



## XXXV SALÃO de INICIAÇÃO CIENTÍFICA

6 a 10 de novembro

<b>Evento</b>	Salão UFRGS 2023: SIC - XXXV SALÃO DE INICIAÇÃO CIENTÍFICA DA UFRGS
<b>Ano</b>	2023
<b>Local</b>	Campus Centro - UFRGS
<b>Título</b>	Classificação de sinais de eletromiografia (EMG) utilizando inteligência artificial (IA)
<b>Autor</b>	PAULO HENRIQUE CECCATO
<b>Orientador</b>	ALEXANDRE BALBINOT

Neste trabalho, emprega-se inteligência artificial (IA) para classificar os sinais provenientes da eletromiografia. O estudo desse sinal desempenha um papel fundamental na medicina diagnóstica, tratamento, pesquisa e em diversas aplicações práticas que envolvem a compreensão e manipulação da atividade muscular. Os sinais mioelétricos (SME) representam a atividade elétrica manifestada durante a contração muscular após despolarização, sob controle cerebral. O uso de aprendizado de máquina, como redes neurais artificiais, é adotado para interpretar esses sinais e identificar os movimentos correspondentes. A base de dados DB2 do projeto NinaPro é utilizada no estudo, abrangendo informações de 40 indivíduos não amputados. A taxa de amostragem dos sinais de eletromiografia de superfície é 2 kHz. Cada iteração de movimento estende-se por 5 segundos, seguidos por 3 segundos de repouso. A etapa de pré-processamento envolve a retificação de onda completa para preservar a totalidade da energia do sinal. Posteriormente, procede-se ao janelamento e à extração de características do sinal, incluindo o valor RMS, valor máximo, desvio padrão, média, corte por 0, comprimento da forma de onda, valor médio absoluto e entropia. Dentre essas características, são selecionadas aquelas com baixa correlação: valor RMS, corte por 0 e comprimento da forma de onda. A estrutura de rede neural MLP é implementada por meio da biblioteca scikit-learn, composta por 2 camadas ocultas, cada uma contendo 350 neurônios, utilizando a função de ativação linear retificada e o otimizador "Adam". O desenvolvimento do algoritmo ocorre no ambiente Spyder do Anaconda, utilizando Python 3, com divisão dos dados em conjuntos de treinamento (75% dos dados) e teste (25% dos dados). Ao finalizar o treinamento do modelo, sua eficácia é avaliada por meio de novos dados, demonstrando um desempenho sólido com uma precisão aproximada de 84%.