



RECONHECIMENTO DE GESTOS DE ELETROMIOGRAFIA DE SUPERFÍCIE UTILIZANDO UMA REDE NEURAL CONVOLUCIONAL BASEADA EM MODELO VGG-19 MODIFICADO

Surface electromyography gesture recognition using a modified VGG-19 model-based convolutional neural network

Bianca Erthal de Abreu¹, María Verónica González Méndez², José Jair Alves Mendes Júnior³

RESUMO

A classificação de biosinais, como sinais de eletromiografia de superfície, ainda é um aspecto desafiador para o aprendizado de modelos de máquina. Este artigo propõe uma análise de uma rede neural convolucional, a VGG-19 modificada, no reconhecimento de gestos da mão, por meio da avaliação de sua acurácia. Para tal objetivo, utilizou-se as aquisições de sEMG contidas na oitava base de dados do projeto NinaPro e fez-se o uso da segmentação, extração de características para criação de imagens baseadas em eletromiografia de superfície e sua classificação. A arquitetura proposta da VGG-19 modificada consiste na redução de camadas de convolução e de agrupamento para a análise dos dados. Os resultados obtidos com o método de separação de 90% para treinamento e 10% para teste de uma aquisição foram de um aumento significativo da acurácia máxima de 90,0% para 98,1%, comprovando a eficácia da rede neural convolucional para categorização dos sinais eletromiográficos.

PALAVRAS-CHAVE: Eletromiografia de superfície; reconhecimento de gestos; redes neurais convolucionais.

ABSTRACT

Biosignal classification, such as surface electromyography (sEMG) signals, is still a challenging aspect for machine learning models. This paper proposes an analysis of a convolutional neural network, the modified VGG-19, in hand gesture recognition, through the evaluation of its accuracy. For this purpose, we used the sEMG acquisitions contained in the eighth database of the NinaPro project and used segmentation, feature extraction to create surface electromyography-based images and their classification. The proposed architecture of the modified VGG-19 consists of reducing convolution and pooling layers for data analysis. The results obtained with the 90% separation method for training and 10% for testing of an acquisition were a significant increase in the maximum accuracy from 90.0% to 98.1%, proving the effectiveness of the convolutional neural network for the categorization of electromyographic signals.

KEYWORDS: surface electromyography; gesture recognition; convolutional neural networks.

INTRODUÇÃO

O reconhecimento de padrões em sinais eletromiográficos é fundamental para caracterização de diferentes gestos da mão. A técnica da eletromiografia de superfície (sEMG) permite registrar a atividade elétrica da contração muscular e é amplamente utilizada na área de reabilitação humana, como no controle de próteses e de órteses

¹ Voluntária do Programa de Iniciação Científica Voluntária. Universidade Tecnológica Federal do Paraná, Curitiba, Paraná, Brasil. E-mail: biancaerthal@alunos.utfpr.edu.br. ID Lattes: 0920080813890345.

² Mestranda do Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial. Universidade Tecnológica Federal do Paraná, Curitiba, Paraná, Brasil. E-mail: mariaveronica@alunos.utfpr.edu.br. ID Lattes: 2899671844789774.

³ Docente no Departamento de Eletrônica (DAELN). Universidade Tecnológica Federal do Paraná, Curitiba, Paraná, Brasil. E-mail: jjjunior@utfpr.edu.br. ID Lattes: 1920188611669631.



(PEERDEMAN et al., 2011). Atualmente, existem diversos métodos de classificação desses bio-sinais (PHINYOMARK et al., 2013). Um dos métodos que se destaca entre muitas pesquisas e literaturas é o uso de Redes Neurais Artificiais (RNAs), graças a sua alta precisão nos resultados, principalmente na manipulação de dados estocásticos em tempo real (CHOWDHURY et al., 2013).

Dentre as topologias de redes neurais, há um constante desenvolvimento das redes neurais convolucionais (*Convolutional Neural Networks*, CNN). Estas redes se caracterizam por múltiplas camadas de convolução, uma arquitetura de aprendizado profundo por retropropagação, um reconhecimento de padrões em imagens com alta eficácia e precisão (INDOLIA et al., 2018) e há diversos trabalhos que envolvem o seu uso para processamento de sEMG. Pode-se citar o Estudo da influência das etapas de segmentação, extração de características e classificação do alfabeto em Linguagem Brasileira de Sinais (Libras) a partir de sinais eletromiográficos de superfície por Mendes Júnior et. al (2020) que fez o uso de diversos classificadores, como a rede *Multi-layer Perceptron* (MLP), e o trabalho sobre a classificação de gestos manuais dinâmicos utilizando CNN com memória de curto prazo na interação homem máquina baseada em EMG realizado por LI et al. (2022).

Desse modo, o clássico modelo *Visual Geometry Group* de CNN com 19 camadas de convolução (VGG-19) é comumente escolhida entre os pesquisadores (SIMONYAN et al., 2014), mas, devido a sua profundidade, necessita de muito tempo de processamento durante o treinamento e para aplicações mais simples, há uma tendência de *overfitting* (superajuste). Portanto, seria interessante a utilização de uma técnica tão eficaz quanto a VGG-19, porém com um tempo menor de processamento e maior acurácia para esses dados selecionados.

Com este panorama, este trabalho pretende analisar o comportamento de uma CNN, a VGG-19 modificada, para o processamento de sinais de eletromiografia de superfície. Dessa forma, foram feitas as etapas de processamento, como extração de características e classificação dos sinais de uma base de dados relacionados a gestos manuais.

MATERIAIS E MÉTODOS

BASE DE DADOS NINAPRO

A base de dados utilizada é de livre acesso e de propriedade dos idealizadores do projeto NinaPro (*Non-Invasive Adaptive Prosthetics*), sendo a oitava base desenvolvida. (KRASOULIS et al., 2019). Ela consiste em 36 aquisições de eletromiografia de superfície (sEMG) por meio 16 sensores sem fio híbridos de duplo diferencial ativo posicionados no antebraço direito. Para cada indivíduo, foram feitas 3 aquisições, sendo a primeira e segunda usualmente usadas para treinamento e a terceira para teste.

Cada aquisição consiste na repetição de 9 gestos da mão na seguinte sequência: repouso, flexão/extensão do polegar, abdução/adução do polegar, extensão/flexão do indicador, flexão/extensão do dedo médio, flexão/extensão do dedo anular e mínimo combinados, flexão dos dedos associados a extensão do indicador (apontar), preensão cilíndrica, preensão lateral e preensão trípole respectivamente. Os gestos são intervalados com 3 segundos de repouso. À vista disso, as informações da sEMG, o número de repetição e a identificação do gesto foram agrupadas em um único arquivo de texto para o processamento no *software* MATLAB™.




PROCESSAMENTO DE SINAIS

As etapas do processamento foram divididas em: segmentação, extração de características e classificação. A primeira etapa consistiu na seleção dos momentos de ativação muscular, ou seja, execução do movimento, para a segmentação do sinal de sEMG em janelas de 300 ms de comprimento e uma taxa de sobreposição de 16,7%.

Já a segunda etapa baseou-se na extração de características de Hudgins et al.(1993) em cada um dos 16 canais de sEMG segmentados, *Mean Absolute Value* (MAV), *Sign Slope Change* (SSC), *Waveform Length* (WL) e *Zero Crossing* (ZC), de cada segmento. Este grupo foi aplicado devido seu uso em diversos trabalhos com sinal de sEMG, sendo considerado um grupo clássico de características. Após a extração desses atributos, cada valor foi dimensionado em uma escala de 0 a 1 pela normalização Mínimo-Máximo, para então, agrupar os valores regularizados das 4 características em um instante de tempo de cada um dos 16 canais em uma matriz 8 por 8.

Tendo em vista o alto desempenho de CNNs na classificação de imagens, os dados da matriz 8 por 8 foram convertidos em valores da escala de intensidade de cores *Red Green Blue* (RGB) para criação de imagens com resolução de 8 por 8 pixels no MATLAB™. A Figura 1 apresenta um exemplo ampliado da imagem produzida com a escala de cores *parula* do software para melhor visualização.


Figura 1 – Resolução de Características Ampliada



Fonte: Elaborada pelos autores (2023).

Por último, com o objetivo de evitar o *overfitting* e aumentar a porcentagem de acertos na previsão de cada gesto, na etapa de classificação utilizou-se a rede pré-treinada VGG-19 modificada. As modificações consistem na redução das camadas de agrupamento de 5 para 1, dos blocos de convolução de 16 para 8, conforme a figura 2.

Figura 2 – Arquitetura VGG-19 Modificada



Fonte: Elaborada pelos autores (2023).



RESULTADOS E DISCUSSÕES

O presente trabalho analisou o comportamento da VGG-19 modificada, para o processamento de sinais de sEMG, comparando o método de separação de 90% para 10% de validação em uma única aquisição, com treinamentos de uma base para outra do mesmo indivíduo como validação. Sendo diferente do que foi observado no estudo de Krasoulis et al., 2019, onde realizou-se o treinamento dos classificadores com as duas primeiras aquisições do *NinaPro* e o teste com a terceira, obtendo como resultados menos de 90% como valor máximo de acurácia de treinamento, com uma média 72%. Já o presente estudo, utilizando a VGG-19 modificada, obteve um valor máximo de acurácia 98,1%.

Na Tabela 1, observa-se os resultados de acurácia dos 10 indivíduos, com os dois métodos utilizados, sendo o método da separação de uma aquisição e o método intra-aquisições. O método de separação, divide uma mesma aquisição em 90% treinamento e 10% teste, já o método intra-aquisições, utiliza uma base para treinamento e outra para o teste. Os resultados do primeiro método variaram entre 75,9% e 98,1% de acertos, já o segundo método apresentou valores com uma maior variabilidade, sendo de 14,1% a 100%.

Tabela 1 – Percentual de Acurácia da VGG Modificada

Indivíduo	Aquisição		Intra		
	A1	A2	A1/A2	A1/A3	A2/A3
01	94,4%	85,9%	45,0%	67,0%	67,0%
02	94,1%	94,8%	100,0%	16,0%	25,2%
03	80,7%	62,9%	20,8%	20,3%	25,7%
04	90,0%	95,2%	65,6%	52,2%	70,5%
05	93,1%	88,2%	35,1%	28,2%	100,0%
06	98,1%	93,3%	50,0%	28,2%	47,6%
07	96,3%	92,9%	45,7%	34,3%	31,7%
08	87,6%	87,7%	34,4%	38,5%	41,7%
09	90,7%	93,3%	51,1%	24,8%	28,7%
10	81,8%	90,0%	19,5%	14,6%	45,6%
11	75,9%	83,5%	47,0%	46,5%	55,2%
12	82,6%	88,5%	51,7%	30,9%	43,2%

Fonte: Elaborado pelos autores (2023).



O método VGG-19 considera-se um método complexo, que demanda um maior tempo de processamento até a convergência final dos pesos de uma época da rede, portanto, modificá-lo com o objetivo de obter uma eficácia igual ou melhor, torna-se uma opção interessante para seus usuários. Sendo assim, a modificação na topologia VGG-19 com o treinamento e teste com a mesma base de dados permitiu melhores resultados no reconhecimento de padrões de gestos (alta média de acurácia), como visto em comparação com as intra-aquisições.

Na literatura, estes tipos de modificações não são encontradas com facilidade e quando observadas, não são utilizadas para essa aplicação, como visto no trabalho de Kamil (2021), que realizou a modificação *fine-tuning* (refinamento) da VGG-19 de forma a manter as camadas iniciais intactas sem que a retropropagação altere seus pesos, e as últimas camadas totalmente conectadas (pré-treinadas) foram substituídas por outras com novos pesos iniciais, para classificação de tomografias computadorizadas do pulmão para diagnósticos de COVID-19 e pneumonia. .

CONCLUSÃO

Diante disso, com o presente estudo, demonstrou que é possível também utilizar a VGG-19 modificada como classificador de sinais sEMG, obtendo valores eficazes de acurácia. Porém, alguns fatores devem ser levados em consideração, como a grande variabilidade da porcentagem da acurácia utilizando o método intra-aquisições, devido à alta variância nos resultados. Para obter melhores resultados em estudos futuros, é necessário refinar o modelo da rede, como substituir as camadas de normalização para melhor convergência dos resultados, novos ajustes nas camadas de ativação e opções de treinamento.

Agradecimentos

Os autores do presente trabalho gostariam de agradecer o Programa de Iniciação Científica Voluntária da Universidade Tecnológica Federal do Paraná, o coordenador do projeto e todo grupo de pesquisa.

Conflito de interesse

Não há conflito de interesse.

REFERÊNCIAS

CHOWDHURY, Rubana H; REAZ, Mamun B. I.; ALI, Mohd Alauddin Bin Mohd; BAKAR, Ashrif A. A.; CHELLAPPAN, Kalaivani; CHANG, Tae G. Surface Electromyography Signal Processing and Classification Techniques. **Sensors**, v. 13, n. 9, p. 12431–12466, 17 set. 2013.

ENGLEHART, Kevin; HUDGINS, Bernard. A robust, real-time control scheme for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, v. 50, n. 7, p. 848–854, jul. 2003.



HUDGINS, B.; PARKER, P.; SCOTT, R. N. A new strategy for multifunction myoelectric control. **IEEE transactions on bio-medical engineering**, v. 40, n. 1, p. 82–94, jan. 1993.

INDOLIA, Sakshi; GOSWAMI, Anil Kumar; MISHRA, S. P.; ASOPA, Pooja. Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach. **Procedia Computer Science**, v. 132, p. 679–688, 2018.

KAMIL, Mohammed. (2021). A deep learning framework to detect Covid-19 disease via chest X-ray and CT scan images. **International Journal of Electrical and Computer Engineering**. 11. 844-850. 10.11591/ijece.v11i1.pp844-850. 2021.

KRASOULIS, Agamenon; VIJAYAKUMAR, Sethu; NAZARPOUR, Kianoush. Effect of User Practice on Prosthetic Finger Control With an Intuitive Myoelectric Decoder. **Frontiers in Neuroscience**, v. 13, 10 set. 2019.

LI, Qiyu; LANGARI, Reza. EMG-based HCI Using CNN-LSTM Neural Network for Dynamic Hand Gestures Recognition. **IFAC-PapersOnLine**, v. 55, n. 37, p. 426–431, 2022.

MENDES JÚNIOR, José Jair Alves; FREITAS, Melissa La Banca; CAMPOS, Daniel Prado; FARINELLI, Felipe Adalberto; STEVAN JÚNIOR, Sergio Luiz Stevan; PICHORIM, Sérgio Francisco. 2020. Analysis of Influence of Segmentation, Features, and Classification in sEMG Processing: A Case Study of Recognition of Brazilian Sign Language Alphabet. **Sensors** 20, no. 16: 4359. 2020.

PEERDEMAN, Bart; BOERE, Daphne; WITTEVEEN, Heidi; VELD, Rianne Huis In't; HERMENS, Hermie; STRAMIGIOLI, Stefano; RIETMAN, Hans; VELTINK, Peter; MISRA, Sarthak. Myoelectric forearm prostheses: State of the art from a user-centered perspective. **The Journal of Rehabilitation Research and Development**, v. 48, n. 6, p. 719, 2011.

PHINYOMARK, Angkoon; QUAINÉ, Franck; CHARBONNIER, Sylvie; SERVIÈRE, Christine; TARPIN-BERNARD, Franck; LAURILLAU, Yann. EMG feature evaluation for improving myoelectric pattern recognition robustness. **Expert Systems with Applications**, v. 40, n. 12, p. 4832–4840, set. 2013.

SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. **CoRR** abs/1409.1556, 2014.