

Desenvolvimento de algoritmo para detecção de movimentos por EMG e comparação com técnica do Operador de Energia de Teager-Kaiser

Lima, Gabriel da Rocha Adamoski¹; Mendes Junior, José Jair Alves²; Campos, Daniel Prado³

1 – Programa de Pós-Graduação em Engenharia Biomédica, UTFPR, limag.2000@alunos.utfpr.edu.br

2 – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, UTFPR, jjjunior@utfpr.edu.br

3 – Programa de Pós-Graduação em Engenharia Biomédica, UTFPR, danielcampos@utfpr.edu.br

DOI 10.52050/9788579177149-04

RESUMO

Diante da demanda de melhores técnicas de reconhecimento de gestos em próteses mioelétricas, este estudo visa desenvolver um algoritmo de detecção de movimento e examinar sua precisão. O trabalho tem também como objetivo comparar o uso da técnica do Operador de Energia de Teager-Kaiser (TKEO) para o tratamento dos sinais, utilizando do índice de Jaccard para avaliar a similaridade com o gesto realizado após a aplicação de técnicas fundamentadas na literatura. Como resultado foi obtido uma precisão de 66% sem o TKEO e 80% com o TKEO, indicando que o algoritmo poderia ser usado em próteses mioelétricas.

Palavras-chave: Eletromiografia de superfície, Tecnologia assistiva para membros superiores, Processamento de sinais, Operador de Energia de Teager-Kaiser

ABSTRACT

Given the demand for better gesture recognition techniques in myoelectric prostheses, this study aims to develop a motion detection algorithm and examine its accuracy. The work also aims to compare the use of the Teager-Kaiser Energy Operator (TKEO) technique for signal processing, using the Jaccard index to evaluate the similarity with the gesture made after applying techniques based on the literature. The result was an accuracy of 66% without TKEO and 80% with TKEO, indicating that the algorithm could be used in myoelectric prostheses.

Keywords: *Surface electromyography, Assistive technologies for upper limbs, Signal processing, Teager-Kaiser Energy Operator*

1. INTRODUÇÃO

Eletromiografia de superfície (sEMG) é amplamente usada em próteses mioelétricas comerciais como uma maneira não invasiva de extrair biosinais elétricos para reconhecimento de movimentos (YU et al., 2023, p. 1-18). As próteses mioelétricas disponíveis possuem diversas funcionalidades, como a de abrir e fechar os dedos (JIRALERSPONG et al., 2023, p. 1163) e a atuação de gestos específicos realizados por sinais em pares para a ativação e desativação dos atuadores, que causam um controle pouco intuitivo para pessoas com amputação no membro superior (PAN et al., 2018, p. 1435-1442). Um dos problemas com as próteses mioelétricas é a limitação a um grupo de músculos usado para detectar alguns movimentos básicos, criando uma situação insatisfatória para pessoas que precisam desta tecnologia assistiva, operando de maneira muito distante da mão humana (ROCHE et al., 2014, p. 1-11). O atual cenário de insatisfação quanto a pouca interatividade destas próteses faz com que exista uma demanda de melhores maneiras de se medir e controlar movimentos com sEMG (PASQUINA et al., 2015, p. 85-93).

Um método bem estudado e promissor é o de identificação de padrões de gestos (VIDODIC et al., 2016, p. 961-970) e intenção de movimento por atividade elétrica muscular, tanto estática quanto com músculos em contração (OSKOEI; HU, 2007, p. 275-294), que são comuns em pesquisas, mas possuem dificuldades para serem implementadas em próteses comerciais devido ao extensivo treinamento e diferença nos sinais elétricos das pessoas (RAHIMIAN et al., 2021, p. 1004-1015). O desempenho dos sensores também é dependente do local em que os eletrodos são conectados e que são menos sensíveis em casos de amputação (STAPORNCHASIT et al., 2019, p. 1-12). Um problema específico em amputações em membros superiores é de reproduzir os movimentos dos dedos, que não tem músculos de ativação na região sensorial ou apenas em músculos profundos, dificultando a captura do sinal (AL-TIMEMY et al., 2013, p. 608-618).

Quanto ao processamento dos sinais, existem diferentes técnicas já fundamentadas para análises nos domínios do tempo e frequência, desde o reconhecimento de padrões entre gestos, quanto a computação de características do EMG com vetores multidimensionais (LI et al., 2021, p. 1-20). Existe também a implementação de métodos sofisticados de controle com feedback de sinais, onde a força ou velocidade exercida pelo usuário é transferida para os atuadores com maior precisão quanto ao movimento humano (WU et al., 2015, p. 1-15). Dentre os métodos disponíveis, foi considerado o Operador de Energia de


Teager-Kaiser (TKEO) como caso de estudo quanto ao aumento do desempenho com baixo custo computacional (WANG et al., 2025, p. 1565987).

O objetivo deste trabalho é apresentar o desenvolvimento de um algoritmo para detectar a realização de movimento através do sinal sEMG, levando em consideração os métodos comumente empregados na literatura e comparar a eficiência do Operador de Energia de Teager-Kaiser no uso do algoritmo, identificando se poderia ser utilizado para reabilitação em pacientes com amputações no membro superior.

2. MATERIAIS E MÉTODOS

Para simular os sinais de movimento foi necessário usar um banco de dados coletados por sensores sEMG. O banco de dados escolhido foi o Ninapro DB, devido a abordagem para coleta dos sinais, que se assemelha com condições reais (Rahimian et al., 2021, p. 1004-1005), além da grande quantidade de dados, amostras e gestos realizados (Milosevic et al., 2017, p. 1432-1437). O banco de dados Ninapro disponibiliza diversos sinais, como o sinal EMG bruto, o estímulo, reestímulo e movimento realizado pelo usuário. Dentre os datasets disponibilizados, foi escolhido o DB2, caracterizado por conter 12 sensores mioelétricos, 8 destes na região do antebraço, e os outros 4 no braço (Atzori et al., 2014, p. 1-13). O banco de dados DB2 armazena sinais para 17 movimentos distintos realizados por 40 amostras de ambos os sexos com os membros superiores intactos e com idade entre 23 e 45 anos. Diversas etapas para processamento dos sinais foram realizadas pelos pesquisadores ao construir o banco de dados, sendo descritos detalhadamente (Atzori et al., 2014, p. 1-13). Para a coleta do EMG, foram usados sensores Delsys com uma frequência de medição de 2 kHz e com um circuito rejeita-faixa para 50 Hz a fim de remover interferência elétrica da rede. Dentre os 17 gestos da DB2, foram utilizados os movimentos 13 e 14, referentes à flexão e extensão do pulso, respectivamente, já que estes gestos representam movimentos contrários e possuem alta atividade muscular na região do antebraço, onde os sensores estão majoritariamente alocados.

Figura 01 - Fluxograma geral do funcionamento do algoritmo.



A figura 1 mostra as etapas do algoritmo desenvolvido no MATLAB, onde cada amostra terá 4 resultados, sendo estes a flexão do pulso com e sem a aplicação do TKEO e a extensão do pulso com e sem a aplicação do TKEO. As etapas são detalhadas a seguir.

2.1. FILTRAGEM DIGITAL

O propósito de adicionar um filtro, seja ele analógico ou digital, é isolar a faixa de frequência que contém os sinais desejados, eliminando o resto da frequência ruidosa e melhorando a qualidade do sinal. O próprio tecido muscular possui características de um filtro dependendo da distância entre o músculo ativo e o eletrodo (XU; XIAO, 2000, p. 275-281). As configurações utilizadas foram de um filtro passa-baixa com frequência de corte de 500 Hz e filtro de tipo Butterworth que é caracterizado por uma resposta mais estável (XIAO et al., 2023, p. 542-546). A equação do filtro Butterworth é dada por (PERTENCE, 2015, p. 141-157):

$$|H(j\omega)| = \frac{K_{PB}}{\sqrt{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}}}$$

A ordem do filtro foi determinada segundo a condição (XIAO et al., 2023, p. 542-546) abaixo, concluindo que a ordem mínima aceitável é de fator 5:

$$N \geq \frac{\log\left(\frac{\sqrt{10^{0,1As}} - 1}{\sqrt{10^{0,1Ap}} - 1}\right)}{\log(\omega_s/\omega_c)}$$

2.2. RETIFICAÇÃO

A retificação do sinal visa eliminar as amplitudes negativas do EMG e a sua influência na otimização de sinais já é conhecida por outros estudos que apontam que a retificação reduz o erro no sinal (WANG et al., 2022, p. 075001). A retificação ocorre eliminando as amplitudes negativas, as alterando para 0, enquanto mantém o valor do EMG para as amplitudes positivas intactas.

2.3. OPERADOR DE ENERGIA DE TEAGER-KAISER

A lógica desenvolvida por Teager e Kaiser foi inspirada nas propriedades mecânicas de um sistema massa-mola, onde as frequências e amplitudes da onda mecânica podem ser obtidas pelas leis de Newton. O operador de energia usa de uma equação análoga a tais propriedades mecânicas para transformar o sinal elétrico considerando tanto a frequência quanto a amplitude, intensificando assim a energia do sinal (KAISER, 1990, p. 381-384).

O operador possui duas características importantes na aplicação, primeiro é o uso adequado para sinais biológicos devido a tolerância a um cruzamento por zero já que não possui divisão na equação. A outra característica é a necessidade de remover o ruído antes da aplicação do operador, visto que o ruído causará um resultado errôneo após a transformação do sinal (KAISER, 1990, p. 381-384). A equação de Teager-Kaiser é dada por:

$$E_n = x_n^2 - x_{n+1}x_{n-1}$$

Esta técnica é usada para sinais discretos não lineares para calcular a energia instantânea do sinal (WANG et al., 2022, p. 075001), reajustando a amplitude final para concentrar os picos de energia.

2.4. RMS

O objetivo ao transformar o sinal usando RMS (Root Mean Square) móvel é para simplificar o sinal mantendo a variação da amplitude (KAMEN; GABRIEL, 2010, p. 105-154). O RMS móvel realiza o cálculo do RMS em um intervalo. O sinal

que será aplicado o RMS pode ser o EMG após a retificação ou o sinal pós TKEO, dependendo de se a técnica de Teager-Kaiser está sendo avaliada.


$$RMS = \sqrt{\frac{1}{T} \sum_{t=1}^T EMG^2(t)}$$

Durante o processo de transformação do sinal discreto, o EMG é elevado ao quadrado e em sequência é feita a raiz nesse intervalo, modificando as amplitudes negativas (AROZI et al., 2020, p. 36-40). A variável T é o intervalo escolhido, neste caso de 100 ms, sensibilidade determinada para o experimento. O intervalo de 100 ms foi obtido empiricamente a partir de testes preliminares, notando que simplifica o sinal EMG suficientemente, mantendo a forma original da amplitude.

2.5. LIMIAZIZAÇÃO

O algoritmo de limiarização é a lógica usada para transformar o sinal final em um sinal binário igual a 0 ou 1, indicando a intenção de movimento do usuário. A determinação da amplitude de ativação e desativação do movimento é adaptada pelo algoritmo tendo como critérios a quantidade de vezes que o movimento é realizado e quão próximo está do reestímulo original, obtido através de uma análise com o Índice de Jaccard.

Figura 02 - Lógica para determinação de limites do limiar.



Após o processamento inicial dos dados finalizado com o RMS, é feito o módulo da diferença dos pontos discretos a cada 50 pontos, com o intuito de reduzir o custo computacional sem interferir com o sinal final. Este sinal final será utilizado para determinar uma linha de base que é uma linha onde o sinal se encontra em repouso e pode ser adaptada de (SOLNIK et al., 2010, p. 289-298).

$$Th1 = Mb + j * DP$$

São encontrados dois valores para determinar uma faixa de histerese para o limiar, Th1 é o ponto superior onde caso o sinal EMG for superior, retornará o sinal booleano 1, enquanto Th0 é o ponto inferior, e caso o EMG for inferior a este valor, retornará o sinal booleano 0. A média da linha de base (Mb) é a média simples do módulo do sinal diferencial e DP é o seu desvio padrão. iTh é a razão de Th0 para Th1. Tanto j quanto iTh são encontrados através de um loop que determina os melhores resultados. O coeficiente iTh varia entre 0,3 e 1.

$$Th0 = Th1 * iTh$$

Durante o loop, dois fatores são levados em consideração para a escolha de j e iTh, o número de subidas para 1, que deve ser maior ou igual a 6. E em segundo é o índice de Jaccard entre o sinal de reestímulo e o sinal final do algoritmo, que deve se aproximar de 1 indicando total convergência dos sinais e a correta determinação dos movimentos.


$$J(A,B) = \frac{|A \cap B|}{|A \cup B|}$$

O índice de Jaccard é uma métrica de similaridade entre dois sinais, calculados pela interseção e união dos sinais. O valor ótimo de iTh é 6, já que é o número de vezes que os gestos são realizados pelos usuários.

3. RESULTADOS

O resultado esperado para as amostras é ilustrado na figura 03 e foi realizado pela amostra 33 com o movimento de extensão do pulso com o Operador de Energia de Teager-Kaiser, sendo o melhor resultado obtido, com similaridade de 97,2% e 6 detecções de movimento. É possível notar a comparação entre a entrada do sinal após o RMS com a saída booleana, que acompanha quase que identicamente o reestímulo. Também são mostrados os dois pontos de limiar, Th1 acima e Th0 abaixo.

Figura 03 - Exemplo de resultado do algoritmo com amostra número 33.



O resultado final comparando extensão e flexão do pulso com e sem TKEO é disponibilizado a seguir, apresentando o Jaccard médio e o erro padrão para cada caso.

Figura 04 - Resultado final para as 40 amostras.




Tabela 01 - Resultado final detalhado.

Caso	Jaccard Médio	Erro Padrão
Flexão sem TKEO	63,8%	2,79%
Extensão sem TKEO	68,3%	2,58%
Flexão com TKEO	79,2%	2,69%
Extensão com TKEO	81,0%	2,56%

Além da similaridade com o reestímulo, outra métrica mensurada foi a quantidade de vezes em que o sinal de saída detectou o movimento, sendo o ideal 6 vezes. Das 160 vezes, 147 (91,9%) o sinal foi ativado exatamente 6 vezes, as outras 13 foi detectado um número errôneo de ativação do movimento.

4. DISCUSSÃO

Comparando os resultados com e sem a aplicação do Operador de Energia de Teager-Kaiser para os movimentos de flexão e extensão do pulso, foi obtido melhor similaridade com o movimento esperado com a adição do TKEO, sendo a média de flexão e extensão neste caso de 80,1%, em comparação a 66% de similaridade sem o operador de energia. É importante notar que a consistência do usuário ao realizar o movimento interfere com o resultado, visto que os valores do limiar se apresentam em uma faixa ideal para o movimento em questão.

O trabalho não tem como propósito aplicar a técnica em tempo real durante medições de bioassinais com sEMG, principalmente pois a determinação dos pontos do limiar depende de uma leitura completa do sinal após 6 gestos, então essa é uma limitação técnica que deve ser considerada para trabalhos futuros, precisando modificar o algoritmo para operar em tempo real. Uma possível solução seria de obter os valores de Th_0 e Th_1 a partir de uma calibração inicial, monitorando o desempenho do algoritmo do limiar desconsiderando iTh até 6. Além disso, é importante notar que os resultados são referentes aos movimentos de flexão e extensão do pulso, que tem uma região muscular ativa próximo aos sensores, e o desempenho para outros grupos musculares não foi avaliado neste experimento.

5. CONCLUSÕES

O algoritmo de limiarização que emprega várias etapas de tratamento de sinais e a escolha dinâmica dos valores do limiar apresentou resultados satisfatórios, principalmente com o uso do TKEO, com um valor consistente de similaridade na flexão e extensão, de cerca de 80% de similaridade, podendo concluir que o objetivo de desenvolver o algoritmo foi alcançado.

Este modelo para reconhecimento de movimento tem suas limitações práticas, como a dificuldade de ser usado em tempo real ou em um grande período de amostragem, além de reconhecer apenas um gesto por vez. Ainda assim apresenta uma contribuição para a detecção de movimentos pré estabelecidos em próteses mioelétricas.

Para trabalhos futuros é importante verificar se o resultado se mantém para usuários com amputação, visto que as amostras deste experimento têm os membros superiores intactos. Além disso, dada a melhor precisão com o TKEO, seria viável testar esta técnica para algoritmos similares em tempo real a fim de determinar com mais exatidão os gestos realizados e com outros gestos diferentes da flexão e extensão do pulso.

REFERÊNCIAS

- AL-TIMEMY, A. H., BUGMANN, G., ESCUDERO, J., OUTRAM, N. Classification of finger movements for the dexterous hand prosthesis control with surface electromyography. *IEEE Journal of Biomedical and Health Informatics*, v.17, p.608–618. 2013.
- AROZI, M., ARIYANTO, M., KRISTIANTO, A., MUNADI, SETIAWAN, J. D. EMG signal processing of MYO armband sensor for prosthetic hand input using RMS and ANFIS. p. 36-40. 2020.
- ATZORI M., GIJSBERTS A., CASTELLINI, C., CAPUTO B., HAGGER, A. G. M., ELSIG, S., GIATSIDIS, G., BASSETTO, F., MÜLLER, H. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific Data*, v.1, p. 1-13. 2014.
- JIRALERSPONG, T., NAKANISHI, E., LIU, C., ISHIKAWA, J. Experimental study of real-time classification of 17 voluntary movements for multi-degree myoelectric prosthetic hand. *Applied Sciences (Switzerland)*, v.7, p. 1163. 2017.
- KAISER, J. F. On a simple algorithm to calculate the 'energy' of a signal. In: *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing*, p.381–384, Albuquerque, NM, 1990.
- KAMEN, G., GABRIEL, D. A. *Essentials of Electromyography*. Champaign: Human Kinetics, 2010.
- LI, W., SHI, P., YU, H. Gesture recognition using surface electromyography and deep learning for prostheses hand: State-of-the-art, challenges, and future. *Frontiers in Neurorobotics*, v.15, p. 1-20. 2021.
- MILOSEVIC, B., BENATTI, S., FARELLA, E., Design Challenges for Wearable EMG Applications. *Design, Automation & Test in Europe Conference & Exhibition (DATE)*, p. 1432-1437. 2017.
- OSKOEI, M. A., HU, H. Myoelectric control systems-a survey. *Biomedical Signal Processing and Control*, v.2, n.4, p.275–294. 2007.
- PAN, L., CROUCH, D. L., HUANG, H. Myoelectric control based on a generic musculoskeletal model: Toward a multi-user neural-machine interface. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v.26, p.1435–1442. 2018.

PASQUINA, P. F., EVANGELISTA, M., CARVALHO, A. J., LOCKHART, J., GRIFFIN, S., NANOS, G., MCKAY, P., HANSEN, M., IPSEN, D., VANDERSEA, J., BUTKUS, J., MILLER, M., MURPHY, I., HANKIN, D. First-in-man demonstration of a fully implanted myoelectric sensors system to control an advanced electromechanical prosthetic hand. *Journal of Neuroscience Methods*, v.244, p.85–93. 2015.

PERTENCE, A. Jr. *Amplificadores operacionais e filtros ativos: eletrônica analógica*. Porto Alegre: Bookman, 2015.

RAHIMIAN, E., ZABIHI, S., ASIF, A. FARINA, D., ATASHZAR, S. F. MOHAMMADI, A. FS-HGR: Few-Shot Learning for Hand Gesture Recognition via Electromyography. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 29, p. 1004-1005. 2021.

ROCHE, A. D., REHBAUM, H., FARINA, D., ASZMANN, O. C. Prosthetic myoelectric control strategies: A clinical perspective. *Current Surgery Reports*, v.2, p. 1-11. 2014.

SOLNIK, S., RIDER, P., STEINWEG, K., DEVITA, P., HORTOBÁGYI, T. Teager-Kaiser energy operator signal conditioning improves EMG onset detection. *European Journal of Applied Physiology*, v. 110, p. 489-498. 2010.

STAPORNCHASIT, S., KIM, Y., TAKAGI, A., YOSHIMURA, N., KOIKE, Y. Finger angle estimation from array EMG system using linear regression model with independent component analysis. *Frontiers in Neurorobotics*, v.13, p. 1-12. 2019.

VIDOVIC, M. M. C., HWANG, H. J., AMSUSS, S., HAHNE, J. M., FARINA, D., MULLER, K. R. Improving the robustness of myoelectric pattern recognition for upper limb prostheses by covariate shift adaptation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v.24, p.961–970., 2016.

WANG, S., ZHU, S., SHANG, Z. Comparison of different algorithms based on TKEO for EMG change point detection. *Physiological Measurement*, v.43, p.075001. 2022.

WANG, S., ZHAO, G., LIAO, Y. Optimized strategies for developing high-speed muscle activity monitors utilizing multi-resolution energy operator. *Frontiers in Bioengineering and Biotechnology*, v.13, p. 1565987. 2025.

WU, C., SONG, A., LING, Y., WANG, N., TIAN, L. A control strategy with tactile perception feedback for EMG prosthetic hand. *Journal of Sensors*, v.2015, p. 1-15. 2015.

XIAO, Z., YE, J., SHEN, H., DENG, S., ZHU, H., XIAO, H. Analysis of digital filtering design based on surface EMG signals. In: *2023 IEEE 3rd International Conference on Electronic Communications, Internet of Things and Big Data (ICEIB 2023)*, p.542–546. 2023.

XU, Z., XIAO, S. Digital filter design for peak detection of surface EMG. *Journal of Electromyography and Kinesiology*, v.10, p.275-281. 2000.

YU, G., DENG, Z., BAO, Z., ZHANG, Y., HE, B. Gesture classification in electromyography signals for real-time prosthetic hand control using a convolutional neural network-enhanced channel attention model. *Bioengineering*, v.10, p. 1-18. 2023.