XXXII Encontro Anual de Iniciação Científica
IX Encontro Anual de Iniciação Científica Jr.
EAIC 2023

APLICAÇÃO DE REDES NEURAIS EM SINAIS DE ELETROMIOGRAFIA

Mateus José da Silva Gomes (PROVIC/UEPG), Jonathan de Matos, Rosane Falate, e-mail: rfalate@uepg.br

Universidade Estadual de Ponta Grossa/Departamento de Informática

Engenharia Elétrica; Medidas Elétricas, Magnéticas e Eletrônicas; Instrumentação.

Palavras-Chave: *Eletromiografia, Redes Neurais, Multilayer Perceptron, Classificação de Sinais.*

Resumo

Os dados de eletromiografia de superfície são medidos pelos pulsos elétricos provenientes de ações musculares. A partir disso, aplicou-se redes neurais *Multilayer Perceptron* para a predição de movimentos, de acordo com a evolução no tempo destes. Foi conseguida acurácia nos testes de até 68 %.

Introdução

A eletromiografia de superfície (sEMG) mede a atividade muscular (Basmajian; De Luca, 1985) e, com o auxílio da Inteligência Artificial (Kubat, 2017), especialmente Redes Neurais, como o *Multilayer Perceptron* (MLP), é possível classificar padrões de atividade muscular para aplicações em biomecânica e reabilitação. O MLP utiliza dados de entrada para aprender e associar os dados, produzindo saídas úteis relacionadas à atividade muscular.

Materiais e Métodos

Para a presente pesquisa, utilizou-se uma base de dados de Krilova *et al.* (2019) e a rede neural MLP. Duas estratégias foram avaliadas: a primeira, a qual utilizou apenas um arquivo com os dados de um único paciente, e os parâmetros de camadas ocultas, taxa de aprendizagem e número de iterações da rede foram variados; e a segunda, a qual assemelhou-se à primeira, modificando os mesmos parâmetros, porém realizando a junção dos arquivos, de maneira a conter os dados de todos os pacientes para ter uma maior gama de dados. As camadas ocultas representaram as camadas intermediárias de neurônios em uma rede neural, a taxa de aprendizagem controlou o tamanho dos ajustes nos pesos da rede a cada iteração, enquanto o número de iterações determinou quantas vezes o algoritmo treinou a rede nos dados de treinamento para melhorar seu desempenho (Kubat, 2017).

Resultados e Discussão

A Tabela 1 apresenta os melhores resultados obtidos para as duas estratégias implementadas. A melhor combinação dos parâmetros de aprendizagem da rede, em termos de camadas ocultas, taxa de aprendizagem e iterações, para a estratégia 1, foi: 12; 0,01; e 1000; enquanto que, para a estratégia 2, foi: 24; 0,01; e 1000.

Tabela 1. Melhores resultados das duas estratégias avaliadas.

Estratégia	Neurônios	Taxa de aprendizagem	Iterações	Acurácia Treino	Acurácia Teste
1	8-12-6	0,01	1000	67%	68%
2	8-24-6	0,01	1000	67%	18%

Conforme pode ser observado, a estratégia 1 foi a que teve melhor resultado, com 68 % de acurácia nos testes, enquanto que a estratégia 2 conseguiu somente 18 %.

Conclusão

Esta pesquisa identificou que o MLP foi eficiente para reconhecer os dados, mas, nos testes realizados, não conseguiu generalizar dados de pacientes diversos. Isso ocorreu, talvez, devido à diferença nas coletas ou então às características próprias de cada paciente. Propõem-se, como trabalhos futuros, realizar mais testes com o MLP, bem como testar um novo método de análise.

Agradecimentos

Agradeço à UEPG, pela infraestrutura e pela bolsa de iniciação científica, nos primeiros meses da pesquisa; à orientadora e ao coorientador, por todo suporte e apoio durante a pesquisa, pois sempre estiveram à disposição.

Basmajian, John V.; De Luca, Carlo. J. **Muscles Alive**: Their Functions Revealed by Electromyography. Baltimore: Williams & Wilkins, 1985.

Krilova,N., Kastalskiy,I., Kazantsev,V., Makarov,V.A., and Lobov,S.. (2019). **EMG data for gestures**. UCI Machine Learning Repository. Disponível em: https://doi.org/10.24432/C5ZP5C. Acesso em: 14 set. 2023.

Kubat, Miroslav. **An introduction to machine learning**. 2 ed. Cham, Switzerland: Springer International Publishing, 2017.