Na seção 4 é apresentada a bioinstrumentação e processamento. Em seguida, na seção 5, serão apresentados os resultados de estimação da técnica abordada e o resultado de controle PID para rastreamento da referência estimada de flexão e extensão do punho em uma garra robótica. Finalizando, na seção 6 se apresenta a conclusão do trabalho.

## 2 Identificação do Modelo Auto Regressivo

Os SME apresentam ruídos de medição e de processo, sendo o primeiro pelo contato dos eletrodos com a pele e o segundo é pela relação sinal e ruído amplificados no condicionamento. O sistema mioelétrico pode ser descrito como um processo estocástico no qual a função de densidade de probabilidade se aproxima de uma função Gaussiana. Então, o mesmo pode ser considerado uma série temporal, sendo modelado por uma combinação de seus valores passados e presentes (DELIS, 2011). Dessa forma, utiliza-se o modelo auto regressivo para representação do sinal. Sua forma matemática é dada por (DELIS, 2011):

$$y(k) = \sum_{i=1}^4 -a_i y(k-i) + \xi(k) \quad (1)$$

onde  $y(k)$  é o valor medido no instante  $k$ ,  $\xi(k)$  um sinal do tipo ruído branco e  $a_i$  representa os coeficientes do modelo AR.

Os parâmetros do modelo auto regressivo contêm informações que servem para justificar o modo de contração muscular. A ordem do modelo AR, deve ser escolhida de maneira a produzir um sistema bem condicionado, no qual o erro de estimação, dado pela diferença entre o valor medido e o valor estimado, deve ser próximo a um ruído branco. Com isso, trabalhos desenvolvidos como de (Huang et al, 2005) e (Liu et al, 2007) definem que modelos de quarta a sexta ordem são eficientes para representar as características do SME como uma série temporal. Dessa forma, objetivando um menor processamento computacional, utiliza-se o modelo de quarta ordem para representação do sinal

Foi utilizado o método de estimação por mínimos quadrados recursivos (Coelho; Coelho, 2015) para identificar, a partir dos SMEs, os coeficientes do modelo AR.

Considerando que o filtro de Kalman é uma técnica aplicável quando os modelos estão descritos sob a forma de espaço de estado (Betti, 2012), reescreve-se o modelo AR, descrito em (1), na forma canônica observável em espaço de estados (Silveira, 2012):

$$x(k+1) = \mathbf{A}x(k) + \mathbf{I}w(k) \quad (2)$$

$$y(k) = \mathbf{C}x(k) + v(k) \quad (3)$$

sendo que  $x(k)$  é o vetor de estados,  $\mathbf{A}$  é a matriz de transição de estados,  $\mathbf{I}$  é a matriz identidade,  $w(k)$  é o ruído de processo,  $\mathbf{C}$  é a matriz que associa os estados à saída medida do processo e  $v(k)$  é o ruído de medição. As Matrizes  $\mathbf{A}$  e  $\mathbf{C}$  são obtidas pela seguinte relação:

$$\mathbf{A} = \begin{bmatrix} -a & \mathbf{I}_{(n_a-1)} \\ & \mathbf{0}_{1 \times (n_a-1)} \end{bmatrix}, \quad (4)$$

$$\mathbf{C} = [1 \quad \mathbf{0}_{1 \times (n_a-1)}], \quad (5)$$

$$\text{para } a^T = [a_1 \quad a_2 \quad \cdots \quad a_{n_a}]$$

$$\text{e } n_a = 4.$$

## 3 Filtro de Kalman

O filtro de Kalman é uma ferramenta bastante utilizada na engenharia para a estimação, fusão e filtragem em tempo real. Este filtro é considerado por muitos

um grande avanço da teoria de estimação do século XX, pois, essa ferramenta possui baixa complexibilidade computacional e realiza estimação ótima de estados de um sistema dinâmico linear. De forma simplificada o filtro de Kalman é uma formulação de predição-correção, pois utiliza o modelo linear predefinido do sistema para prever o estado do próximo passo de iteração e adiciona uma componente para atualizar os erros no modelo através das observações atuais do sistema (Diniz, 2008).

Para melhor entendimento, o FK é um processo ótimo de estimação de estados para o problema Gaussiano linear, por meio da minimização do erro de estimação quadrático. Tal problema consiste na estimação dos estados instantâneos de um sistema dinâmico linear perturbado por ruído branco, por meio de medições linearmente relacionadas aos estados, também contaminadas por ruído branco (Façanha; Carneiro; Filho, 2013). O erro de estimação é causado pelas perturbações, constituídas pelas incertezas na estimativa inicial do vetor de estados e pelos ruídos de processo e de medida (Façanha; Carneiro; Filho, 2013).

Com isso, o FK tem como objetivo filtrar erros de estimação e ruído, de forma que a variável de estado consiga a melhor correção possível, reduzindo o erro quadrático médio (Paulo, 2008).

A estrutura do FK, utilizado nesta pesquisa, é exatamente a mesma de um observador de estados determinístico de Luenberger e o estimador de Kalman é projetado pelo caso dual ao Regulador Linear Quadrático (LQR, do inglês *Linear Quadratic Regulator*) de horizonte infinito, o qual, baseia-se na equação a diferenças de Riccati (EDR) (Goodwin; Sin, 1984) para o cálculo da matriz de covariância do erro,  $P$ , e ganho de Kalman,  $K$ . Para isso, utiliza-se a matriz de covariância do ruído de processo,  $Q$ , e a matriz de covariância do ruído de medição,  $R$ , tal que a EDR é descrita por.

$$P(k+1) = AP(k)A^T - AP(k)C^T (CP(k)C^T + R)^{-1} CP(k)A^T + Q \quad (6)$$

A matriz de covariância  $P$  em (6) baseia-se na minimização do funcional quadrático

$$J = \mathbf{E} \left\{ [x(k) - \hat{x}(k)]^T [x(k) - \hat{x}(k)] \right\} \quad (7)$$

em que  $\mathbf{E}$  é o operador de esperança matemáticas e  $J$  é utilizado com o método dos mínimos quadrados para o cálculo do ganho ótimo  $K$ , com base no resultado da  $P := P(k \rightarrow \infty)$ , calculado conforme mostrado a seguir:

$$K = APC^T (CPC^T + R)^{-1} \quad (8)$$

Com isso, determina-se que a estimativa  $\hat{x}(k)$  do vetor de estados seja capaz de minimizar o erro de estimação  $e_{est}(k) = x(k) - \hat{x}(k)$ .

$$\hat{x}(k+1) = \mathbf{A}\hat{x}(k) + K[y(k) - \hat{y}(k)] \quad (9)$$

A partir da retroalimentação a expressão representada em malha fechada do estimador em (9) é dado por:

$$\hat{x}(k+1) = (\mathbf{A} - \mathbf{K}\mathbf{C})\hat{x}(k) + \mathbf{K}y(k) \quad (10)$$

Representando a entrada medida  $y(k)$  pela variável  $emg_i(k)$ , a equação (10) assume a seguinte forma:

$$\begin{aligned} \hat{x}_i(k+1) &= (\mathbf{A} - \mathbf{K}\mathbf{C})\hat{x}_i(k) + K emg_i(k) \\ emg_{est_i}(k) &= \mathbf{C}\hat{x}_i(k) \end{aligned} \quad (11)$$

onde  $emg_i$  representa o sinal registrado de eletromiografia,  $emg_{est_i}$  é o resultado filtrado e estimado do sinal de entrada medido e  $i$  representa o número do canal utilizado, já que são utilizados 2 canais para medição de sinais mioelétricos.

O resultado do Filtro de Kalman apresenta um sinal estimado e mais suave em relação ao sinal medido. Na Figura 1 representa-se o diagrama de blocos de um sistema autoregressivo que utiliza o Filtro de Kalman, no qual pode-se perceber a relação existente entre o Filtro e o sistema, em que os estados estão sendo estimados.

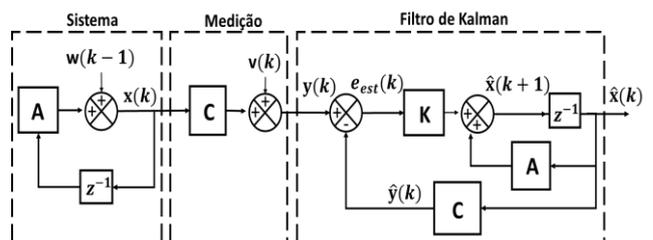


Figura 1. Diagrama em blocos do sistema autoregressivo, modelo de medição e filtro de Kalman.

### 3.1 Sintonia do filtro de Kalman

A sintonia do FK deve garantir que a saída estimada siga a saída média do processo e forneça um ganho  $K$  que minimize o impacto dos ruídos Gaussiano no erro de estimação. A sintonia do filtro de Kalman é feita pela apropriada seleção das matrizes de ponderação  $Q$  e  $R$ . Para a ponderação das matrizes leva-se em consideração que a matriz  $Q$  é responsável por moldar a curva de magnitude em frequência do Filtro de Kalman e a matriz  $R$  é responsável por deslocar a

curva de magnitude em frequência para os lados, podendo ser utilizada para ajustar a frequência de corte desejada para o Filtro. Com isso, se tem a seguir o valor definido para as matrizes, obtidos por tentativa e erro para se estabelecer, com base nos modelos identificados neste trabalho, a frequência de corte de 10 Hz:

$$Q = \begin{bmatrix} 20 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}; R = 500 \quad (12)$$

#### 4 Bioinstrumentação e Processamento

Os testes de registro dos sinais, processamento e controle do dispositivo robótico foram feitos com auxílio de um protótipo portátil de bancada, denominado de módulo de bioinstrumentação. O equipamento de bioinstrumentação é composto pela placa Arduino Due, baseada no microcontrolador ATSAM3X8E, e 4 unidades do circuito, de baixo custo e disponível comercialmente, Muscle Sensor V3 (MSV3) (Advancer Technologies, 2017), ponte H (L293D) e servomecanismo acoplado a uma garra robótica. Na Figura 2 apresenta-se o equipamento de bioinstrumentação e um diagrama esquemático do mesmo.

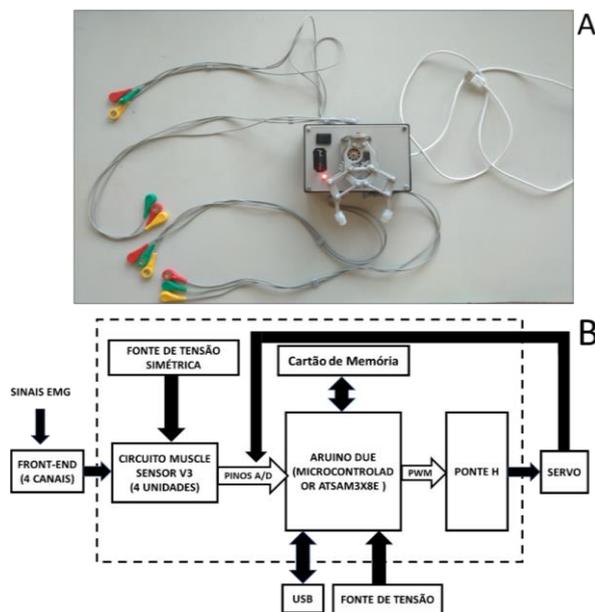


Figura 2. (A) Equipamento experimental de bioinstrumentação, (B) Esquemático do equipamento bioinstrumental.

O SME é registrado por eletrodos superficiais localizados nos músculos flexor radial do carpo e extensor ulnar do carpo (Figura 3) (Geethanjali, 2016). Cada grupo muscular recebe um canal de coleta de eletromiografia, com isso cada músculo recebe três eletrodos, sendo dois para registro do potencial elétrico e o eletrodo restante é utilizado como eletrodo de referência. Com auxílio do circuito MSV3 realiza-se a

aquisição, amplificação, filtragem, retificação e uma pré-filtragem no sinal mioelétrico.



Figura 3. Posicionamento dos eletrodos no ventre do músculo flexor radial do carpo e extensor ulnar do carpo.

O circuito MSV3 de eletromiógrafo, que realiza a aquisição, condicionamento do sinal e pré-processamento, possui 5 etapas. A primeira etapa consiste na aquisição e pré-amplificação do SME bruto, por meio do amplificador diferencial AD8226 com ganho 200 de amplificação. Na segunda etapa, o sinal passa por um filtro passa alta, com frequência de corte em 100 Hz, para eliminar perturbações de baixa frequência e qualquer polaridade DC (*offset* DC) inerente no sinal. Em seguida na terceira etapa, realiza-se a retificação do sinal registrado, na configuração de onda completa. Na quarta etapa, o valor absoluto do sinal mioelétrico retificado é alisado por um filtro passa-baixa passivo, com frequência de corte de 5 Hz, resultando em um envoltório linear. Por último, o sinal é amplificado pelo amplificador operacional TL084, com um ganho variável de 1-1000 definido por um potenciômetro.

O sinal registrado, obtido pela utilização do circuito, é um sinal retificado filtrado e amortecido, representando um envelope linear da magnitude do sinal mioelétrico bruto. Este sinal é passado pela porta analógico/digital de 12 bits do Arduino due, configurada com 1kHz de taxa de amostragem de aquisição. No Arduino é realizado o cálculo do filtro de Kalman para as duas medições de SMEs em seguida os resultados filtrados dos sinais provenientes dos canais de flexão e extensão são subtraídos para formar o movimento estimado. Pois, como são músculos antagonistas, em uma contração isométrica, ao realizar movimento de extensão ou de flexão do punho, os mesmos têm contrações máximas e mínimas intercaladas. Ou seja, quando um está realizando contração máxima o outro está realizando uma contração mínima e vice-versa. A não ser que a contração seja elástica ou exista movimentos musculares involuntários

O sinal resultante da subtração é normalizado com amplitude entre 0 e 5, no qual valores acima de 2,5 representam o movimento de flexão, valores abaixo de 2,5 representam movimentos de extensão e valores em 2,5 representam a ausência de movimento, como ilustrado na Figura 4. Após isso o sinal é passado para o computador pela porta serial e para a malha de controle PID realizar o rastreamento da referência, com a garra mecânica.

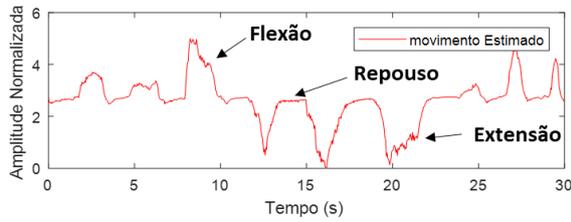


Figura 4. Movimento estimado

Na Figura 5 representa-se o fluxograma de funcionamento da técnica de estimação de movimentos utilizada. A técnica consiste em realizar a subtração dos sinais filtrados de cada grupo muscular para gerar o movimento estimado de extensão e flexão. O resultado final é uma referência proporcional à contração, para a malha de controle seguir e atuar com a garra robótica. Com isso, o usuário pode controlar a posição e velocidade da garra de acordo com a intensidade da contração muscular e tem como auxílio a realimentação visual.

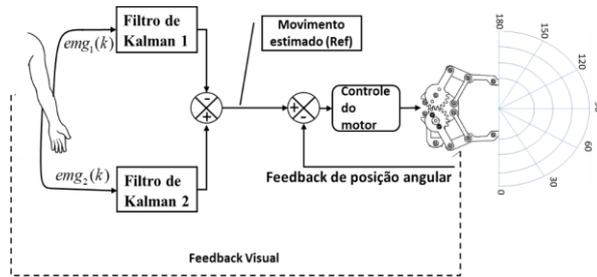


Figura 5. Controle de garra a partir de SMEs

#### 4.1 Sintonia da malha de controle

A partir de dados entrada, tensão aplicada nos terminais do motor, e dados saída, resposta do potenciômetro presente no eixo do servomecanismo, utiliza-se o método de mínimos quadrados para identificar o modelo discreto do servo motor

$$G_s = \frac{0,006341z^2 + 0,01433z}{z^2 - 1,466z + 0,4662} \quad (13)$$

a malha de controle PID digital, responsável por controlar a garra, foi sintonizada pela técnica de cancelamento dinâmico dos polos, disponível em (Araujo, et al., 2017), com objetivo de impor no servomecanismo um comportamento de primeira ordem em malha fechada. Foi definido, por tentativa e erro, um tempo de amostragem de 0,1 segundos e escolhida uma constante de tempo de subida em malha fechada de  $\tau = 0,25$  segundos. Os valores resultantes da sintonia das constantes que regem a lei de controle do PID digital, representadas pelo termo proporcional  $K_p$ , integral  $K_i$  e derivativa  $K_d$ , são representadas na tabela 1.

Tabela 1. Constantes PID

Constantes PID	
$K_p$	8,5103
$K_i$	0,0319
$K_d$	0,7435

A função de transferência em malha fechada do controlador PID digital com o modelo discreto do servo motor é representada por:

$$G_{mf} = \frac{0,05868z^4 + 0,02067z^3 - 0,1997z^2 + 0,1204z}{1,059z^4 - 3,345z^3 + 3,952z^2 - 2,085z + 0,4196} \quad (14)$$

## 5 Estimação de Referências e Resultados

Seguem como resultados os testes realizados, de acordo com a bioinstrumentação, para contrações baixas, médias e altas, dos músculos flexor radial do carpo e extensor ulnar do carpo. Apresenta-se o sinal após a filtragem com FK, o resultado do sinal estimado de movimento para a garra robótica e o rastreamento da referência gerada pela malha de controle.

Nota-se na Figura 6 a presença dos sinais resultantes da filtragem com FK, para testes de contrações baixas, médias e altas dos músculos medidos.

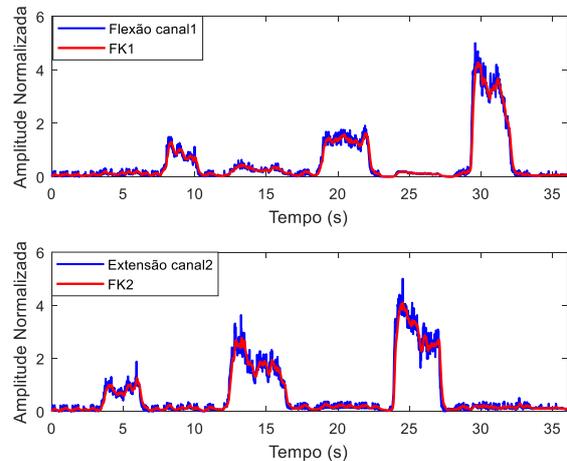


Figura 6. Resultado dos sinais registrados nos canais 1 e 2 filtrados pelo filtro de Kalman.

Na Figura 7 apresenta-se os sinais filtrados normalizados. Nela está presente também o resultado da subtração desses sinais, que representa o movimento estimado e é utilizado como referência para o servomecanismo da garra robótica seguir.

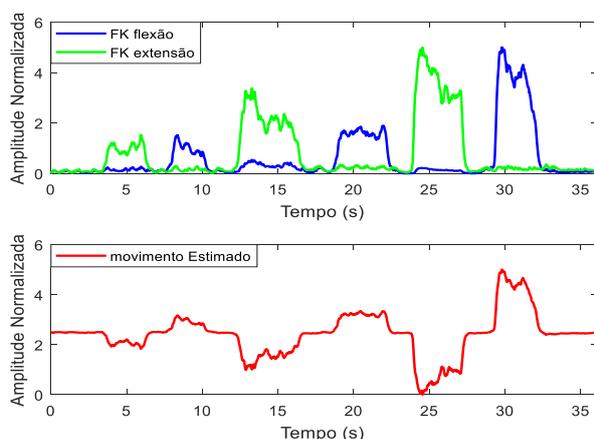


Figura 7. O gráfico superior representa o resultado dos sinais de extensão e flexão filtrados pelo FK. No gráfico inferior demonstra-se o movimento estimado.

Na Figura 8 apresenta-se o resultado final do método, no qual o sinal de referência entra na malha de controle e a garra é ativada. Percebe-se no gráfico que o atuador abre e fecha proporcionalmente aos níveis de contração musculares. Sendo que em 5 a garra está completamente fechada, em 0 está completamente aberta e em 2,5 está no meio termo, representando ausência de movimento.

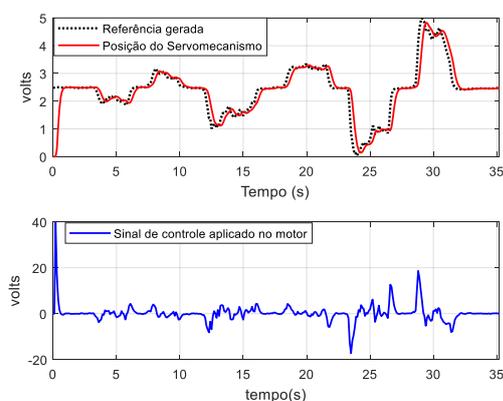


Figura 8. O gráfico superior representa a resposta do motor seguindo a referência estimada. O gráfico inferior é a lei de controle u, que representa a tensão inserida no motor.

## 6 Conclusão

Neste artigo, apresentou-se um método de filtragem de SME e estimação de movimentos para controle de próteses mioelétricas. Como principal objetivo, buscou-se aprimorar a etapa de pré-processamento de envelope linear do SME por meio da filtragem e estimação com filtro de Kalman e realizar a estimativa da intenção de movimento, a partir dos níveis de contrações musculares de extensão e flexão do punho, para controle de uma garra robótica.

Explicou-se a importância da utilização do filtro de Kalman nos SMEs. Visto que, é uma técnica de

filtragem recursiva, estimação ótima, com baixo custo computacional e de fácil implementação.

Para validação do método proposto, utilizou-se um módulo de bioinstrumentação, para realizar registros de SMEs, embarcar o filtro de Kalman, a técnica de estimação de movimento e a sintonia de controle PID.

Após as análises dos resultados percebeu-se que devido ao baixo custo computacional e aplicabilidade em tempo real, a técnica de filtragem com filtro de Kalman mostrou-se eficiente para filtrar componentes de alta frequência e ruídos passados pelo filtro de primeira ordem contido na placa MSV3 de aquisição e condicionamento de SMEs. Com isso, melhorando a relação sinal/ruído e fornecendo uma referência, com o mínimo de variações gaussianas, para malha de controle. Após as análises dos resultados experimentais, conclui-se que o método de identificação de movimento é eficaz em tempo real e funcionou com êxito para controle da garra robótica utilizada.

Como contribuições futuras, sugere-se a utilização de classificadores recursivos em conjunto com as técnicas abordadas, para aumentar o número de atuadores robóticos e ainda assim manter as características de robustez do sistema. Sendo assim, em pesquisas futuras, pode-se investigar se o método, de filtragem com filtro de Kalman, pode melhorar a classificação de movimentos ao se utilizar classificadores presentes na literatura, como as redes neurais e lógica fuzzy. Outra contribuição válida seria a utilização da técnica de estimação de movimento abordada em conjunto com um algoritmo de controle preditivo, como o controle gaussiano de variância mínima generalizada (GMV) (Silveira, 2012), para minimizar os atrasos envolvidos nos atuadores e manter a robustez da malha de controle.

## Agradecimentos

Os autores agradecem ao apoio financeiro do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) da Universidade Federal do Pará (UFPA), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq (408559/2016-0) e a Fundação de Amparo a Estudos e Pesquisa (FAPESPA)(ICAAF 049/2016).

## Referências Bibliográficas

- Advancer Technologies, 2017. *Muscle Sensor v3 Manual*. [Online] Available at: <http://www.advancertechnologies.com/p/muscle-sensor-v3.html>
- Araujo, M. S. et al., 2017. Projeto de controladores digitais PID e I-PD via RST: Uma análise de desempenho. *Simpósio Brasileiro de Automação inteligente (SBAI)*.
- Betti, V. A., 2012. *Estudos teóricos na estimação em processos K-factor gamma via modelo de espaço*

- de estudos utilizando filtro de Kalman*, Rio Grande do Sul.
- Coelho, A. A. R. & Coelho, L. S., 2015. *Identificação de sistemas dinâmicos lineares*. 2ª Revista ed. Florianópolis: Ed. da UFSC.
- Delis, A. L. et al., 2011. Myoelectric knee angle estimation algorithms for control of active transfemoral leg prostheses. *In Self Organizing Maps-Applications and Novel Algorithm Design. InTech.*
- Diniz, P. S., 2008. Adaptive Filtering Algorithm and Practical Implementation. *Springer Science+Business Media, LLC*.
- Façanha, T. S., Carneiro, A. L. & Filho, J. T. C., 2013. FILTRO DE KALMAN VIA PROGRAMAÇÃO QUADRÁTICA. *Simpósio Brasileiro de Automação Inteligente (SBAI)*.
- Geethanjali, P., 2016. *Myoelectric control of prosthetic hands: state-of-the-art review*. s.l., s.n., p. 247.
- Goodwin, G. C. & Sin, K. S., 1984. Adaptive Filtering, Prediction and Control. Englewood Cliffs. *NJ: Prentice-Hall*, pp. 248-252.
- Hakonen, Maria, Piitulainen, H. & Visala, A., 2015. Current state of digital signal processing in myoelectric interfaces and related applications. *Biomedical Signal Processing and Control*. Volume 18, pp. 334-359.
- Huang, Y., Englehart, K. B., Hudgins, B. & Chan, A. D., 2005. A Gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses. *IEEE Transactions on Biomedical Engineering*, 52(11), pp. 1801-1811.
- Liu, Y. H., Huang, H. P. & Weng, C. H., 2007. Recognition of electromyographic signals using cascaded kernel learning machine. *IEEE/ASME Transactions on Mechatronics*, 12(3), pp. 253-264.
- López, N. M., Di Sciascio, F., Soria, C. M. & Valentinuzzi, M., 2009. Robust EMG sensing system based on data fusion for myoelectric control of a robotic arm. *Biomedical engineering online*, 8(1), p. 5.
- Menegaldo, L. L., 2012. Exploring possibilities for real-time muscle dynamics state estimation from EMG signals. *Biomedical Robotics and Biomechanics (BioRob), 2012 4th IEEE RAS & EMBS International Conference on*, pp. 1850-1855.
- Moraes, R. B. D., 2016. *Metodologia para detecção automática da ativação muscular em sinais eletromiográficos*, Rio Grande do Sul: Pontifícia Universidade Católica do Rio Grande do Sul.
- Paulo, S. D., 2008. Adaptive filtering: algorithms and practical implementation. *The international series in Engineering and Computer Science*, pp. 23-50.
- Silveira, A. S., 2012. *Contribuições Ao Controle De Variância Mínima Generalizado: Abordagem De Projeto No Espaço De Estados*. Florianópolis: Tese submetida ao Programa de Pós-Graduação