

## SENSOR DE MIOGRAFIA DE FORÇA BASEADO EM SMARTPHONE

Matheus S. Rodrigues<sup>1\*</sup>, Eric Fujiwara<sup>2</sup>

1. Estudante da Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas (FEM-UNICAMP)
2. Professor da FEM-UNICAMP - Laboratório de Materiais e Dispositivos Fotônicos

### Resumo

Um sensor de fibra óptica integrado a um smartphone foi proposto para identificar os gestos das mãos através da técnica de miografia de força (FMG), que caracteriza os estímulos da musculatura do antebraço em termos de pressões mecânicas. A lanterna do dispositivo móvel excita duas fibras ópticas poliméricas e os sinais de saída das guias de onda são capturados pela câmera. A intensidade da luz é modulada por meio de transdutores mecânicos de microcurvatura acionados por força presos ao antebraço do usuário, e os sinais ópticos adquiridos são processados por um algoritmo baseado em árvores de decisão e erro residual. Foi atingida uma taxa de acerto de 87% em relação a quatro posturas, conferindo ao sensor confiabilidade associada a uma configuração simples, portátil e de baixo custo integrada a um smartphone.

**Autorização legal:** CAAE 17283319.7.0000.5405.

**Palavras-chave:** classificação; processamento de imagem; fibra óptica.

**Apoio financeiro:** Este trabalho foi financiado em parte pelo PIBIC/CNPq, e em parte pela FAPESP sob a cota 2017/25666-2.

**Trabalho selecionado para a JNIC:** PRP-UNICAMP.

### Introdução

A caracterização dos movimentos da mão humana é essencial para diversas aplicações tecnológicas, como controle de robôs, reabilitação de pacientes e implementação de interfaces homem-máquina [1]. Embora esse monitoramento possa ser realizado com sensores baseados em luvas ou rastreamento óptico, as técnicas de miografia permitem determinar as forças e posturas da mão (ou intenções de movimento) de forma precisa e não-invasiva [1,2].


Na miografia de força (FMG), alternativa mecânica à eletromiografia de superfície (sEMG), os estímulos musculares são detectados na forma de pressões radiais do antebraço, possibilitando a identificação de gestos sem utilizar um grande número de canais ou pré-processamento intensivos dos dados [3]. Os estímulos mecânicos do antebraço geram sinais ópticos modulados, uma vez ocorre a atenuação da luz transmitida pelas fibras ópticas através de perdas por microcurvatura [4]. Ao contrário dos transdutores eletrônicos convencionais, sensores de fibra óptica não são afetados pelas condições da pele ou sudorese, e são imunes à interferência eletromagnética [5].

Neste estudo, um sensor óptico de miografia de força embarcado em um smartphone é proposto para classificar os gestos das mãos através de FMG. Uma aplicação Android foi desenvolvida e testada para a aquisição, processamento e classificação dos sinais ópticos. Experimentos de validação foram realizados com quatro posturas distintas das mãos e a classificação foi realizada por um classificador baseado em árvore de decisão. Finalmente, as taxas de acerto do classificador foram quantificadas e suas curvas características de operação (ROC) foram analisadas para avaliar o desempenho geral do sensor.

### Metodologia

#### Aparato Experimental

O aparato experimental, Fig. 1, consiste em um diodo emissor de luz (LED) que excita um par de fibras ópticas multimodo de polímero (PMMA). Os canais ópticos são fixados ao antebraço do usuário por transdutores de microcurvatura acionados por força. As extremidades das fibras são posicionadas perpendicularmente ao receptor, a câmera CCD do smartphone, onde ocorre a captura de frames de imagem da luz de saída. Visto que a fonte de luz (lanterna) e a câmera fazem parte do smartphone, o acoplamento óptico é feito através de uma case fabricada em impressora 3D sob medida para o aparelho. O hardware no qual o sistema foi integrado é um dispositivo Android SO v8.1. Ele possui um chipset Qualcomm Snapdragon 660, 4 GB de RAM e uma câmera de 12 MP que é utilizada para a captura dos frames em uma resolução 1280x720 p.



**Fig. 1.** Visão geral do sistema de sensoriamento: LED (lanterna); MMF: para de fibras ópticas multimodo de PMMA; CCD: câmera digital.

Para a classificação dos gestos em um conjunto predefinido, uma calibração inicial deve ser realizada. Esses ajustes são indispensáveis devido às singularidades intrínsecas a cada usuário. Um movimento pode exigir um grau de flexão diferente para cada pessoa, por exemplo, produzindo diferentes padrões de intensidade de luz para o mesmo gesto [6,7]. Conforme apresentado na Fig. 1, os dois transdutores de microcurvatura [8] são posicionados nos músculos extensores do antebraço e fixados com tiras de velcro, aplicando uma pré-carga moderada e evitando o desconforto do usuário. Outrossim, o posicionamento dos transdutores é realizado através da palpação dos músculos, objetivando maximizar a sensibilidade em relação aos estímulos. Os experimentos foram realizados de acordo com as recomendações do Comitê de Ética (CAAE 17283319.7.0000.5405).

### Aplicativo Android

A aplicação para aquisição, processamento e classificação dos dados foi desenvolvida na Android API 27, na linguagem de programação Java. O aplicativo possui uma interface intuitiva e de processamento rápido, cujas principais funcionalidades são executadas satisfatoriamente em qualquer smartphone. Os frames são capturados em formato bitmap a um intervalo de amostragem  $\Delta t$  (ms); Em seguida, janelas referentes às duas seções transversais das fibras ópticas são destacadas em sub-bitmaps e analisados quanto à sua intensidade em RGB,

$$I(x_i, y_i) = |[R_i, G_i, B_i]|, \quad (1)$$

$$I_m = \frac{\sum_{i=1}^n I(x_i, y_i)}{n}, \quad (2)$$

onde  $I(x_i, y_i)$  é a intensidade do  $i$ -ésimo pixel de componentes  $[R_i, G_i, B_i]$ ;  $n$  é o número total de pixels contido no bitmap.

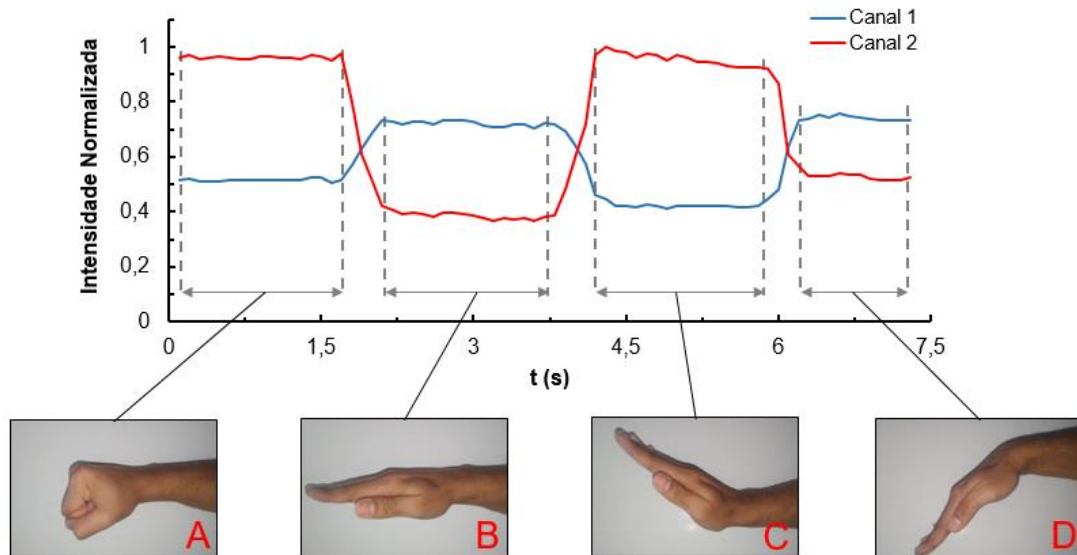
O aplicativo classifica os padrões no conjunto pré-fixado de posturas de acordo com os dados de intensidade amostrados. Primeiro, é calculado o resíduo normalizado para cada ponto em relação às posturas alvo,

$$R_i = \frac{|I_i - I_m|}{\sum |I_j - I_m|}, \quad (3)$$

onde  $R_i$  é o resíduo normalizado de um ponto amostrado  $I_m$  em relação ao  $i$ -ésimo padrão;  $I_j$  é o  $j$ -ésimo padrão. Em seguida, um algoritmo baseado em uma árvore de decisões [9] classifica os dados de acordo com o resíduo mínimo normalizado.

Medições de sinais FMG

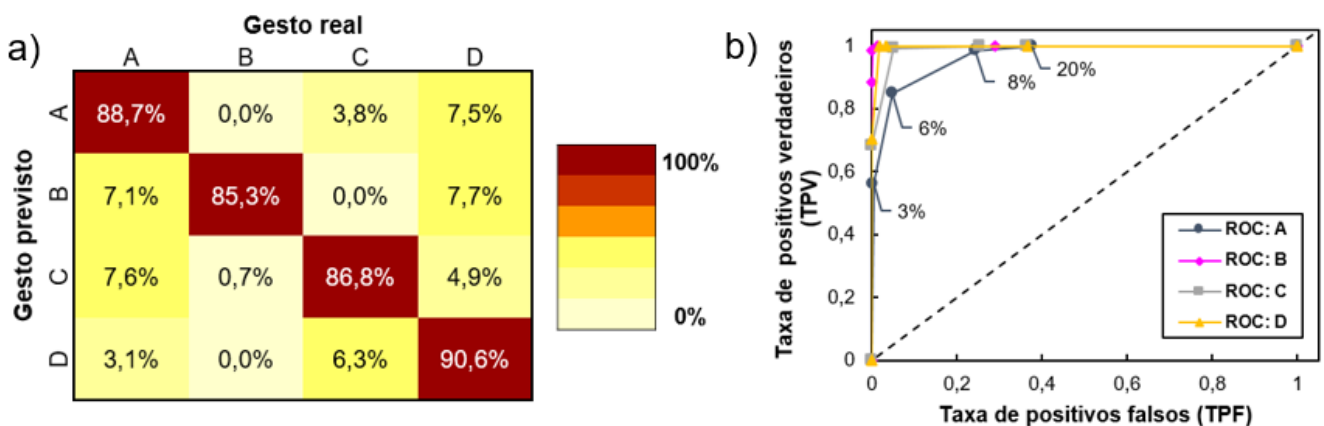
O sensor possui um espaço amostral de quatro padrões de classificação, podendo ter esse número expandido. Para um conjunto de posturas arbitrário, foi realizada a rotina de calibração, e os respectivos sinais de intensidade dos canais ópticos registrados são mostrados na Fig. 2. O usuário manteve cada postura por ~2 s, enquanto o sensor mediu os valores médios de intensidade e salvou os padrões referência A, B, C e D, respectivamente. Nota-se que cada postura apresenta um par característico  $[I_1, I_2]$ , indicando não existir ambiguidades aparentes entre os padrões. Além disso, é possível observar ainda boa estabilidade do sinal, com oscilações de inferiores a 1%. Embora os dados apresentados façam referência a uma medição específica, uma vez que os transdutores sejam fixados nas mesmas posições no antebraço e o setup opere devidamente calibrado, são esperados sinais com as mesmas características independentemente do usuário.



**Fig. 2.** Sinais de intensidade normalizada dos canais de fibra óptica ao longo do tempo. Posturas das mãos analisadas. A: mão fechada; B: mão espalmada; C: mão flexionada para cima; D: mão flexionada para baixo.

Classificação dos gestos

Para validação do sensor, seqüências aleatórias de movimentos foram realizadas a fim de se obter uma estimativa do desempenho do algoritmo de classificação. No total, foram realizados 40 movimentos em que as posturas foram mantidas por ~2 s, totalizando 500 medições de posturas (incluindo transições) com um período de amostragem  $\Delta t = 100$  ms. Em relação ao *threshold* de classificação, foi arbitrado um limite de intensidade de 8% para realizar o reconhecimento de padrões. Os resultados dos experimentos são apresentados através de uma matriz de confusão (Fig. 3a), onde é possível verificar uma taxa média de acerto de ~87%. Uma vez que o algoritmo não trata os dados de movimentos como casos excepcionais (mas como um padrão a ser classificado), grande parte dos erros ocorre durante as transições entre posturas. Desta forma, com um processamento intermediário do sinal, a taxa de acerto do classificador pode atingir valores próximos a 97%.



**Fig. 3.** a) Matriz de confusão em relação às taxas de acerto do classificador. b) Curvas ROC referentes às classificações de posturas para diferentes *thresholds* (indicados na curva ROC: A).

Além disso, para o conjunto de dados fornecido, as curvas características de operação do receptor (curvas ROC) [10] foram construídas para se observar a performance do classificador em relação ao limite de corte residual. Essas curvas são apresentadas na Fig. 3b. As curvas foram obtidas levando-se em consideração

os *threshold* de classificação de 3%, 6%, 8% e 20%, além dos valores extremos de 0% e 100%. Verifica-se que as curvas estão muito próximas do ideal (Área abaixo das curvas  $\sim 1$ ), demonstrando que o classificador possui um desempenho satisfatório. Os pontos intermediários referentes aos limites de 6% e 8% apresentam TPVs (taxa de positivos verdadeiros) próximas a 1 para TPFs (taxa de positivos falsos) abaixo de 0,5, confirmando que a escolha do limiar de classificação de 8% está adequada. Mais ainda, há também uma queda acentuada no TPV para o menor limite de corte de 3%, enquanto para o limite de 20% se obtém a maior taxa de positivos falsos, decorrente do intervalo de classificação muito amplo. Embora as curvas ROC tenham sido construídas independentemente para cada um dos padrões, a classificação das posturas ocorre em conjunto pelo algoritmo, de modo que o classificador apresenta um *threshold* geral ainda menor do que os observados quanto à classificação dos padrões isolados.

## Conclusões

Foi desenvolvido com sucesso um sensor de miografia de força de fibra óptica simples, de baixo custo e minimamente invasivo integrado a um smartphone para a classificação dos gestos da mão humana. O aparato experimental conta com um smartphone como elemento central de hardware, que funciona como fonte luminosa, receptor e unidade de processamento. Peças foram fabricadas em impressora 3D para realizar o acoplamento óptico das fibras e a modulação dos sinais por transdução de microcurvatura. Para aquisição, processamento e classificação dos dados, foi desenvolvida uma aplicação Android. Para teste e validação do sensor, um conjunto de medidas com um conjunto de postura pré-definidos foi realizado, resultando em uma taxa de acerto de  $\sim 87\%$ . Além disso, através da observação das curvas ROC do sistema, foi constatado que o classificador opera próximo à máxima eficiência com um *threshold* de 8%. Em trabalhos futuros o monitoramento dinâmico dos movimentos bem como a integração do sistema de detecção com atuadores serão abordados. Uma abordagem preliminar com máquinas de estados finitos (FSM – *Finite State Machines*) [11] foi testada para classificar sequências de movimentos e gerou resultados promissores. Portanto, apesar da abordagem generalista usada neste trabalho, as aplicações do sistema de sensoriamento desenvolvido são inúmeras e se estendem desde as áreas biomédicas ao controle avançado de dispositivos mecatrônicos.

## Referências bibliográficas

1. Dipietro, L.; Sabatini, A. M.; Dario, P. "A survey of glove-based systems and their applications." *IEEE Transactions on Systems, Man, and Cybernetics, Part C* 38.4 (2008): 461-482.
2. Chowdhury, R. H. *et al.* "Surface electromyography signal processing and classification techniques." *Sensors* 13.9 (2013): 12431-12466.
3. Craelius, W. "The bionic man: restoring mobility." *Science* 295.5557 (2002): 1018-1021.
4. Boechat, A. A. P. *et al.* "Bend loss in large core multimode optical fiber beam delivery systems." *Applied Optics* 30.3 (1991): 321-327.
5. Fujiwara, E; Suzuki, C. K. "Optical fiber force myography sensor for identification of hand postures." *Journal of Sensors* 2018 (2018): 8940373.
6. Aagaard, P. *et al.* "Isokinetic muscle strength and capacity for muscular knee joint stabilization in elite sailors." *International Journal of Sports Medicine* 18.07 (1997): 521-525.
7. Hayes, K. W.; Falconer, J. "Differential muscle strength decline in osteoarthritis of the knee. A developing hypothesis." *Arthritis & Rheumatism: Official Journal of the American College of Rheumatology* 5.1 (1992): 24-28.
8. Liu, Y. *et al.* "Surface plasmon resonance biosensor based on smart phone platforms." *Scientific Reports* 5.1 (2015): 1-9.
9. Safavian, S. R.; Landgrebe, D.. "A survey of decision tree classifier methodology." *IEEE Transactions on Systems, Man, and Cybernetics* 21.3 (1991): 660-674.
10. Fan, J.; Upadhye, S.; Worster, A. "Understanding receiver operating characteristic (ROC) curves." *Canadian Journal of Emergency Medicine* 8.1 (2006): 19-20.
11. Fajardo, J. *et al.* "A wearable robotic glove based on optical FMG driven controller," in: IEEE ICARM 2019, 2019, 81-84.