

Classificação com SVM de sinais de EMG para implementação de próteses robóticas de baixo custo

Junior Cesar Ruiz Batista
juniorcrbatista@gmail.com
Universidade Tecnológica Federal do
Paraná*
Cornélio Procópio, Paraná, Brasil

Diêgo Rodrigues Labarewski
diegolabarewski@alunos.utfpr.edu.br
Universidade Tecnológica Federal do
Paraná
Cornélio Procópio, Paraná, Brasil

Renata Coelho Borges
renatacoelho@utfpr.edu.br
Universidade Tecnológica Federal do
Paraná
Cornélio Procópio, Paraná, Brasil

ABSTRACT

People with amputation go through several challenges, many of which are carried daily. The loss of functionality of the amputated limb can make some tasks difficult to perform, reducing their autonomy and quality of life. The use of robotic prostheses offers the possibility of returning elaborate movements that were previously lost. Through sensors and motors, robotic prostheses are capable of performing user-controlled movements, allowing the partial or complete return of lost movements. This work presents the results obtained with a classifier trained with support vector machines for the identification of movements through electromyography signals, obtained through non-invasive acquisition using surface electrodes. The results presented are part of several tests that will be carried out for the development of a control system for low cost robotic prostheses. In this paper, an average of 85% accuracy was obtained for classifiers trained from 3 features extracted from the frequency domain.

KEYWORDS

Prótese robótica, eletromiografia, máquinas de vetores de suporte, processamento de sinais

1 INTRODUÇÃO

O avanço e grande crescimento da robótica na saúde tem proporcionado diversos benefícios, desde exames mais precisos e mais rápidos até melhorias em procedimentos cirúrgicos [1]. Uma das áreas que tem recebido crescente atenção é a engenharia de reabilitação, responsável por desenvolver dispositivos médicos com o objetivo de auxiliar pessoas com deficiências ou necessidades especiais, sejam elas causadas por doenças ou lesões. As tecnologias desenvolvidas nesta área oferecem melhor qualidade de vida às pessoas com deficiência através da recuperação completa ou parcial de funcionalidades perdidas. As próteses robóticas são, por exemplo, potenciais substitutos para membros amputados e podem ser controladas pelo usuário, devolvendo parte da mobilidade perdida com a amputação do membro. Pessoas amputadas perdem muitas vezes a capacidade de realizar diversos movimentos, o que reduz sua autonomia e qualidade de vida[2].

Os dispositivos para auxílio em partes do corpo que foram amputadas dispõem de tecnologia avançada, utilizada para identificação do movimento que o usuário deseja realizar através da captação e interpretação de sinais biológicos, sendo o mais utilizado o sinal de eletromiografia (EMG). O sinal de eletromiografia é um

sinal elétrico que se origina no sistema nervoso central e desencadeia uma série de potenciais de ação, que percorrem os músculos do corpo e resultam nos conhecidos movimentos de contração muscular [3]. Para a interpretação do sinal são utilizadas técnicas de aprendizado de máquina, como Máquina de Vetores de Suporte, Support Vector Machine (SVM, em inglês) e redes neurais. Essas técnicas de aprendizagem de máquina utilizam os parâmetros extraídos dos classificadores, de modo que possam interpretar o sinal e identificar o movimento que deve ser realizado pela prótese. A classificação correta do movimento a ser realizado é essencial para o funcionamento da prótese e deve ser feito em tempo hábil para que todo o sistema de reconhecimento do movimento e controle da prótese, funcione de forma rápida e eficiente. Desta forma, a escolha do modelo utilizado para classificação do sinal deve ser realizada com cuidado, para que se obtenha o melhor desempenho possível.

2 SOLUÇÃO PROPOSTA

O objetivo deste trabalho é avaliar o desempenho de algoritmos de aprendizado de máquina na classificação de movimentos de mão e dedos. A análise de um bom classificador é de fundamental importância para que o sistema seja eficaz em termos de execução correta dos movimentos. Essa etapa do trabalho precede a etapa de implementação em hardware do sistema de baixo custo para próteses superiores. Para isso, foi utilizado o banco DB2 disponibilizado publicamente pelo projeto Ninapro [4]. O banco contém dados de 40 indivíduos não amputados. Para cada um dos indivíduos foram feitas aquisições de sinais eletromiográficos de superfície. Os eletrodos foram posicionados no antebraço, bíceps e mão, com um total de 50 movimentos (incluindo o descanso) [4].

Os classificadores analisados foram treinados com o algoritmo Máquina de Vetores de Suporte, *Support Vector Machine* (SVM, em inglês). Este algoritmo é baseado na criação de hiperplanos para separação de classes binárias de conjuntos de dados lineares e não lineares através das técnicas de *kernel* [5, 6]. Embora inicialmente as SVM possam separar somente conjuntos de duas classes (podendo ser aplicada apenas a problemas binários), existem algumas técnicas que permitem a utilização de classificadores binários na separação de conjuntos com três ou mais classes (*multiclass*), sendo a mais conhecida destas técnicas a um contra todos, *one-versus-all* (OVA, em inglês).

Para obter um melhor desempenho decorrente do treinamento do classificador, os dados são submetidos a uma etapa de pré-processamento. Nesta etapa, os dados são processados com a finalidade principal de redução de ruídos. Após esse processo são

*Universidade Tecnológica Federal do Paraná - UTFPR. Campus Cornélio Procópio. Av. Alberto Carazzini, 1640 - Vila Seugling, Cornélio Procópio - PR, 86300-000.

selecionadas as características MAV, RMS e WL usadas para o treinamento dos classificadores. Através desse processo é possível reduzir o tamanho do conjunto de dados que será utilizado no treinamento e aumentar sua eficiência. Para fins de comparação, 3 características foram escolhidas para serem extraídas no domínio do tempo. A extração das características foi efetuada usando o algoritmo desenvolvido e disponibilizado pelo projeto Ninapro [7, 8].

MAV: O valor médio absoluto, Mean absolute value (MAV), em inglês. Calculado usando a média móvel no módulo do sinal[9].

RMS: A raiz quadrada média, *root-mean-square* (RMS, em inglês), é uma característica comumente usada por ser computacionalmente eficiente e rápida [9].

WL: É dado como um recurso de informações sobre a complexidade da onda em cada segmento. Sendo simplesmente o comprimento acumulativo da forma de onda ao longo do segmento de tempo[9].

Todas as três características foram utilizadas para treinamento e teste com o algoritmo SVM fazendo uso de *kernel*, radial basis function, em inglês. Esta função realiza o mapeamento das entradas para um espaço de características com um número maior de dimensões. Com a realização da projeção dos dados para um outro espaço de maior dimensões, através da função *kernel*, um hiperplano pode ser utilizado nesse novo espaço de maior dimensão para separar os conjuntos de dados.

Os treinamentos e testes foram realizados em linguagem *python* com o uso da biblioteca *scikit-learn* [10]. Os movimentos selecionados estão apresentados na Figura 1. Para estes movimentos, foram utilizados apenas os eletrodos de 1 a 8 posicionados no antebraço, sem a utilização dos demais eletrodos posicionados ao longo do braço. A configuração dos eletrodos são apresentadas na Figura 2 [11]. Os sinais sEMG foram amostrados a uma taxa de 2 kHz, onde cada repetição de movimento teve uma duração de 5 segundos seguida por 3 segundos de descanso.



Figura 1: Movimentos 5, 6, 7 e 8 do banco de dados NinaPro usado no treinamento [11]

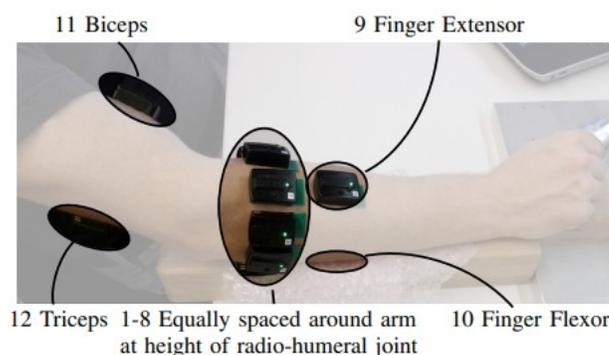


Figura 2: Configuração dos eletrodos[12]

3 RESULTADOS PRELIMINARES

A Tabela 1 contém os valores de acurácia para os 10 primeiros pacientes destros do banco de dados. Para cada paciente foram verificadas as acurácias utilizando cada uma das características extraídas definidas na Seção 2.

Tabela 1: Acurácias

| Indivíduo | MAV | RMS | WL |
|-----------|-----------------|------------------|------------------|
| 1 | (93,56 ± 3,43)% | (93,68 ± 4,07)% | (93,49 ± 3,72)% |
| 2 | (78,80 ± 9,79)% | (78,16 ± 11,08)% | (78,54 ± 12,29)% |
| 3 | (89,41 ± 6,21)% | (88,02 ± 6,66)% | (89,56 ± 5,38)% |
| 4 | (91,27 ± 6,48) | (91,66 ± 7,13)% | (90,9 ± 8,38)% |
| 5 | (76,54 ± 3,23) | (75,99 ± 4,45)% | (79,43 ± 1,59)% |
| 6 | (69,54 ± 4,22) | (69,82 ± 4,49)% | (65,58 ± 5,33)% |
| 7 | (95,97 ± 1,87)% | (94,29 ± 2,29)% | (90,68 ± 11,33)% |
| 8 | (95,28 ± 2,08)% | (95,80 ± 2,24)% | (95,59 ± 3,48)% |
| 9 | (95 ± 4,04)% | (93,39 ± 4,63)% | (95,52 ± 4,10)% |
| 10 | (78,33 ± 6,28)% | (78,11 ± 5,98)% | (70,75 ± 9,50)% |

Considerando as acurácias obtidas para os classificadores treinados com máquina de vetores de suporte (SVM) apresentadas na Tabela 1, foram obtidas as médias de 86,37% para a característica MAV, 85,89% para o RMS e 85% para o WL. É possível notar que as médias obtidas para cada uma das três características apresentaram uma pequena diferença (1,37%). Como essas características foram extraídas do domínio do tempo, serão acrescentados testes utilizando também características extraídas no domínio da frequência. Dessa forma, será possível verificar se existe um ganho de desempenho em relação às características extraídas no tempo e definir quais características serão utilizadas para a implementação em hardware.

3.1 Próximas etapas

A proposta para finalização deste projeto é a implementação dos algoritmos de classificação em um braço robótico MeArm para fins didáticos. O algoritmo de aprendizado de máquina escolhido a partir dos testes será implementado em um Arduino Uno para a realização das etapas de amostragem do sinal, processamento, classificação

dos movimentos e controle do braço robótico. O sistema será implementado de forma a funcionar em tempo real para a classificação dos 4 movimentos selecionados (conforme Figura 1).

Nesta etapa, os dados serão adquiridos de voluntários nos músculos do antebraço com a utilização de eletrodos de superfície. A primeira etapa da aquisição dos sinais será feita a partir de um circuito de pré-condicionamento de sinais, apresentado na Figura 3. A unidade de alimentação do circuito é composta por dois reguladores de tensão LM7805, usados para fornecer uma tensão simétrica ao circuito de 5V a partir de uma fonte de duas baterias de 9V.

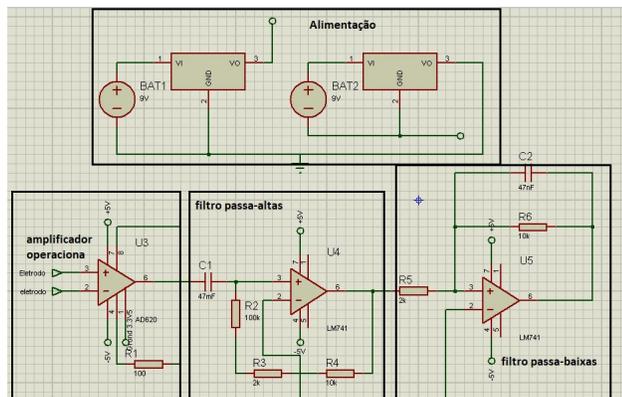


Figura 3: Circuito de aquisição de dados EMG de um canal.

Após o correto posicionamento dos eletrodos, o sinal de EMG passa na fase de amplificação do circuito. Essa primeira amplificação do sinal EMG bruto é feita por um amplificador de instrumentação. O amplificador de instrumentação é o primeiro componente da cadeia de aquisição responsável pela etapa de ganho inicial. Nesta etapa o amplificador utilizado foi o AD620. Este componente foi escolhido por apresentar alta impedância de entrada ($10G\Omega$) e uma razão de rejeição de modo comum (CMRR) elevada (100 dB com ganho 10 a 1kHz). O ganho para essa fase de amplificação é de 495 vezes. As duas últimas etapas do circuito são feitas por amplificadores operacionais do tipo LM741 operando no modo filtro.

O primeiro filtro, após a passagem do sinal pelo amplificador de instrumentação, é um filtro passa-altas com topologia não inversora. A função deste filtro é eliminar sinais de baixa frequência abaixo de 0.5Hz. Na sequência, última etapa do circuito, o sinal é sujeito à um filtro-baixas de topologia não inversora. A função deste filtro é eliminar sinais de alta frequência, superiores a 1kHz evitando o *aliasing*, pois a frequência máximo do sinal de EMG é $taltalt[2]$. O ganho total para essas duas fases resulta em 12 vezes.

4 CONSIDERAÇÕES FINAIS

Até o presente momento foram realizados testes somente utilizando máquinas de vetores de suporte. No entanto, futuramente também serão incluídos testes com outros algoritmos de aprendizado de máquina, como redes neurais para o treinamento do classificador. O intuito, nesse caso, é avaliar qual será, possivelmente, o melhor modelo para a implementação em hardware. Serão avaliados, além das acurácias dos classificadores, o custo computacional para a

implementação e o tempo de treinamento, visto que para implementações de baixo custo é importante considerar não somente a acurácia mas também os recursos computacionais disponíveis em hardware.

Por fim estudos realizados com eletromiografia para o controle de próteses robóticas tem mostrado um grande potencial para a reabilitação de pessoas com perda de movimentos por amputações, embora a recuperação completa dos movimentos ainda seja um desafio, a recuperação parcial dos movimentos perdidos pode ser alcançada. Neste trabalho foram apresentados os testes das acurácias de 4 movimentos utilizando máquina de vetores de suporte. Os mesmos testes serão realizados com redes neurais, assim como serão acrescentadas novas características extraídas do domínio da frequência. O foco do projeto é a implementação de um sistema de baixo custo para controle de próteses robóticas a partir do sinal de EMG, tendo em vista que atualmente o custo para a aquisição de próteses robóticas pode ser uma barreira para muitas pessoas.

REFERÊNCIAS

- [1] Juliano Elesbão Balthke et al. Sistema de processamento de sinais biomédicos: módulos didáticos de aquisição de ecg, emg, eeg e conversão analógico-digital de biosinais, 2008.
- [2] Gabriela Winkler Favieiro. Controle de uma prótese experimental do segmento mão-braço por sinais mioelétricos e redes neurais artificiais, 2009.
- [3] Carlo J De Luca. The use of surface electromyography in biomechanics. *Journal of applied biomechanics*, 13(2):135–163, 1997.
- [4] Manfredo Atzori, Arjan Gijsberts, Ilja Kuzborskij, Simone Elsig, Anne-Gabrielle Mittaz Hager, Olivier Deriaz, Claudio Castellini, Henning Müller, and Barbara Caputo. Characterization of a benchmark database for myoelectric movement classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 23(1):73–83, 2014.
- [5] André Carvalho, K Faceli, A Lorena, and J Gama. Inteligência artificial—uma abordagem de aprendizado de máquina. *Rio de Janeiro: LTC*, page 45, 2011.
- [6] Brandon H Boyle. *Support vector machines: data analysis, machine learning and applications*. Nova Science Publ., 2011.
- [7] Manfredo Atzori and Henning Müller. Pawfe: Fast signal feature extraction using parallel time windows. *Frontiers in neurobotics*, 13:74, 2019.
- [8] Adrain DC Chan and Geoffrey C Green. Myoelectric control development toolbox. *CMBES Proceedings*, 30, 2007.
- [9] Christopher Spiewak, M Islam, A Zaman, and Mohammad Habibur Rahman. A comprehensive study on emg feature extraction and classifiers. *Open Access Journal of Biomedical Engineering and Biosciences*, 1(1):1–10, 2018.
- [10] Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, et al. Scikit-learn: Machine learning in python. *the Journal of machine Learning research*, 12:2825–2830, 2011.
- [11] Manfredo Atzori, Arjan Gijsberts, Ilja Kuzborskij, Simone Heynen, Anne-Gabrielle Mittaz Hager, Olivier Deriaz, Claudio Castellini, Henning Müller, and Barbara Caputo. A benchmark database for myoelectric movement classification. *Trans. Neural Syst. Rehabil. Eng.*, 2013.
- [12] Arjan Gijsberts, Manfredo Atzori, Claudio Castellini, Henning Müller, and Barbara Caputo. Movement error rate for evaluation of machine learning methods for semg-based hand movement classification. *IEEE transactions on neural systems and rehabilitation engineering*, 22(4):735–744, 2014.