

Aplicação da Análise Discriminante Linear (LDA) para Classificação de Sinais Eletromiográficos (EMG) de Movimentos da Mão

Ana Cláudia Barbosa Rezende¹, Gilberto Lopes Filho¹, Flávio Henrique Teles Vieira¹

¹ Escola de Engenharia Elétrica, Mecânica e de Computação
Universidade Federal de Goiás (UFG)
Av. Universitária, nº. 1488 – Goiânia – GO – Brasil

cana@ufg.br, gilberto.lopes@ufg.com, flavio_vieira@ufg.br

Abstract. *Electromyography (EMG) provides valuable information about muscle activity and morphology. Classification and pattern recognition of EMG signals are important steps in detecting abnormalities, muscle performance analysis and prosthesis control. Linear discriminant analysis (LDA) is a statistical method used for separating two or more object classes. A method based on LDA, preprocessing the input data and applying the voting technique (Fashion) of the outputs to perform EMG signal classification of an individual's hand movements is proposed. The proposed method presented a hit rate of up to 97.85 % in the test step of the samples, pointing out the potential and efficiency of the ADL in the signal classification.*

Resumo. *A eletromiografia (EMG) fornece informações valiosas acerca da atividade e morfologia muscular. A classificação e reconhecimento de padrões dos sinais EMG são passos importantes na detecção de anormalidades, análise de desempenho muscular e controle de prótese. A análise discriminante linear (LDA) é um método estatístico usado para separação de duas ou mais classes de objetos. Propõe-se um método baseado em LDA, pré-processamento dos dados de entrada e aplicação de técnica de votação (Moda) das saídas para realizar classificação de sinais EMG de movimentos da mão de um indivíduo. O método proposto apresentou taxa de acerto de até 97,85% na fase de teste das amostras, apontando o potencial e eficiência do LDA na classificação dos sinais.*

1. Introdução

A eletromiografia (EMG), o estudo dos sinais elétricos gerados em um músculo durante sua contração, fornece dados que descrevem tanto a atividade neuromuscular, bem como a morfologia muscular [Raez 2006].

Nos últimos vinte anos, a eletromiografia foi amplamente utilizada por pesquisadores e médicos como uma ferramenta valiosa para diagnóstico preciso de doenças neuromusculares [Basmajian and De Luca 1985]. Distúrbio neuromuscular é um termo geral que abrange as patologias que afetam qualquer parte do nervo ou músculo, incluindo os motoneurônios, junções neuromusculares e tecidos musculares.

O reconhecimento de padrões e a caracterização precisa e acurada dos sinais eletromiográficos são passos importantes no diagnóstico correto das doenças neuromusculares. Para isso, os sinais adquiridos devem ser analisados, decompostos e classificados. Alguns dos métodos de classificação de sinais incluem técnicas de aprendizado de máquina, como redes neurais artificiais, sistemas difusos (*fuzzy*) e modelagens probabilísticas (classificadores bayesianos, análise linear discriminante (LDA ou *Linear Discriminant Analysis*), algoritmo K vizinhos mais próximos (KNN ou *KNearest Neighbors*) [Yousefi and Hamilton-Wright 2014].

A análise linear discriminante é uma técnica usada em estatística e aprendizado de máquina para encontrar a combinação linear de características. Essas características separam duas ou mais classes de objeto. O LDA funciona quando as medições feitas em cada observação são quantidades contínuas [Kotsiantis et al. 2007].

Portanto, propõe-se neste trabalho o pré-processamento de sinais EMG mediante cálculo da raiz do valor quadrático médio (RMS ou *Root Mean Square*), e doravante a classificação destes sinais por meio do LDA. As amostras foram coletadas no antebraço de um indivíduo durante a realização de movimentos específicos com os dedos das mãos. Os ensaios foram realizados para 2 classes de movimentos, a primeira classe incluiu pressão com o dedo polegar, enquanto a segunda incluiu pressão simultânea com os dedos indicador e médio em um volante.

2. Trabalhos Relacionados

Nos últimos anos, os pesquisadores estudaram a diferenciação entre movimentos de punho e mão usando uma variedade de abordagens de aquisição e classificação de EMG. Esses estudos utilizam uma variedade de técnicas de reconhecimento de padrões para avaliar características de sinais EMG e discriminar classes distintas de movimentos [Shenoy et al. 2008] [Phinyomark et al. 2012a].

O trabalho de [Zhang et al. 2012] utiliza quatro sensores *MyoScan* colocados sobre os músculos do antebraço para a aquisição de sinais EMG para classificar quatro movimentos de mão. Empregou-se a combinação de recursos no domínio de tempo e frequência em conjunto com a análise de componentes principais (PCA ou *Principal Component Analysis*) e LDA para projeção e classificação dos sinais EMG.

O estudo de [Too et al. 2017] avaliou o desempenho no domínio do tempo (TD) e domínio de frequência (FD) das características do sinal para discriminação de classes do EMG. A performance das características no domínio do tempo e frequência, foi avaliada pela análise discriminante linear (LDA). As características no domínio da frequência alcançaram a maior precisão, 91,34% no classificador LDA. Os resultados foram verificados pelo classificador e as características no domínio da frequência apresentaram melhor desempenho na classificação de sinal EMG.

[Raurale et al. 2018] apresentou um sistema em tempo real para aquisição e classificação de sinais eletromiográficos (EMG). A primeira abordagem a permitir a classificação de poses de mãos a partir de sinais EMG, estruturado em multicanais captados a partir de sensores alocados aleatoriamente no braço. O sistema combinou extração de recursos no domínio do tempo, análise discriminante linear (LDA), projeção de características e perceptron multicamadas (MLP). A classificação permitiu que nove poses distintas fossem corretamente identificadas em mais de 95% das tentativas.

3. Análise Discriminante Linear (LDA)

O LDA é uma generalização do discriminante linear de Fisher, um método usado em estatística, reconhecimento de padrões e aprendizado de máquina para encontrar uma combinação linear de características que caracterizam ou separam duas ou mais classes de objetos ou eventos. A combinação resultante pode ser usada como um classificador linear ou, mais comumente, para redução de dimensionalidade antes da classificação posterior.

A idéia básica do LDA é que as amostras sejam projetadas em um espaço vetorial discriminante ideal para obter o melhor efeito possível de extração de informações de classificação e compactação de dimensão das características. Deseja-se que as amostras tenham a maior distância entre classes e a menor distância dentro da classe, ou seja, maximização da separação entre duas ou mais classes.

Dadas amostradas de duas classes C_1 e C_2 , queremos encontrar a direção, definida por um vetor w , de modo que quando os dados, x , são projetados em w , os exemplos das duas classes sejam separados o máximo possível. A projeção de x na direção de w é dada pela Eq. 1 [Alpaydin 2010]:

$$z = w^T x \quad (1)$$

A Eq. 2 define a matriz inter-classe (S_b), enquanto as Eqs. 3 e 4 definem as matrizes intra-classe para cada uma das classes (S_1 e S_2).

$$S_b = (m_1 - m_2)(m_1 - m_2)^T \quad (2)$$

$$S_1 = \sum_{t=1}^N r^t (x^t - m_1)(x^t - m_1)^T \quad (3)$$

$$S_2 = \sum_{t=1}^N (1 - r^t)(x^t - m_2)(x^t - m_2)^T \quad (4)$$

em que x^t representa as amostras das classes, m_1 é a média das amostras da classe C_1 , m_2 é a média das amostras da classe C_2 , N o número total de amostras, respectivamente. r^t é um fator de classificação das amostras, em que $r^t = 1$ caso $x^t \in C_1$ e $r^t = 0$ caso $x^t \in C_2$.

A matriz intra-classe total é calculada segundo a Eq. 5:

$$S_w = S_1 + S_2 \quad (5)$$

Assim, o vetor w pode ser encontrado conforme apresenta a Eq. 6:

$$w = cS_w^{-1}(m_1 - m_2) \quad (6)$$

em que c é uma constante. Todavia, como o mais importante é a direção e não a magnitude de w , assume-se $c = 1$.

4. Sinal Eletromiográfico (EMG)

O sinal eletromiográfico (EMG) fornece informações importantes sobre o desempenho dos músculos e nervos. Os sinais EMG registrados a partir da superfície da pele foram amplamente utilizados em diferentes campos, tais como controle de prótese, análise de estimulação elétrica funcional, interação homem-máquina, tremor patológico e análise de fadiga muscular [Shenoy et al. 2008] [Dideriksen et al. 2011].

As ferramentas para análise e extração de características do sinal EMG podem ser divididas em três grupos principais, análise no domínio do tempo, no domínio de frequência ou representação em tempo-frequência [Phinyomark et al. 2012b]. O processamento das características do sinal no domínio do tempo geralmente é feito rapidamente, já que não é necessário aplicar nenhuma transformada. Algumas das ferramentas de análise do sinal no domínio do tempo incluem a retificação, envoltória linear, RMS e integração.

1. Retificação: Consiste em tomar o valor absoluto do sinal EMG, ou seja, rebater as fases negativas (*full-wave*), ou remover os valores negativos do sinal bruto (*half full-wave*).
2. Envoltório Linear: O sinal retificado pode ser alisado por um filtro passa-baixa para suprimir flutuações de alta frequência, permitindo uma avaliação clara da amplitude do sinal EMG (envoltório linear). Funciona como um tipo de média móvel que indica a magnitude do sinal. A exata seleção das frequências de corte depende de sua aplicação, embora existam recomendações entre 3 a 50 Hz [Robertson et al. 2013].
3. RMS : Este método de processamento não requer retificação, pois a amplitude do sinal EMG é elevada ao quadrado. Associar a técnica de RMS a um intervalo de tempo determinado, constitui o RMS móvel, utilizado para observar as alterações do sinal EMG em função do tempo. Para se criar um RMS móvel, a janela no tempo é movida ao longo do sinal adquirido e o RMS é calculado. Esta janela pode ser sobreposta ou não. A sobreposição permite uma grande continuidade do sinal EMG. A janela típica para o RMS móvel é de 100 a 200 *ms*, que se correlaciona com o tempo de resposta muscular [De Luca 1997].
4. Integração : O sinal EMG integrado (IEMG) é definido como a área sob a curva do sinal EMG retificado, isto é, a integral matemática do valor absoluto do sinal EMG bruto. Quando o valor absoluto do sinal é obtido, o ruído fará com que a integral matemática tenha um aumento constante. O IEMG não discrimina ruído ou sinal EMG [Robertson et al. 2013].

Neste trabalho é empregado o cálculo do valor RMS do sinal, e posteriormente, utilizado o algoritmo LDA como classificador. Para o cálculo dos valores RMS, utiliza-se uma janela de 30 dados, com passos de 10 em 10 dados. Ou seja, 20 dados vão se repetir para cada janela. A Eq. 7 apresenta como calcular o valor RMS do sinal.

$$RMS = \sqrt{\frac{1}{T} \int_0^T x^2(t) dt} \quad (7)$$

em que $x(t)$ é a função que descreve o sinal e T o período.

A Figura 1 apresenta um exemplo genérico da técnica de janelamento, para o cálculo de um valor RMS. O vetor de entrada u possui 6 elementos, e o tamanho da janela é 3. Na primeira iteração, o cálculo da saída y_1 é por meio dos valores RMS entre 0, 0 e u_1 . Na segunda iteração, a janela se desloca, e a saída y_2 é o valor RMS de 0, u_1 e u_2 . E isso se repete até que sejam percorridos todos os dados do vetor de entrada, formando o vetor de saída y , que no caso desse trabalho, são os valores RMS dos dados de entrada.

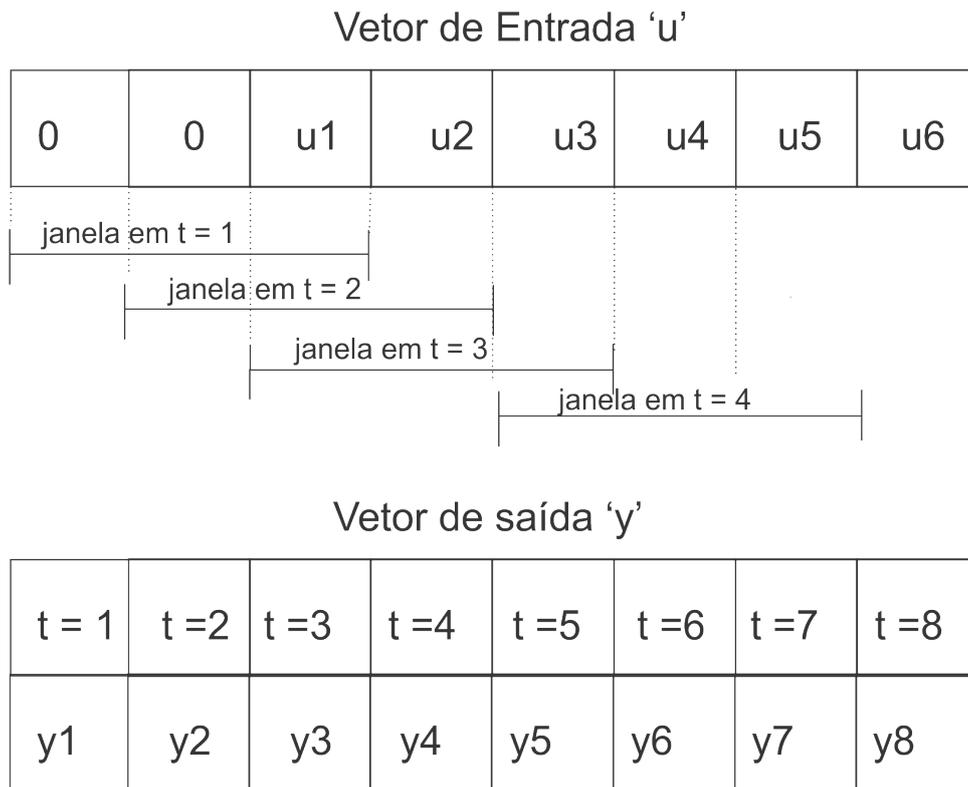


Figura 1. Janelamento dos dados de entrada para o cálculo dos valores RMS.

5. Metodologia

A base de dados utilizada contém medições de sinais EMG do antebraço de um indivíduo sem distúrbios neurológicos ou musculares [Khushaba et al. 2013]. No total, 8 eletrodos EMG foram posicionados através da circunferência do antebraço humano, um eletrodo adicional de referência foi alocado no pulso durante a coleta. Foram realizadas 2 classes de combinações de pressão com os dedos em um volante. Essas classes incluíam aplicar pressão com o dedo polegar e aplicar pressão com os dedos indicador e médio simultaneamente. O participante foi solicitado a realizar cada uma das duas classes de movimento descritas anteriormente 4 vezes, e manter a pressão com os dedos por um período de 5 segundos em cada tentativa.

A Figura 2 ilustra as classes de combinações de pressão com os dedos utilizadas para serem classificadas pelo algoritmo LDA nas fases de treinamento e validação. A classe 1 (C_1) se refere aos sinais EMG coletados pelo movimento de pressão com o dedo polegar, enquanto a classe 2 (C_2) se refere aos sinais coletados dos movimentos de pressão dos dedos indicador e médio.

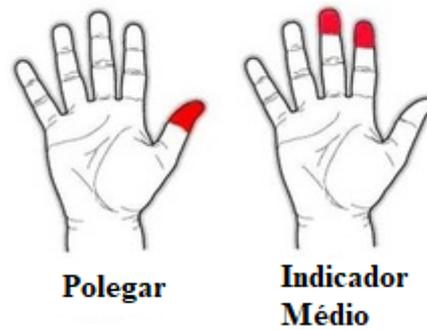


Figura 2. Classes de combinações de pressão com os dedos em um volante.
Fonte: Adaptado de [Khushaba et al. 2013]

As leituras dos 8 sensores para cada classe foram agrupados conforme apresenta a matriz C_i ($1 \leq i \leq 2$) em (8). Para as amostras de cada um dos 8 sensores S , são realizadas 4 ensaios, definidos como observações. As classes C_1 e C_2 tem o seguinte formato:

$$C_i = \begin{bmatrix} S_{1,1} & S_{1,2} & S_{1,3} & S_{1,4} \\ S_{2,1} & S_{2,2} & S_{2,3} & S_{2,4} \\ \vdots & \vdots & \vdots & \vdots \\ S_{7,1} & S_{7,2} & S_{7,3} & S_{7,4} \\ S_{8,1} & S_{8,2} & S_{8,3} & S_{8,4} \end{bmatrix} \quad (8)$$

Os elementos $S_{n,o}$ constituem as matrizes C_1 e C_2 , em que as colunas o correspondem a quantidade de observações realizadas, enquanto as linhas n correspondem as informações de cada um dos 8 sensores. Dessa forma, o elemento $S_{1,1}$ corresponde à primeira observação de amostras do sensor 1, enquanto o elemento $S_{7,3}$ corresponde à terceira observação de amostras do sensor número 7, por exemplo.

Neste primeiro cenário, para cada sensor S_i , onde $1 \leq i \leq 8$, têm-se uma resposta do LDA diferente. Ou seja, o LDA classifica os dados de acordo com 8 sensores, tendo 8 respostas (podendo ser iguais ou diferentes).

As amostras de cada sensor estão organizadas da seguinte forma:

$$S_t = \begin{bmatrix} s_1 \\ s_2 \\ s_3 \\ s_4 \\ s_5 \\ \vdots \\ s_t \end{bmatrix} \quad (9)$$

onde t é o comprimento do vetor de amostras, cada sensor possui $t = 2000$ amostras por observação.

Foram utilizadas 2 observações para o treinamento e duas observações para validação, de tal forma que o conjunto de treinamento é formado pela i -ésima classe e pelo n -ésimo sensor, desse modo:

$$\mathbf{Treinamento}_i = [\mathbf{S}_{n,1} \quad \mathbf{S}_{n,2}] \quad (10)$$

$$\mathbf{Valida}_i = [\mathbf{S}_{n,3} \quad \mathbf{S}_{n,4}] \quad (11)$$

Por meio do conjunto de treinamento são calculadas as matrizes de inter-classe e intra-classe, conforme as Eq. 2 e 5. Na etapa de validação, utiliza-se as matrizes calculadas com os conjuntos de treinamento, e aplicam-se os dados do conjunto de teste para se realizar a classificação de classes. As entradas X do algoritmo LDA ficam do seguinte modo:

$$\mathbf{X}_{treina} = \begin{bmatrix} \mathbf{Treinamento}_1 \\ \mathbf{Treinamento}_2 \end{bmatrix} \quad (12)$$

$$\mathbf{X}_{valida} = \begin{bmatrix} \mathbf{Valida}_1 \\ \mathbf{Valida}_2 \end{bmatrix} \quad (13)$$

Conforme mostrado, cada sensor provê uma classificação para um conjunto de dados. Ou seja, é possível que haja resultados de classificação distintos. Porém, é provável que para cada dado de entrada, a classificação correta fornecida por cada um dos 8 sensores apareça mais de uma vez. Dessa forma, é possível formar o vetor D , onde os elementos d_i apresentam a resposta de cada um dos sensores.

$$D = [d_1 \quad d_2 \quad d_3 \quad d_4 \quad d_5 \quad d_6 \quad d_7 \quad d_8] \quad (14)$$

Assume-se que a resposta, provida por cada sensor, que aparece com mais frequência é a classificação correta (Moda amostral). Por exemplo, para um certo conjunto de dados, caso hajam 6 sensores indicando que estes dados pertençam a classe 1, e 2 sensores indicando que pertençam a classe 2, assume-se que estes dados sejam da classe 1.

6. Resultados

A Tabela 1 apresenta um resumo das características gerais e parâmetros utilizados no estudo. Tais como o tipo de sinal, método utilizado no pré-processamento dos dados, algoritmo de classificação empregado, dentre outras informações.

Tabela 1. Resumo das características e parâmetros utilizados neste trabalho.

Tipo do sinal	EMG
Pré-processamento dos dados	Cálculo do valor RMS
Tamanho da janela do RMS	30
Algoritmo de Classificação	LDA
Números de sensores	8
Número de classes	2
Número de amostras por sensor	2000
Número de observações	4
Frequência de amostragem do sinal	4kHz

A Tabela 2 apresenta as taxas de acerto nas etapas de treinamento e validação, separadas por sensor.

Tabela 2. Resumo dos resultados individuais de cada sensor para classificação das duas classes.

Sensor	Taxa de acerto (%)	
	Treinamento	Validação
1	79,77	79,57
2	90,67	95,67
3	94,85	96,60
4	93,20	95,67
5	79,87	96,35
6	62,25	83,37
7	61,12	70,97
8	69,25	71,65

Os índices de acerto variam de 61,12% a 94,85% na etapa de treinamento, e de 70,97% a 96,60% na fase de validação. O sensor 3 é o que apresentou as taxas de acerto mais altas na classificação das amostras, tanto na etapa de treinamento quanto na de validação.

A Tabela 3 apresenta os resultados das taxas de acerto para diferentes combinações de sensores na etapa de validação.

Tabela 3. Taxas de acertos combinando as respostas dos sensores na etapa de validação.

Sensor	Taxa de acerto (%)
1 a 4	97,60
1 a 5	96,40
1 a 6	97,25
1 a 7	94,27
1 a 8	95,80
3 e 4	97,85

As maiores taxas de acerto foram obtidas para a combinação das características dos sensores 1 a 4 e 3 e 4, conforme a Tabela 3. Os sensores 3 e 4 apresentaram o maior índice de acerto, alcançando uma taxa de 97,85% na fase de teste. A classificação correta foi obtida como sendo a resposta resultante mais frequente dos 8 sensores (Moda).

A escolha adequada dos sensores, da quantidade de sensores e das características do sinal, apontaram ser um fator importante na classificação realizada pelo LDA.

7. Conclusões

A classificação de sinais EMG utilizando o LDA apresentou taxas elevadas de acerto nas fases de treinamento e validação. A análise individual dos sensores apontou melhores resultados de classificação na fase de validação para os sensores 3 e 5, com índices de acerto de 96,60% e 96,35% respectivamente. A combinação das respostas dos sensores resultou em um aumento nos índices de acerto do método de classificação. Os resultados apresentaram taxa de acerto de 97,85% na classificação para a combinação das informações dos sensores 3 e 4.

O método LDA carece de um pré-processamento e seleção das melhores características a serem empregadas na classificação. Isto pôde ser visto durante a análise individual e combinada das informações dos sensores. A escolha de qual ou quais sensores a serem utilizados na classificação, demonstrou ser um fator importante no processo. A combinação das respostas dos sensores pode maximizar ou minimizar as taxas de acerto do LDA.

Como trabalhos futuros, pretende-se aumentar o número de classes no processo de classificação utilizando o LDA (alcançando índices elevados de acerto na multi-classificação).

Testar diferentes métodos de seleção de características durante o pré-processamento dos sinais, como técnicas de filtragem e o PCA, buscando o aprimoramento do modelo de classificação utilizado.

Explorar e comparar o desempenho de outras técnicas como a análise discriminante regularizada (RDA ou *Regularized Discriminant Analysis*) e a análise discriminante quadrática (QDA ou *Quadratic Discriminant Analysis*), de modo a propor um novo modelo híbrido mais robusto e eficiente para multi-classificação de sinais EMG.

Referências

- Alpaydin, E. (2010). *Introduction to Machine Learning*. MIT Press.
- Basmajian, J. and De Luca, C. (1985). *Muscle Alive: Their Functions Revealed by Electromyography*, volume 5. William and Wilkins, Baltimore.
- De Luca, C. J. (1997). The use of surface electromyography in biomechanics. *Journal of applied biomechanics*, 13(2):135–163.
- Dideriksen, J. L., Gianfelici, F., Maneski, L. Z. P., and Farina, D. (2011). Emg-based characterization of pathological tremor using the iterated hilbert transform. *IEEE Transactions on Biomedical Engineering*, 58(10):2911–2921.
- Khushaba, R. N., Kodagoda, S., Liu, D., and Dissanayake, G. (2013). Muscle computer interfaces for driver distraction reduction. *Computer methods and programs in biomedicine*, 110(2):137–149.
- Kotsiantis, S. B., Zaharakis, I., and Pintelas, P. (2007). Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160:3–24.
- Phinyomark, A., Hu, H., Phukpattaranont, P., and Limsakul, C. (2012a). Application of linear discriminant analysis in dimensionality reduction for hand motion classification. *Measurement Science Review*, 12(3):82–89.
- Phinyomark, A., Phukpattaranont, P., and Limsakul, C. (2012b). Feature reduction and selection for emg signal classification. *Expert systems with applications*, 39(8):7420–7431.
- Raez, M. (2006). Techniques of emg signal analysis: detection, classification and applications. 8:11–35.
- Raurale, S., McAllister, J., and del Rincon, J. M. (2018). Emg acquisition and hand pose classification for bionic hands from randomly-placed sensors. In *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 1105–1109. IEEE.
- Robertson, G. E., Caldwell, G. E., Hamill, J., Kamen, G., and Whittlesey, S. (2013). *Research methods in biomechanics*. Human kinetics.
- Shenoy, P., Miller, K. J., Crawford, B., and Rao, R. P. (2008). Online electromyographic control of a robotic prosthesis. *IEEE transactions on biomedical engineering*, 55(3):1128–1135.
- Too, J., Abdullah, A., Zawawi, T. T., Saad, N. M., and Musa, H. (2017). Classification of emg signal based on time domain and frequency domain features. *International Journal of Human and Technology Interaction (IJHaTI)*, 1(1):25–30.
- Yousefi, J. and Hamilton-Wright, A. (2014). Characterizing emg data using machine-learning tools. *Computers in biology and medicine*, 51:1–13.
- Zhang, D., Xiong, A., Zhao, X., and Han, J. (2012). Pca and lda for emg-based control of bionic mechanical hand. In *2012 IEEE International Conference on Information and Automation*, pages 960–965. IEEE.