

SISTEMA DE INTELIGÊNCIA ARTIFICIAL PARA CLASSIFICAÇÃO DE MOVIMENTOS DE MEMBROS SUPERIORES (MMSS)

Eli Fellipe Valadão Belo¹; José Roberto Marques²; Alessandro Pereira da Silva³

1. Estudante do curso de Engenharia elétrica; e-mail: elifellipe6@gmail.com
2. Professor da Universidade Mogi das Cruzes; e-mail: jroberto@umc.br
3. Professor da Universidade Mogi das Cruzes; e-mail: alessandrops@umc.br

Área do conhecimento: Processamento de sinais biológicos

Palavras chave: Sinais eletromiográficos de superfície; Processamento de sinais biológicos; Tecnologias assistivas.

INTRODUÇÃO

Pessoas portadoras de alguma deficiência física nos membros superiores (MMSS) contém diversas dificuldades em tarefas diárias, por conta de suas limitações (FAVIEIRO, 2009). No entanto, com pesquisas e desenvolvimentos tecnológicos, estão aparecendo novas possibilidades para que estas superem suas limitações (FAVIEIRO, 2009). Nesse sentido, a engenharia de reabilitação vem se modernizando cada vez mais, trazendo mais benefícios e recursos para a reabilitação humana, melhorando os métodos para a reabilitação, e então a qualidade de vida (FAVIEIRO, 2009). O desenvolvimento tecnológico na área de reabilitação humana e tecnologias assistivas está gerando maiores possibilidades para pessoas com deficiências físicas se integrarem na sociedade e tornando-os mais independentes (FAVIEIRO, 2012). Sinais de eletromiografia de superfície (SEMG) contém aplicações em diversas áreas, como diagnósticos de doenças neuromusculares, controle de próteses e equipamentos ortopédicos, interfaces entre homem e máquina, realidades virtuais etc. Estudos referentes à classificação dos movimentos baseadas em inteligência artificial visam para criar um sistema capaz de identificar gestos específicos e usá-los para transmitir informação ou para controle de dispositivos (AHSAN; IBRAHIMY; KHALIFA, 2011, tradução nossa). Cordella et. al. (2016, tradução nossa) concluíram, após realização de uma revisão da literatura das necessidades de usuários de membros superiores protéticos, que apesar do avanço realizado nas próteses ao longo dos anos, ainda existe a necessidade de melhorar o controle de tais próteses para melhorar a interação com o ambiente e realização de tarefas diárias. Neste contexto estudos que implementem técnicas de processamento aos sinais EMG para extrair características podem contribuir para a classificação dos movimentos realizados por meio de reconhecimento dos movimentos realizados.


OBJETIVOS

Este estudo visa implementar um sistema computadorizado com inteligência artificial para classificar os movimentos realizados pelos membros superiores (MMSS) a partir dos sinais mioelétricos, utilizando a linguagem de programação Python.

METODOLOGIA

Para a realização deste estudo foi utilizado um banco de dados disponibilizado no repositório da UCI (UCI Machine Learn Repository, 2019). De acordo com Sapsanis, Gerogoulas e Tzes (2013, tradução nossa), que disponibilizaram o banco de dados, os sinais adquiridos foram filtrados durante a coleta, fazendo com que não seja necessária realizar a filtragem digital nos sinais, uma vez que a interferência de ruídos foi significativamente

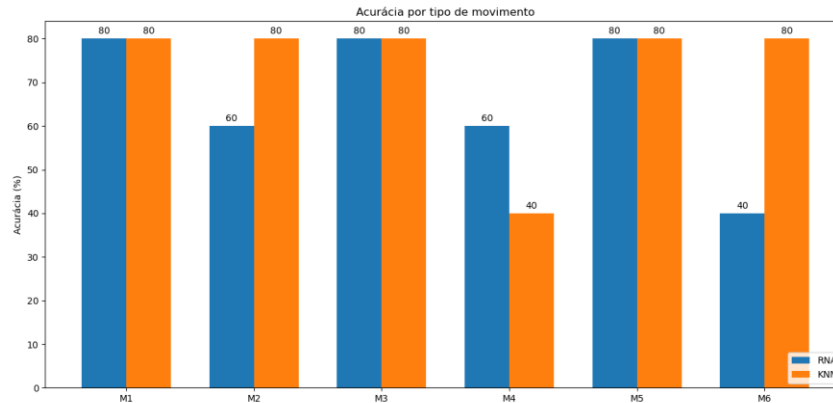
reduzida durante a coleta. Os sinais do banco de dados foram captados por dois eletrodos, localizados nos músculos flexor ulnar do carpo e no extensor radial curto e longo do carpo. No presente estudo foram implementados quatro métodos para extrair características dos sinais provindos do repositório da UCI (UCI Machine Learn Repository, 2019). Dessa forma, 5 coeficientes de um modelo auto regressivo (AR), a mudança de sinal de declive (Slope Sign Change, SSC), o comprimento da forma de onda (Waveform Length, WL) e o cálculo de variância de cada sinal (Phinyomark; Phukpattaranont; Limsakul, 2012, tradução nossa) foram definidos para alimentar a rede neural artificial (RNA). A configuração inicial da RNA consiste em 4 camadas escondidas, sendo que a primeira e a última contêm 300 neurônios e a segunda e terceira camadas 700 neurônios, utilizando a ativação “relu”, solucionador “adam”, com máximo de 500 iterações e taxa de aprendizado adaptativo. A imagem a seguir demonstra o esquema descrito.



RESULTADOS

O código desenvolvido para classificar os movimentos realizados foi capaz de adquirir as características dos sinais acessando os arquivos salvos, e normalizá-los com o método z-score e posteriormente separá-los nos grupos de treino e teste da rede neural. Com os dados normalizados a rede neural foi treinada e testada utilizando os dados adquiridos. Após diversos testes, a acurácia geral da rede ficou em torno de 60%. Por consequência, foi desenvolvido um código para busca por hiper parâmetros da rede neural, utilizando a biblioteca kerastuner, porém após diversos extensivos testes, a acurácia permanecia em torno de apenas 16,66%, com raras ocasiões onde, no máximo, ficava em torno de 66,66%. Devido à dificuldade para melhorar a acurácia geral da rede, mesmo com a busca por hiper parâmetros, foi realizado um teste para classificação utilizando k-NN (k nearest neighborhood), que gerou uma acurácia geral máxima de 73,33%. A figura a seguir apresenta um gráfico com o desempenho do método para diferentes valores de k, onde é possível notar drástica redução de desempenho para k com valores superiores a 55. O gráfico a seguir ilustra a comparação de acurácias obtidas por cada método, onde nota-se que o método KNN conseguiu melhor acurácia nos movimentos de preensão em gancho e lateral, porém com baixa acurácia para o movimento de preensão palmar.

Figura 1: Comparação da acurácia entre os classificadores RNA e KNN



Por questão de visualização, foram colocadas identificações “M1” a “M6” no eixo x que se referem, respectivamente, aos movimentos preensão cilíndrica, em gancho, em pinça, palmar, esférica e lateral.

DISCUSSÃO

Após a realização de alguns testes foi realizada uma busca por Hiper-Parâmetros, em que a melhor acurácia alcançada, dentro dos parâmetros da busca, foi com 5 camadas escondidas com 300, 700, 300, 700, 300 neurônios respectivamente. Além das camadas escondidas, foram realizados testes com as ativações “relu”, “sigmoid”, “softmax” e “tanh”, onde a função relu apresentou melhores resultados. Além da busca por Hiper-parâmetros utilizando a biblioteca kerastuner foram realizados testes com a função GridSearchCV do sklearn, porém, os parâmetros encontrados também geravam uma acurácia geral baixa, de aproximadamente 16%. No estudo de Khaledian e Miller (2020) é apresentada uma comparação entre métodos de classificação, como k-Nearest Neighborhood (kNN), Rede Neural Artificial (RNA), entre outros. Um ponto destacado no estudo é a sensibilidade da RNA para a quantidade de dados fornecido a ela, e sua variação de resultados para quantidades pequenas de dados, onde é recomendado utilizar centenas ou milhares de dados para obter acurácias maiores e com menor variação. Em contraste, é apontada uma consistência na acurácia do método kNN para diferentes quantidades de dados. Apesar da insensibilidade do KNN para a quantidade de dados, este método apresenta variação com o valor “k” selecionado, por isso foi realizada uma busca por valores de k que gerassem melhor acurácia, como demonstrado a figura 4. Porém, nesse caso, a acurácia reduziu com valores de k superiores a 55.

CONCLUSÕES

Após a realização do presente estudo, foi possível observar a possibilidade de utilizar somente características extraídas no domínio do tempo para classificação de movimentos a partir de sinais SEMG. Porém, mais testes precisam ser realizados, com diferentes algoritmos de classificação e bases de dados maiores, para determinar a capacidade de separar os tipos de movimentos com os dados extraídos. Além de realizar melhorias na classificação do movimento de preensão palmar. Estudos para interpretação de sinais SEMG são importantes para desenvolvimento e melhoria de tecnologias assistivas que utilizam esses sinais como variável para controle, como próteses e interfaces que auxiliem na recuperação de pacientes, sendo assim o presente estudo contribuiu para o desenvolvimento de sistemas de interpretação de sinais SEMG para utilização em tecnologias assistivas.

REFERÊNCIAS BIBLIOGRÁFICAS

CORDELLA, Francesca; et. al. Literature Review on Needs of Upper Limb Prosthesis Users. *Frontiers in Neuroscience*. 2016. Vol. 10.

FAVIEIRO, Gabriela Winkler. **Controle de uma Prótese Experimental do Segmento Mão-Braço por Sinais Mioelétricos e Redes Neurais Artificiais**. Trabalho de Diplomação - Engenharia da Computação, Universidade Federal do Rio Grande do Sul, 2009.

FAVIEIRO, Gabriela Winkler. **Desenvolvimento de um sistema Neuro-Fuzzy para análise de sinais mioelétricos do segmento mão-braço**. Dissertação (Mestrado)- Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, 2012.

KHALEDIAN, Yones; MILLER, Bradley A.. Selecting Appropriate Machine Learning Methods for Digital Soil Mapping. *Applied Mathematical Modelling*. 2020. Vol 81.

PHINYOMARK, angkoon; PHUKPATTARANONT, Pornchai; LIMSAKUL, Chusak. Feature Reduction and Selection for EMG Signal Classification. *Expert Systems with Applications*. 2012. Vol. 39.

SEMG for Basic Hand Movements Data Set. UCI Machine Learn Repository. **Título** Disponível em: <<https://archive.ics.uci.edu/ml/datasets/sEMG+for+Basic+Hand+movements>>. Acesso em: 6 Ago. 2019.