



Caracterização de gestos da mão humana através de um sensor de fibra óptica de miografia de força baseado em smartphone

Matheus S. Rodrigues* e Eric Fujiwara

Faculdade de Engenharia Mecânica, UNICAMP, São Paulo 13083-860, Brazil;
santos.r.math@gmail.com (M.R.); fujiwara@fem.unicamp.br (E.F.)

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 excita um par de fibras ópticas poliméricas e os sinais de saída são detectados pela câmera. A intensidade da luz é modulada por meio de transdutores mecânicos de microcurvatura acionados por força colocados no antebraço, e os sinais ópticos adquiridos são processados por um algoritmo baseado em árvores de decisão e erro residual. O sensor forneceu uma taxa de acerto de 87% em relação a quatro posturas, gerando desempenho confiável com uma configuração simples, portátil e de baixo custo embarcado em um smartphone.

Palavras-chave: sensor de fibra óptica; miografia de força; smartphone

1. Introdução

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

A miografia de força (FMG) foi proposta como contrapartida mecânica à eletromiografia de superfície (sEMG). Na FMG, os estímulos musculares são detectados na forma de pressões radiais, possibilitando a identificação de movimentos sem a utilização de um número exagerado de canais ou pré-processamento de sinais intensivos [3]. As pressões radiais dos músculos do antebraço geram sinais ópticos modulados, uma vez que a micro curvatura das fibras ópticas causa perda da intensidade da luz transmitida [4].

Utilizando tal fenômeno, um sensor óptico de miografia de força de bancada foi proposto para a caracterização dos movimentos da mão humana. Em trabalhos anteriores, foi desenvolvido um sistema FMG de fibra óptica, permitindo a identificação de até 11 posturas com uma precisão de 99,7% [5]. O presente estudo, entretanto, teve como objetivo desenvolver um sistema baseado em uma plataforma mais acessível e com uma abordagem de processamento simplificada: um smartphone. Com muitas funções emergentes, como aquisição de imagem; fonte de luz; processamento local; comunicação sem fio; e assim por diante, o smartphone é considerado um hardware altamente versátil e promissor para detecção que apresenta uma tendência crescente na utilização [6-8].

Neste trabalho, um sensor de miografia de força de fibra óptica embutido em um aparelho smartphone é proposto para caracterizar os gestos das mãos humanas. Um aplicativo móvel para aquisição, processamento e classificação do sinal óptico foi desenvolvido e testado para avaliar sua sensibilidade e resposta temporal. Posteriormente, foram realizados experimentos com quatro diferentes posturas das mãos e sua classificação foi realizada por um algoritmo baseado em uma árvore de decisão. Por fim, as taxas de acerto do classificador foram quantificadas e suas curvas características de operação (curva ROC) foram investigadas para avaliar o desempenho do sensor.

2. Materiais e Métodos

2.1. Setup Experimental

O setup experimental, Figura 1, consiste em um LED branco que excita um par de fibras ópticas de poliméricas (PMMA) multimodo. Os guias de onda são fixados ao antebraço do usuário por transdutores de microcurvatura acionados por força. As seções finais das fibras são posicionadas perpendicularmente ao receptor, e a câmera CCD do smartphone captura frames de imagem da luz de saída. Uma vez que a fonte de luz e a câmera fazem parte do smartphone, o acoplamento óptico é feito através de uma case fabricada para o dispositivo em impressora 3D. O hardware no qual o sistema foi integrado é um celular Android com sistema operacional versão 8.1. Ele contém um chipset Snapdragon 660 Qualcomm SDM660, 4 GB de RAM e uma câmera de 12 Mp que é usada para a aquisição de frames em uma resolução de 1280×720 .




Figura 1. Visão geral do sistema de sensoriamento: LED (lanterna); MMF: fibras ópticas multimodo de PMMA; CCD: câmera do dispositivo.

Para determinar posturas e movimentos em um conjunto predefinido de padrões, uma calibração inicial deve ser realizada para cada usuário. Esses ajustes são indispensáveis devido às singularidades intrínsecas entre os sujeitos. Um movimento pode exigir um grau de flexão diferente para cada pessoa, por exemplo, produzindo variações de intensidade de luz para um mesmo movimento [9,10]. Conforme mostrado na Figura 1, os dois transdutores de microcurvatura [6] são colocados nos músculos extensores do antebraço e fixados com tiras de velcro, aplicando uma pré-carga moderada e evitando o desconforto do usuário. Além disso, o posicionamento dos transdutores é realizado pela palpação dos músculos, visando maximizar a sensibilidade em relação aos movimentos testados. Os experimentos foram realizados de acordo com as recomendações do Comitê de Ética (CAAE 17283319.7.0000.5405).

2.2. Aplicativo mobile e reconhecimento dos padrões

O software para aquisição e processamento de dados foi desenvolvido no Android API 27, que é compatível com as versões 8.1 e superiores. Além disso, apenas bibliotecas padrão do Java e Android foram usadas para evitar erros de compatibilidade e processamento excessivo pelo dispositivo. Embora existam muitas bibliotecas de processamento de imagens disponíveis, como o OpenCV, para a abordagem utilizada neste trabalho as bibliotecas padrão tiveram um bom desempenho. Assim, o aplicativo possui uma interface intuitiva e de processamento rápido, cujas principais funcionalidades podem performar de forma satisfatória em qualquer smartphone comum. Assim que a *activity* principal é iniciada, é iniciada o *preview* da câmera, mostrando os frames capturados pelo CCD. O processamento dos dados da aplicação é feito em tempo real, sendo que o usuário pode selecionar a resolução da janela, período de amostragem de quadros, bem como o foco da câmera na interface (parâmetros que podem gerar grande variabilidade nas medidas quando não normalizados). Esses ajustes devem ser realizados antes de iniciar uma medição, mas podem ser modificados durante o experimento. Além disso, o aplicativo também possui um modo de calibração que realiza a rotina de gravação dos padrões de postura.

Os frames são capturados em formato bitmap com um intervalo de amostragem T (ms); então, as janelas referentes às duas seções de canais ópticos são destacadas e esses sub-bitmaps são 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 de pixel contido no bitmap. Assim, na base decimal, $R, G, B \in [0, 255]$, então os valores de intensidade podem variar de 0 (preto) à 441 (branco).

O aplicativo deve ser capaz de classificar padrões no conjunto pré-fixado de posturas de acordo com os dados de intensidade amostrados. Para realizar esta tarefa, vários algoritmos poderiam ser usados, por exemplo, redes neurais artificiais que já foram utilizadas em trabalhos anteriores [11]. No entanto, um método de classificação complexo esbarra nas limitações de hardware e processamento do smartphone. Assim, uma abordagem simplificada com base no resíduo amostral normalizada é proposta: ela consiste em calcular o resíduo para cada ponto amostrado para as posturas calibradas e normalizá-lo pelo resíduo total,

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

onde R_i é o resíduo normalizado de um ponto adquirido I_m para o i -ésimo padrão; I_j é o j -ésimo padrão. Essencialmente, a técnica é baseada em uma árvore de decisão, onde as decisões são feitas com base no resíduo mínimo normalizado. Tais classificadores são usados de forma satisfatória em diversas áreas [12], pois possuem a capacidade de transformar um processo de decisão complexo em vários subprocessos de decisão simplificados, gerando uma solução mais simples de interpretar e modelar. Porém, para a metodologia adotada neste trabalho, não foi necessária uma árvore extensa, de forma que: o nível 0 é a raiz e o nível 1 são as posturas alvo da classificação. Isso torna o classificador muito rápido, conforme exigido pelo hardware. No entanto, tal técnica permite que, enquanto novas posturas são adicionadas e o sensor é usado para outras aplicações, níveis de árvore subsequentes podem ser adicionados para um maior refinamento do classificador.

3. Resultados e Discussões

3.1. Medições de sinais FMG

Primeiro, para verificar a sensibilidade do sensor aos estímulos mecânicos e garantir que a resposta do sinal ocorra à uma taxa satisfatória, foi realizado um experimento com um micrômetro em que o instrumento foi colocado em contato com o transdutor de microcurvatura e então variado em 0,5 mm de modo a gerar uma compressão, e em seguida o instrumento foi variado até o estado inicial, na ausência de tensões. Nota-se pela Figura 2 que tanto o estímulo de compressão (cinza) quanto o de folga (vermelho) conduziram à mesma resposta linear de $|\Delta I/\Delta y| \approx 46 \text{ mm}^{-1}$. Demonstrando não ocorrer nenhuma deformação plástica do material ou histerese perceptível, mesmo para estímulos de alta amplitude, apresentando boa reprodutibilidade.

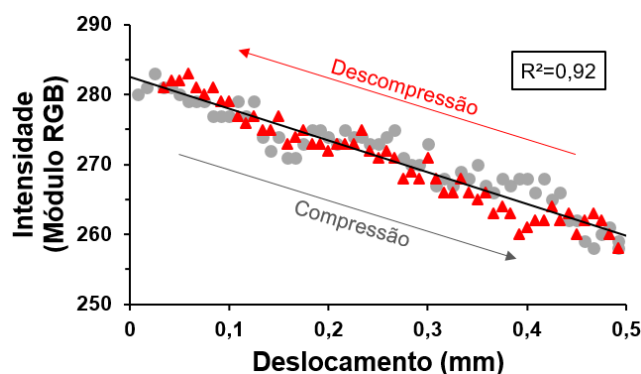


Figura 2. Resposta óptica a um deslocamento linear realizado por um micrômetro acoplado ao transdutor mecânico.

O sensor compreende um espaço amostral de 4 possíveis padrões de classificação, assim um conjunto de posturas e os respectivos sinais de intensidade registrados na rotina de calibração para uma determinada medição são mostrados na Figura 3. O usuário manteve cada postura por $\sim 2s$, enquanto o sensor mediu os sinais médios e salvou os padrões A, B, C e D, respectivamente. Percebe-se que cada postura apresenta um par característico [11, 12], confirmando não

haver ambiguidades aparentes entre os padrões. Além disso, no presente experimento, foi possível observar boa estabilidade do sinal, com variações de <1%. Embora os dados apresentados façam referência a uma medição específica, uma vez que os transdutores são posicionados nos mesmos músculos do antebraço e o setup opera com a mesma calibração, são esperados sinais com as mesmas características para diferentes usuários.

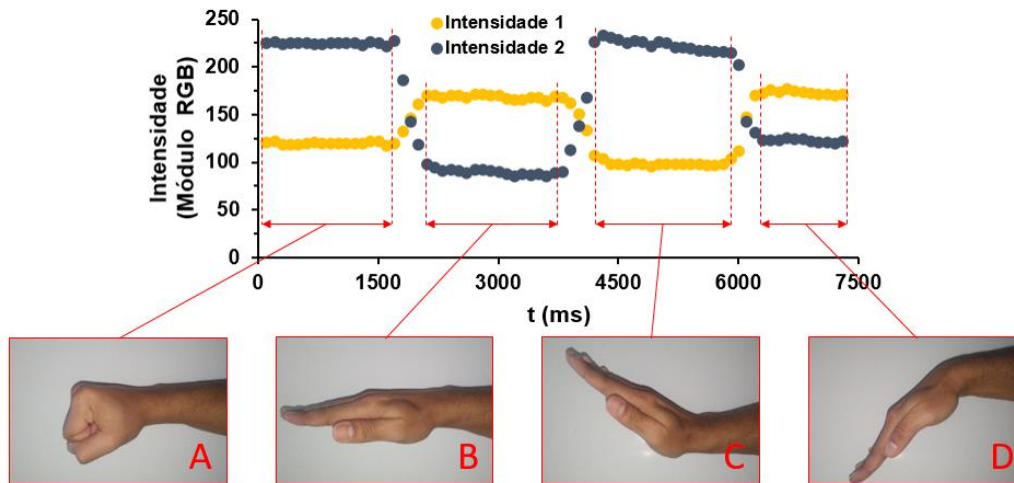


Figura 3. Sinais de intensidade de luz dos canais de fibra óptica ao longo do tempo. Posturas das mãos analisadas. A: mão fechada; B: mão espalmada; C: mão flexionada para cima; D: mão flexionada para baixo.

3.2. Classificação dos gestos

O objetivo principal do trabalho era produzir um sensor confiável com uma taxa de acerto aceitável. Assim, seqüências aleatórias de movimentos foram realizadas para obter uma estimativa do desempenho do classificador. No total, foram realizados 40 movimentos em que as posturas foram mantidas por aproximadamente 2 segundos, totalizando 500 medidas (incluindo transições posturais) com um período de amostragem de 100 ms. Em relação ao *threshold* de classificação, foi arbitrado um limite de corte de intensidade de 8% para realizar o reconhecimento de padrões. Os resultados dos experimentos são mostrados na Figura 4a, onde é possível verificar uma taxa média de acerto de ~ 87%. Uma vez que a classificação não trata os dados de movimentos como casos excepcionais (mas como pontos de postura comuns), a maior parte dos erros é percebida durante as transições. Portanto, com um tratamento intermediário do sinal, a taxa de acerto do classificador pode atingir valores próximos a 97%.

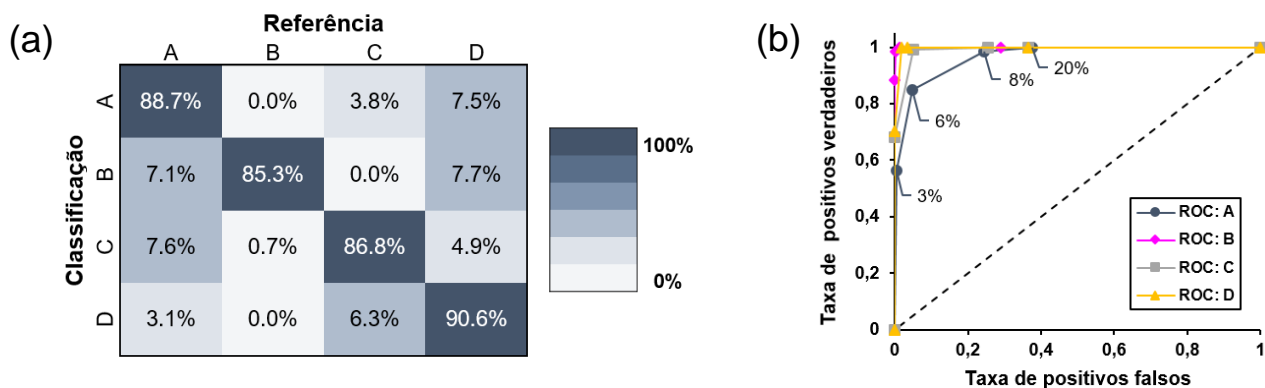


Figura 4. (a) Matriz de confusão em relação às taxas de acerto do classificador. (b) Curvas ROC referentes às classificações de posturas para diferentes *thresholds* (indicados na curva ROC: A).

Além disso, para o conjunto de dados fornecido, as curvas características de operação do receptor (curvas ROC) foram estabelecidas para observar o desempenho do classificador em relação ao limite de corte residual. Esses resultados são mostrados na Figura 4b. As curvas foram obtidas levando-se em consideração os desvios de classificação de 3%, 6%, 8% e 20%, além dos valores extremos de 0% e 100%. Verifica-se que as curvas estão extremamente próximas do ideal (área abaixo da curva próxima a 1), indicando que o classificador tem um desempenho satisfatório. Além disso, 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. Além disso, 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 uma das posturas, a classificação dos padrões ocorre em conjunto na árvore de decisões, de forma que o classificador geral apresenta um *threshold* ainda menor do que o verificado para os padrões isolados.

4. Conclusão

Foi desenvolvido com sucesso um sensor de miografia de força de fibra óptica compacto, versátil e simples baseado em um smartphone para a classificação dos gestos da mão humana. Uma case impressa em 3D foi fabricada para realizar o acoplamento óptico e fornecer condições estáveis para aquisição de dados e minimização de ruído. Para aquisição e processamento dos dados, foi desenvolvido um aplicativo Android para mensurar e classificar os dados. Em seguida, um conjunto de medidas com padrões de postura pré-definidos foi realizado para testar e validar o sensor desenvolvido, resultando em uma taxa de acerto de ~ 87% para identificar quatro posturas de mão. Em estudos futuros, a reconstrução completa dos movimentos e a integração do sistema de detecção com atuadores serão abordadas. Uma abordagem com máquinas de estados finitos [13] foi testada para monitorar sequências de movimentos e gerou resultados promissores. Portanto, apesar da abordagem generalista usada neste trabalho, as aplicações do sensor desenvolvido são numerosas e se estendem desde a assistência em sessões de fisioterapia ao controle avançado de dispositivos mecatrônicos.

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

Referências

1. Dipietro, L.; et al. A survey of glove-based systems and their applications, *IEEE Trans. Syst. Man Cy* **2008**, C 38, pp. 461–482.
2. Chowdhury, R. H.; et al. Surface electromyography signal processing and classification techniques. *Sensors* **2013**, vol 13, pp. 12431–12466.
3. Craelius, W. The bionic man: restoring mobility. *Science* **2002**, vol 295, pp. 1018–1021.
4. Alvaro, A. P.; et. al. Bend loss in large core multimode optical fiber beam delivery systems. *Appl. Opt.* **1991**, vol. 30, pp. 321-327.
5. Fujiwara, E.; Suzuki, C. K. Optical fiber force myography sensor for identification of hand postures. *Journal of Sensors* **2018**, vol 2018, 8940373.
6. Liu, Y.; et al. Surface plasmon resonance biosensor based on smart phone platforms. *Scientific Reports* **2015**, vol 5, 12864.
7. Sun, A.; et al. A multi-technique reconfigurable electrochemical biosensor: enabling personal health monitoring in mobile devices. *IEEE Trans. Biomed. Circ. Sys.* **2016**, vol 10, pp. 945–954.
8. Kong, Q.; et al. Structural health monitoring of buildings using smartphone sensors. *SeismolRes Lett.* **2018**, vol 89(2A), pp. 594-602.
9. Aagaard, P., et. al. Sokinetic muscle strength and capacity for muscular knee joint stabilization in elite sailors. *International Journal of Sports Medicine* **1997**, vol. 18, p. 521–525.
10. Hayes, K.W. e Falconer, J. Differential muscle strength decline in osteoarthritis of the knee: A developing hypothesis. *Arthritis Care Research* **1992**, vol. 5, pp. 24–28.
11. Wu, Y. T. et al., 2020. Integrated Optical Fiber Force Myography Sensor as Pervasive Predictor of Hand Postures. *Biomedical Engineering and Computational Biology* **2020**.
12. Safavian, S. R.; Landgrebe, D. A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics* **1991**, vol. 21, no. 3, pp. 660-674.
13. Brown, S. and Vranesic, Z. *Fundamentals of Digital Logic with Verilog Design*, 2nd ed. Mc Graw Hill: New York, USA, 2003; pp. 447-463.