

APLICAÇÃO DA ANÁLISE DE COMPONENTES PRINCIPAIS EM SINAIS MIOELÉTRICOS DO BÍCEPS BRAQUIAL E TRÍCEPS BRAQUIAL

D. P. Oliveira, T. H. Nascimento, M. C. F. Castro

Depto de Eng. Elétrica / Centro Universitário da FEI, São Bernardo do Campo, Brasil

e-mail: mclaudia@fei.edu.br

Abstract: This work focuses on the investigation of using Principal Component Analysis (PCA) as a tool not only for dimensionality reduction but also for discrimination between classes, applied to a sample of myoelectric data obtained from the biceps brachii and triceps brachii during flexion / extension movements of the arm, aiming to discriminate angular position of the elbow. The PCA resulted in a number of principal components equal to or smaller than the number of classes used in this study, which may be a limitation for future classification. There is a pattern separability when adopted three classes but the efficiency decreases when the number and the proximity of classes increases. The type of movement and the use of 0.5 Kg load did not affect the separation of classes, but the information of both muscles should be considered for discriminatory purposes instead of the information from a single muscle.

Palavras-chave: PCA, Reconhecimento de padrões, bíceps / tríceps, Posição angular, Flexão / extensão.

Introdução

O interesse no uso do sinal mioelétrico (SME), como fonte de ativação de sistemas de interface homem-máquina, tem crescido nos últimos anos, tendo em vista que este sinal retém informações de controle do sistema nervoso, podendo então ser utilizado para a extração de informações relacionadas à intenção de movimento do sujeito. Essa extração de informação é conhecida como reconhecimento de padrões, segundo o qual, através de técnicas estatísticas e/ou de inteligência artificial, pretende-se detectar um comportamento comum em um movimento ou contração muscular de maneira a descrever o padrão [1]-[6].

O processo de reconhecimento de padrões pode ser dividido em duas etapas: extração de características e classificação. É sabido que o SME é redundante e ruidoso, o que quer dizer que, no conjunto total de dados, existe uma parte que não contribui com informação útil. A fase de extração de características tem por objetivo selecionar um conjunto de características que seja mais representativo e que contenha a maior parte da informação útil contida nos dados originais, e dessa forma obter um conjunto de

dimensão menor, e mais fácil de se lidar na fase de classificação. Essa por sua vez, corresponde à identificação das características como pertencentes a uma determinada classe dentre um certo conjunto que pode ou não ser especificado a priori [3]-[7].

Na abordagem estatística, o SME pode ser representado por um vetor com d características, ou seja, $x=[x_1, x_2, x_3, \dots, x_d]$. Um conjunto de SMEs pode ser representado por N vetores como este, definindo um espaço d -dimensional representado pela matriz $X_{N \times d}$. O processo de extração de características consiste em selecionar as m características mais representativas, tal que $m \ll d$, visando garantir que os padrões associados a diferentes classes ocupem regiões distintas no espaço m -dimensional, conhecido como espaço das características (*feature space*). A eficácia dessa etapa pode ser determinada pela separabilidade das classes no espaço m -dimensional [7].

Um dos métodos mais utilizados na fase de extração de características, principalmente visando à redução de dimensionalidade é a Análise de Componentes Principais (PCA), que baseia-se em combinar linearmente os dados, criando uma nova base de dados e projetá-los nas direções de maior variabilidade. Isto é importante para que não haja perda significativa de informação [7].

Este trabalho baseia-se na investigação do uso da PCA como ferramenta não apenas para a redução de dimensionalidade mas também para a discriminação entre classes, de uma amostra de dados mioelétricos, obtidos do bíceps braquial e tríceps braquial durante a realização de movimentos de flexão / extensão do braço, visando correlacioná-los à posição angular do cotovelo.

Materiais e Métodos

PCA—Sendo W_{pca} a transformação linear que mapeia o espaço original de dimensão d no novo espaço de dimensão m , com $m \ll d$, a nova base de dados pode ser construída por

$$Y = XW_{pca} \quad (1)$$

Resumidamente, o processo de definição da transformação linear corresponde à obtenção dos m maiores autovalores da matriz de covariância da base de dados originais, com os autovetores correspondentes formando as colunas de W_{pca} . Em outras palavras, os

autovetores são as direções e os autovalores as variâncias das chamadas Componentes Principais (CPs). Tendo em vista que estão sendo considerados os maiores valores, os dados estão sendo projetados nas direções de maior variância, e dessa forma, a informação redundante é desprezada, e a informação capaz de diferenciar as classes é mantida [7]-[8].

Base de dados – A amostra piloto foi formada por dados de 7 voluntários que realizaram duas configurações de movimentos de flexão / extensão, no plano horizontal, chamadas de Mov.1 e Mov.2 definidas a seguir. Os procedimentos foram repetidos três vezes cada, e nas configurações sem carga e com uma carga de 0.5 Kg presa ao punho. Enquanto o Mov.2 foi realizado continuamente, iniciando em extensão total, flexionando o braço até 90°, e estendendo novamente, com velocidade de 10°/s. , o Mov.1 foi realizado com pausas de 3 s a cada 10°, com a mesma velocidade e amplitude total de movimento. Além dos SMEs do bíceps braquial (bíceps) e tríceps braquial (tríceps), a posição angular do cotovelo também foi monitorada e armazenada para a formação posterior das classes.

Os SMEs adquiridos foram pré-processados para amplificação e atenuação de ruídos, retificados e filtrados com um filtro passa baixa de suavização, de maneira a se obter a envoltória da variação da amplitude do sinal. Foram selecionados os 200 ms iniciais para cada uma das posições angulares considerando incrementos de 10°. Dessa forma, cada posição angular constituiu uma classe, formada por vetores de dados de dimensão $d=200$, resultando em um total de até 18 classes considerando as posições angulares durante os movimentos de flexão e extensão. O tamanho das amostras de cada uma das classes, pode ser $N_i=21$ considerando Mov.1 e Mov.2 separadamente (7 voluntários x 3 repetições) ou $N_i=42$ considerando Mov.1 e Mov.2 em conjunto ou as configurações sem carga e com carga para um mesmo movimento (2 x 7 voluntários x 3 repetições).

Experimentos – Os testes realizados consistiram em definir diferentes conformações de amostras de classes, bem como diferentes configurações de número de classes, visando verificar a influência de alguns parâmetros no processo de redução de dimensionalidade e na separabilidade entre as classes. São eles: configuração de músculos utilizada, sendo bíceps e tríceps separadamente e em conjunto; número e proximidade entre as classes; configuração do movimento, ou seja, distinção entre Mov.1 e Mov.2; utilização ou não de carga.

Resultados

A influência dos parâmetros investigados foi comum para todas as configurações de amostras testadas, ou seja, os resultados foram independentes do movimento e da utilização ou não de carga.

A redução de dimensionalidade variou entre 3 e 5 CPs, explicando mais de 99% da variância total dos dados. Na maioria dos testes, considerando cada

músculo individualmente, a primeira CP explicou mais de 90% da variabilidade (usualmente em torno de 95%), e a segunda variando entre 3 e 6%. Porém, quando as classes foram formadas considerando os dois músculos em conjunto essas porcentagens diminuíram, podendo chegar a 75% de explicação para a primeira CP e 19% para a segunda CP.

Outra constatação foi uma separabilidade melhor quando considerados os dois músculos em conjunto em comparação aos resultados obtidos com cada músculo separadamente (Figuras 1 e 2). E comparando cada um dos músculos, os dados do bíceps resultaram em uma separabilidade melhor. Mas a separação entre as classes fica prejudicada com o aumento do número e da proximidade entre as classes (Figura 3 e 4).

Apesar de não ser evidente, pela maior quantidade e espalhamento dos dados, o mesmo comportamento foi verificado nas amostras formadas com os dados do Mov.1 e Mov.2 tomados em conjunto (Figura 5), e nas amostras formadas com os dados na configuração do Mov.1 com e sem carga (Figura 6).

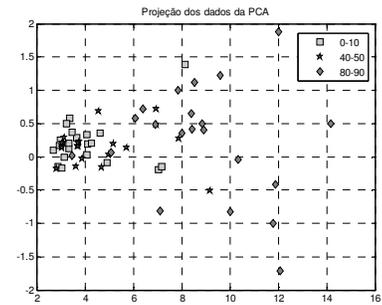


Figura 1 – Dados do bíceps no Mov.1 com carga projetados nas duas primeiras CPs.

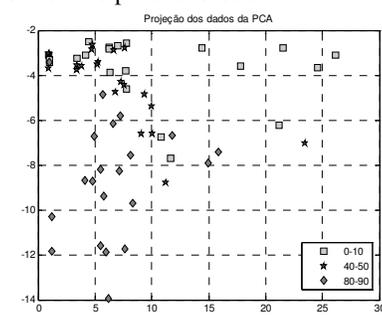


Figura 2 – Dados do bíceps e tríceps no Mov.1 com carga projetados nas duas primeiras CPs.

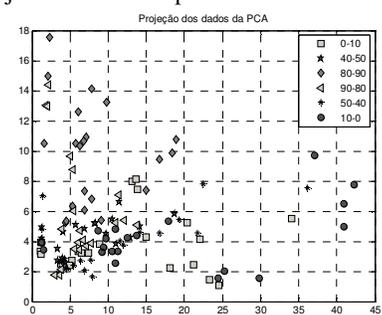


Figura 3 – Dados do bíceps e tríceps no Mov.1 sem carga projetados nas duas primeiras CPs.

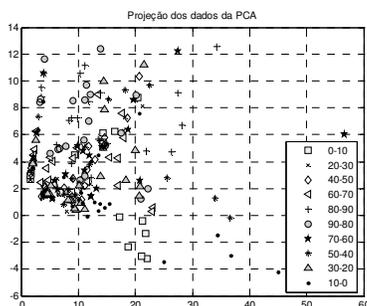


Figura 4 – Dados do bíceps e tríceps no Mov.2 com carga projetados nas duas primeiras CPs.

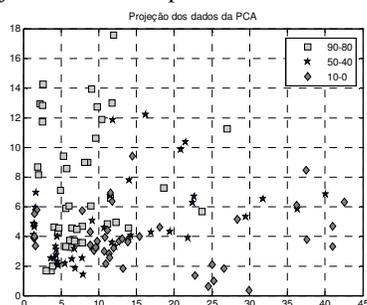


Figura 5 – Dados do bíceps e tríceps nos Mov.1 e Mov.2 sem carga projetados nas duas primeiras CPs.

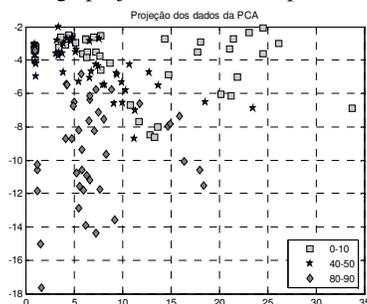


Figura 6 – Dados do bíceps e tríceps no Mov.1, nas configurações sem e com carga, projetados nas duas primeiras CPs.

Discussão

Em [6] B. Hudgins, P. Parker e R. N. Scott mostram que os 200 ms iniciais da contração muscular contêm informações determinísticas. Por esse motivo a opção em selecionar os 200 ms iniciais para caracterizar cada posição angular durante a realização dos movimentos, originando os vetores com dimensão $d=200$.

A redução de dimensionalidade é uma etapa fundamental para diminuir a complexidade e aumentar a eficácia dos classificadores. A taxa de classificações certas decai quando o número de elementos N_i de cada classe é pequeno, comparado à dimensionalidade do espaço original [7]. No caso em questão, o tamanho das amostras está relacionado ao número de aquisições, que por sua vez, está relacionado ao número de sujeitos e/ou repetições do movimento, e costuma ser pequeno quando comparado à dimensionalidade do sinal mioelétrico que pode ser desde poucas centenas até milhares de dados.

A redução de dimensionalidade de $d=200$ para $d=3-5$ CPs, respondendo por mais de 99% da variabilidade dos dados, confirma a característica redundante dos SMEs, utilizados aqui na forma de envoltória. Isto quer dizer que 3 combinações lineares dos dados, foi suficiente para explicar mais de 90% da variabilidade contida nos mesmos. Este resultado está de acordo com o apresentado em [9] apesar de o experimento ter trabalhado diretamente com o SME e não com a envoltória. Mas do ponto de vista analisado aqui, a redução foi, em geral, igual ou menor que o número de classes utilizadas nos experimentos. Ou seja, 3 a 5 CPs para configurações de 3, 5, 6, 10 ou 18 classes. Isto pode ser uma limitação a ser lidada nas etapas subsequentes de classificação. Em aplicações de processamento do SME, a literatura mostra o uso da PCA visando à redução de dimensionalidade, mas não discute os resultados dessa aplicação em termos de número de CPs utilizadas, impossibilitando uma comparação.

Quanto à etapa de classificação, a literatura mostra uma distinção mais extrema de estados, como por exemplo flexão / extensão, pronação / supinação, abertura / fechamento da mão, do que a pretendida aqui no sentido do sistema ser capaz de distinguir a posição angular com incrementos de 10° graus de diferença, que é uma diferença muito mais sutil. Além disso, a PCA não tem sido utilizada para esse fim, restringindo-se à etapa de redução de dimensionalidade. Os classificadores mais utilizados se baseiam na teoria de Redes Neurais, Lógica Fuzzy e técnicas estatísticas como Análise de Discriminantes Lineares (LDA), Vizinhos mais Próximos e Classificador Linear Bayesiano, após uma etapa de extração de características ou modelamento do SME [1]-[7].

No que diz respeito à separação de classes, para o problema tratado aqui, a PCA não obteve uma distinção muito evidente e clara das classes. Nota-se em todas as figuras uma concentração maior de pontos na origem do sistema de eixos e uma dispersão maior a medida que se distanciam da origem. De qualquer forma, notam-se regiões de maior concentração de dados para cada uma das classes, apesar de existirem também regiões de sobreposição.

Comparando as Figuras 1 e 2 verifica-se que a utilização dos dados de ambos os músculos proporcionou uma melhor separação das classes, quando comparado à utilização dos dados de um único músculo. Enquanto na Figura 1 os dados das duas primeiras classes (intervalos 0-10 e 40-50) estão mais sobrepostos na origem e os dados da terceira classe (intervalo 80-90) estão mais dispersos, na Figura 2 nota-se os dados da primeira classe dispostos horizontalmente na parte superior, os da terceira classe dispostos verticalmente à esquerda e os da segunda classe na faixa intermediária. Isto mostra que, durante o movimento, ambos os músculos estão atuando em conjunto e que as informações contidas em ambos devem ser levadas em consideração.

Esse mesmo padrão de distribuição pode ser visto

nas Figuras 5 e 6, que mostram os resultados obtidos com amostras formadas pela junção de dados considerando os Mov.1 e Mov.2 e as configurações sem carga e com carga. Mas em ambas também foram definidas 3 classes. Isto quer dizer que, mesmo o número de pontos por classe tendo aumentado, para esta configuração de classes, relativamente distantes entre si, o padrão de separabilidade foi mantido. Já nas Figuras 3 e 4 o número de classes aumentou, e na Figura 4 a distância entre cada classe diminuiu. Nota-se, nesses casos, um aumento da sobreposição, diminuindo a separação entre as classes. Ou seja, nas situações em que houve a necessidade de um poder de discriminação maior a PCA não foi capaz de separar as classes satisfatoriamente.

A explicação para a baixa eficiência da PCA na separabilidade das classes, utilizadas nesse trabalho, pode estar relacionada: a utilização da envoltória do sinal diretamente ao invés de se ter utilizado um modelo para a extração de características, e o próprio algoritmo, que computa a variabilidade global dos dados, sem levar em consideração a divisão das classes. Ou seja, a matriz de covariância considerada é a da amostra total, não computando nenhuma informação sobre as classes. Tendo isto em mente, o padrão de separação apresentado para a configuração de 3 classes razoavelmente distantes entre si (Figuras 1, 2, 5 e 6), corresponde à extração de um padrão menos detalhado, e portanto mais evidente, do que aquele exigido nas configurações com 5, 6 e 10 classes. Este resultado está de acordo com as aplicações que vem sendo apresentadas na literatura, que pretendem a distinção de classes extremas, como mencionado anteriormente, diferentemente do proposto neste trabalho que é a distinção de classes com diferenças sutis entre si [3]-[5].

Conclusão

A PCA muito utilizada para redução de dimensionalidade, resultou em um número de componentes principais igual ou inferior ao número de classes utilizadas nesse estudo, o que pode ser uma limitação para a aplicação de classificadores.

No que diz respeito à separação de classes, a PCA mostrou um padrão de separabilidade quando utilizadas 3 classes razoavelmente distantes entre si. Mas não pode ser considerada eficaz, por apresentar um grande espalhamento dos dados projetados com sobreposição entre as classes, situação esta intensificada com o aumento do número e da proximidade entre os intervalos que formam as classes.

Com relação aos demais parâmetros investigados, os tipos de movimentos bem como a utilização de carga não influenciaram, podendo inclusive ser juntados numa única amostra na formação das classes. Já a configuração de músculo, este sim permitiu concluir que a informação contida em ambos os músculos atuantes no movimento devem ser considerados para efeitos discriminatórios.

Como alternativas para o PCA pretende-se verificar,

na sequência, os efeitos da análise baseada em combinações não lineares como o Kernel PCA (KPCA) e a Análise de Discriminantes Lineares (LDA) que leva em consideração a formação de classes a priori.

Agradecimentos

Os autores gostariam de agradecer ao Prof. Dr. Carlos E. Thomaz e ao MSc. Giuliano A. Silva pelas discussões pessoais sobre o tema. Também gostariam de agradecer a FEI pelo financiamento do projeto através das bolsas PBIC-61/09 e PBIC-62/09 e a FAPESP.

Referências

- [1] Ahsan, Md.R., Ibrahimy, M.I., Khalifa, O.O. (2009) "EMG signal classification for human computer interaction: a review" *European Journal Scientific Research*, vol. 33, n. 3, p.480-501.
- [2] Reaz, M.B.I., Hussian, M.S., Mohd-Yasin, F. (2006) "Techniques of EMG signal analysis: detection, processing, classification and applications" *Biological Procedures Online*, vol. 8, n. 1, p.11-35, Disponível em: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC1455479/>.
- [3] Khezri, M., Jahed, M. (2007) "Real-time intelligent pattern recognition algorithm for surface EMG signal" *BioMedical Engineering Online*, vol. 6:45, Dez., Disponível em: <http://www.biomedical-engineering-online.com/content/6/1/45>.
- [4] Nazarpour, K., Sharafat, A.R., Firoozabadi, S.M. (2005) "A novel feature extraction scheme for myoelectric signals classification using higher order statistics", In: *Proceedings of the 2nd International IEEE EMBS Conference on Neural engineering*, Arlington, VA, p.293-296, Mar.
- [5] Englehart, K., Hudgins, B., Parker, P.A., Stevenson, M. (1999) "Classification of the myoelectric signal using time-frequency based representations" *Medical Engineering and Physics - Especial Issue on Intelligent Data Analysis in Electromyography and Electroneurography*, vol. 21, n. 6-7, pp. 431-438.
- [6] Hudgins, B., Parker, P., Scott, R.N. (1993) "A new strategy for multifunction myoelectric control" *IEEE Transaction on Biomedical Engineering*, vol. 40, n. 1, pp. 82-94.
- [7] Jain, A.K., Duin, R.P.W., Mao, J. (2000) "Statistical pattern recognition: a review" *IEEE Transaction on Pattern Analysis. Intelligence*, vol. 22, n. 1, pp.4-37.
- [8] Smith, L.I. (2002) "A tutorial on principal components analysis" disponível em: http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf acessado em 24/09/2009.
- [9] Daffertshofer, A., Lamoth, C.J.C., Meijer, O.G., Beek, P.J. (2004) "PCA in studying coordination and variability: a tutorial" *Clinical Biomechanics*, vol. 19, n. 4, p. 415-428.