



## APRENDIZADO AUTO-SUPERVISIONADO NO CONTROLE DE PROSTÉTICOS

PALAVRAS-CHAVE: ELETROMIOGRAFIA, INTELIGÊNCIA ARTIFICIAL, PROSTÉTICOS

*Candidato:*

Tiago Vello Marques

*Orientador:*

Prof. Dr. Romis Attux (FEEC/UNICAMP)

## 1 Introdução

A confluência de grandes avanços tecnológicos desenvolvidos na última década nas áreas de impressão 3D, engenharia de tecidos, cirurgia, redes neurais artificiais e robótica prometem um terreno fértil para o desenvolvimento de próteses para as próximas décadas. Dadas as tendências tecnológicas na área de próstéticos, o projeto tem como foco o desenvolvimento de um paradigma de coleta de dados que, em vez de classificar padrões de eletromiografia em um número de gestos arbitrados por um humano, utiliza sensores de pressão, acelerômetros e giroscópios para automaticamente identificar o gesto realizado. O objetivo é proporcionar uma coleta de dados automatizada e mais descritiva para atender à crescente demanda por dados por parte das modernas ferramentas de IA/Aprendizado de Máquina.

## 2 Objetivos e Metodologia

Este projeto tem como objetivo principal o desenvolvimento de um paradigma de coleta de dados para o treinamento de inteligência artificial de eletromiografia em que a posição da mão de um voluntário é estimada automaticamente, através de uma luva com sensores.

### 2.1 Eletromiografia

O cérebro, ao enviar um comando para a movimentação de um músculo, transmite a informação através de neurônios motores. Na sinapse neuromuscular, a ramificação dendrítica amplifica o sinal e emite ondas eletromagnéticas que podem ser medidas através de eletrodos de eletromiografia superficiais ou sEMG (do inglês surface Electromyography). Mesmo que um paciente tenha perdido o membro cuja musculatura se propunha movimentar, ainda é possível estimar qual era a intenção do movimento por meio destes sensores a fim de controlar um membro próstético.[M. B. I. Reaz and Mohd-Yasin, 2006]

sEMG são amplamente utilizados em próteses comerciais de membros superiores devido ao preço e à fácil instalação; contudo, sofrem de uma baixa relação sinal/ruído, que piora em climas secos e frios. Conseguem apenas medir, com precisão aceitável, a atividade muscular superficial de grandes grupos musculares. A fim de amenizar esses problemas, eletrodos mais invasivos foram propostos na última década, conforme relatado em [Xu and Todorov, 2019] [B. S. Spearman, 2018] [N. Xavier, 2005]. A introdução de corpos estranhos ao corpo, no entanto causa problemas como cicatrização que dificulta a transmissão desses impulsos nervosos ao longo do tempo.

Avanços cirúrgicos do começo do século [Miller et al., 2008] permitem a uma equipe médica implantar pequenos enxertos de músculo de-inervado do próprio paciente em volta da terminação dos nervos. Essa cirurgia de TMR (do inglês Targeted Muscle Reinnervation) devolve aos nervos eferentes um substrato natural para sua regeneração e diminui a formação de neuromas.[Dumanian GA, 2019] Ao se ramificar e reinervar o músculo, o sinal que iria para o membro amputado controla agora a contração de um pequeno enxerto, isso amplifica o sinal e permite sua captação com uma boa relação sinal ruído, mesmo com eletrodos superficiais. Próteses avançadas como a MLP (Modular Limb Prosthetic), desenvolvida por grupo da Johns Hopkins University [Perry BN, 2018], utiliza 16 sEMG além da cirurgia de Target Muscle Reinnervation (TMR) para amplificar o sinal. A Mind Control Prosthesis desenvolvida pela Michigan University [Philip P. Vu, 2020] utiliza pequenas agulhas como eletrodos introduzidas no enxerto de músculo da TMR.

O campo de eletromiografia é bem ativo, e pesquisas visando este método de controle de próstéticos se mostram promissoras. Este projeto utiliza 8 eletrodos diferenciais de superfície amplificados pela Cyton Board v3.12 da OpenBCI com uma taxa de amostragem de 250Hz e filtragem para eliminar ruídos provenientes da rede elétrica. Os 8 canais de sEMG foram posicionados de acordo com o músculo alvo da tabela acima a fim de coletar dados dos principais agrupamentos musculares

responsáveis pela pronação e supinação do antebraço; extensão e flexão do punho; flexão e extensão dos dedos mindinho, anelar, médio e indicador. As Figs. 1 e 2 ilustram a configuração.

Canal	Músculo Alvo	Canal	Músculo Alvo
1	Biceps brachii	5	Pronator Teres
2	Extensor Digitorum	6	Palmaris Longus
3	Extensor Carpi Ulnaris	7	Flexor Digitorum Superficialis
4	Flexor Carpi Radialis	8	Flexor Carpi Ulnaris

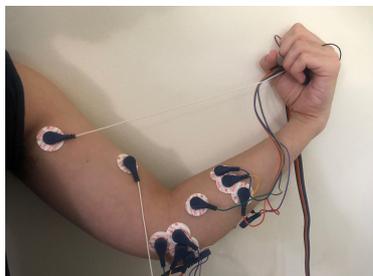


Figura 1: Disposição dos eletrodos



Figura 2: Disposição dos eletrodos

## 2.2 O Paradigma de Aprendizado Supervisionado

Tradicionalmente, o processo de controle de próteses mio-elétricas envolve o treinamento de um algoritmo de inteligência artificial que classifica os dados coletados por um sEMG em um número discreto de gestos, como fechar a mão, abrir a mão, girar o pulso para a direita etc.[Manfredo Atzori and Muller, 2012] O campo de inteligência artificial como um todo progrediu significativamente utilizando paradigmas similares, principalmente após redes neurais convolucionais - ou CNN (do inglês Convolutional Neural Networks) - atingirem o estado da arte em classificação de imagens em 2012 [Krizhevsky et al., 2012]. O sucesso deste paradigma tem a ver com o fato de que o crescente volume de dados rotulados possibilitou redes neurais a se tornarem melhores em realizar as tarefas em que foram, especificamente, designadas para realizar. No entanto, este paradigma tem limitações, como buscaremos explicar.

O fato de que a interpretação do que exatamente é um determinado gesto (sua velocidade, aceleração, amplitude e duração) pode ser subjetiva ou imprecisa dificulta o treinamento da rede, pois fundamentalmente injeta um viés humano nos dados. Este problema é exacerbado em bases de dados com mais de um sujeito, tornando a transferência de conhecimento entre modelos particularmente difícil.

A cada gesto, o algoritmo de inteligência artificial tem a oportunidade de calcular os gradientes uma vez, ou seja, a informação que é aprendida por unidade de tempo da sEMG é baixa, uma vez que é humanamente impraticável associar uma classe a cada fração de cada movimento.

Modelos treinados nesse paradigma, não obstante, têm dificuldade de aprender com as similaridades entre classes diferentes. Humanos formam modelos preditivos gerais sobre o mundo - este “senso comum” de como o mundo funciona ajuda consideravelmente a diminuir a quantidade de informação necessária para aprender tarefas parecidas. Modelos treinados com o paradigma de classificação supervisionada tratam gestos como levantar o dedo indicador e levantar o dedo anelar como duas classes fundamentalmente diferentes, o que limita a informação que pode ser aprendida a cada amostra de dado.

## 2.3 Aprendizado auto supervisionado

Desde o início do aprendizado de máquina, a busca por modelos com “senso comum” é considerada, de certa maneira, a “matéria escura” da inteligência artificial [LeCun and Misra, 2021]. Dois grandes passos no caminho da inteligência artificial generalizada são a mudança para o paradigma de aprendizado auto supervisionado e arquiteturas de redes neural mais generalistas baseadas em atenção que juntos atingiram o estado da arte em modelos de processamento de linguagem.[Vaswani et al., 2017] A diferença fundamental entre os dois paradigmas é que, em vez de o aprendizado partir de dados rotulados por humanos, a supervisão, grosso modo, é dada pelo próprio dado, delegando ao humano o trabalho de especificar a forma em que a informação supervisiona o aprendizado. Desta nova forma, a diminuição do custo da construção de bases de dados massivas torna possível a utilização de arquiteturas de redes neurais mais generalistas, ou seja, sem os tradicionais vieses embutidos nas CNNs e SVMs (do inglês Support Vector Machines).

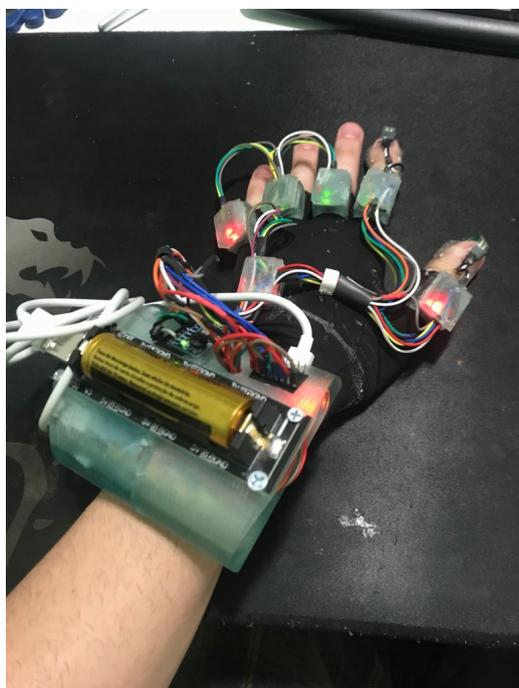


Figura 3: Luva sensorial desenvolvida no projeto



Figura 4: Sensores de pressão posicionados no dedão e dedo indicador

## 2.4 Luva Sensorial

A fim de trazer o paradigma do aprendizado auto supervisionado para o campo de próstéticos, o projeto propõe o desenvolvimento de uma luva com 6 acelerômetros, 6 giroscópios e 2 sensores de pressão, responsáveis por estimar a orientação e força da mão, dedos e pulso de forma automática. Futuramente, um indivíduo saudável utilizaria a luva enquanto eletrodos de sEMG observam a atividade muscular. Após essa coleta de dados, uma inteligência artificial baseada na arquitetura de um transformer[Vaswani et al., 2017] e outra baseada em redes convolucionais seria treinada com o objetivo de prever a orientação e posição da mão com base na leitura dos sensores de sEMG a fim de comparar a eficiência das duas arquiteturas no problema específico. A segunda etapa seria colocar os sEMG no coto de um paciente em quanto a luva sensorial seria posicionado na mão que ainda esta presente. O paciente então realizaria movimentos com a mão que está com a luva, enquanto imagina realizar os movimentos espelhados com o coto, mesmo sem a mão, se espera que o cérebro mande os comandos para os músculos do coto e os sEMG os capturem. O transformer e a CNN treinadas na primeira etapa seriam utilizados para pré-treinar outras duas redes. O objetivo dessa etapa é comparar o potencial de transferência de aprendizado das duas arquiteturas neste problema em específico. O objetivo da luva é adereçar as três limitações apresentadas na sessão 2.2

O viés humano introduzido pela subjetividade da arbitração do gesto é eliminada na primeira etapa, uma vez que sensores bem calibrados assumem este papel e amenizada na segunda etapa, pois o mesmo indivíduo esta arbitrando as características do gesto.

A taxa de informação que é aprendida pelo algoritmo por unidade de tempo aumenta significativamente, uma vez que os dados da luva são amostrados em uma taxa de 20Hz.

Gestos similares tem suas similaridades reconhecidas de uma maneira objetiva. Tanto o ato de levantar o dedo anelar quanto o de levantar o dedo indicador mantém o resto da mão estacionaria, isso é reconhecido pela luva e é transmitido para o algoritmo como informação útil para a construção de representações mais gerais de como uma mão humana deve funcionar.

### 2.4.1 Hardware

A luva utilizada é uma luva de compressão para artrite. A escolha foi feita para que os sensores não se deslocassem durante os ensaios.

Todas as peças em verde claro mostradas na Fig. 3 foram impressas em 3D utilizando uma impressora de resina Photon (Anycubic) com uma mistura de Blu (Siraya Tech) e Clear Resin (Monile).

Os sensores de pressão mostrados na Fig. 4 foram adicionados no projeto para que a atividade muscular convertida em força também seja levada em conta na perspectiva do algoritmo. Foram utilizados dois sensores FSR402 que variam a resistência ao serem pressionados. Foi adicionado um conversor analógico digital MCP3008 para transmitir informação para um Raspberry Pi 3B utilizando o protocolo SPI. Os sensores foram colados em uma peça impressa em 3D que foi costurada em uma ponta de luva transparente e flexível.

Para estimar a orientação da mão, foram utilizados 6 MPU6050, cada um contendo um acelerômetro e um giroscópio.

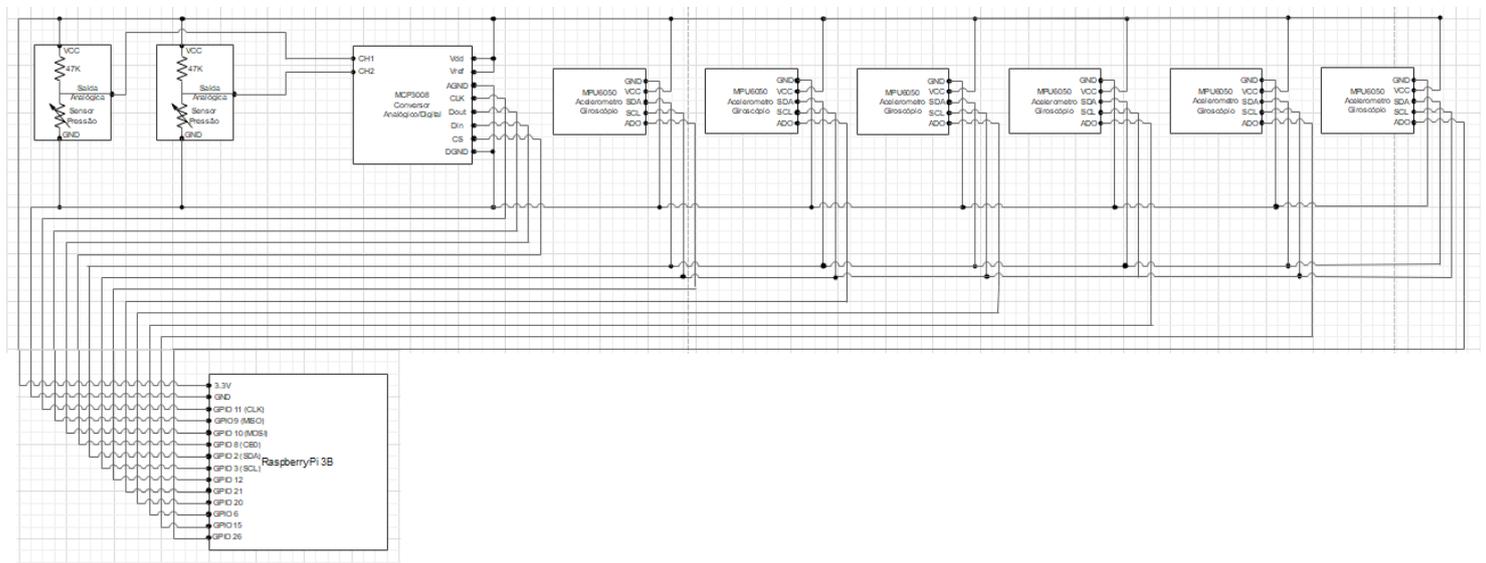


Figura 5: Diagrama do hardware utilizado na luva sensorial

Foram posicionados um em cada dedo e um nas costas da mão. Cada MPU6050 foi posicionado em uma caixa impressa em 3D que foi costurada na luva. Os sensores enviam informação para o Raspberry Pi 3B utilizando o protocolo i2C.

### 2.4.2 Software

Um período inicial de 1000 amostras em que a mão do voluntário ficava estática foi utilizado para a calibração do giroscópio. No início de cada amostra, um período de 100 amostras em que a mão permanece estática para ajustar a posição inicial da luva.

Para estimar a orientação de cada MPU6050, se utilizou um filtro de Madgwick com  $\beta = 0.05$ . [Madgwick, 2010] Este algoritmo utiliza a representação de quatérnios para integrar o deslocamento angular estimado pelo giroscópio no tempo e corrigir os erros iterativamente por gradiente descendente utilizando a rotação em relação ao vetor gravidade estimado pelo acelerômetro. O  $\beta$  é uma constante definida a priori que estima a desconfiança do algoritmo na medida do giroscópio.

A partir das representações quaternas de cada MPU6050 estimadas a partir do filtro de Madgwick, foi desenvolvido um modelo computacional em python utilizando a biblioteca vpython para simular a posição da mão.

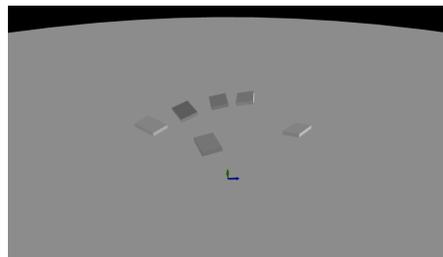


Figura 6: Modelo computacional desenvolvido para simular a posição dos sensores

## 3 Resultados

O projeto obteve como resultado a construção de uma luva sensorial capaz de produzir um modelo computacional dos movimentos dos dedos e pulso de uma mão. Com esta luva e um equipamento de sEMG, o objeto também obteve uma base de dados com sete ensaios de dez minutos cada. O treinamento das redes neurais até o momento da escrita deste relatório ainda não foi completado.

## 4 Conclusão

A simulação gerada pelo modelo computacional é capaz de reproduzir os movimentos realizados pela mão em ensaios de curta duração. Uma hipótese para degeneração dos resultados em ensaios longos é a falta de um magnetômetro no MPU6050, pois não é possível corrigir a deriva do giroscópio no eixo perpendicular à gravidade somente com um acelerômetro. A escolha

de um sensor sem o magnetômetro foi feita tendo em mente a possível interferência da luva nos sensores, no entanto, mesmo com a interferência, a utilização do magnetômetro pode aumentar qualidade dos dados.

A eletromiografia utilizando uma taxa de amostragem de 250Hz é considerada baixa, no entanto, o Cyton é limitado pela transferência por bluetooth. Existem duas soluções para o problema: Um Wifi Shield está em desenvolvimento pela OpenBCI que promete taxas de transferência até 1kHz, Uma modificação de firmware permite transferência para um cartão de memória microSD local, contudo, a documentação de como realizar esta modificação se mostrou insuficiente.[julfy, 2021]

O paradigma de aprendizado auto supervisionado proposto requererá futuros estudos mais completos para ser validado, mas os resultados aqui relatados podem ser considerados promissores.

## 5 Agradecimentos

Gostaria de agradecer ao meu orientador Romis Attux pela sua dedicação e sabedoria. Aos meus pais por terem acreditado no meu potencial e me incentivado durante todo o processo. Ao CNPq pelo financiamento, e à UNICAMP por toda a estrutura e laboratórios que possibilitaram a minha pesquisa. Agradeço a todos os professores que formaram o meu conhecimento. A todos os outros e outras cientistas que citei nas referências, gostaria de deixar aqui também minha gratidão.

## Referências

- [B. S. Spearman, 2018] B. S. Spearman, e. a. (2018). Tissue-engineered peripheral nerve interfaces. *Advanced Funcional Materials*.
- [Dumanian GA, 2019] Dumanian GA, Potter BK, M. L. K. J. C. J. S. J. E. W. T. S. N. G. V. I. K. T. A. A. P. K. J. S. (2019). Targeted muscle reinnervation treats neuroma and phantom pain in major limb amputees: A randomized clinical trial. *Ann Surg*.
- [julfy, 2021] julfy (2021). Allow writing to sd card with sampling rate over 250.
- [Krizhevsky et al., 2012] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In Pereira, F., Burges, C. J. C., Bottou, L., and Weinberger, K. Q., editors, *Advances in Neural Information Processing Systems*, volume 25. Curran Associates, Inc.
- [LeCun and Misra, 2021] LeCun, Y. and Misra, I. (2021). Self-supervised learning: The dark matter of intelligence.
- [M. B. I. Reaz and Mohd-Yasin, 2006] M. B. I. Reaz, M. S. H. and Mohd-Yasin, F. (2006). Techniques of emg signal analysis: detection, processing, classification and applications. in *Biological Procedures Online*.
- [Madgwick, 2010] Madgwick, S. (2010). An efficient orientation filter for inertial and inertial/magnetic sensor arrays. *Report x-io and University of Bristol (UK)*.
- [Manfredo Atzori and Muller, 2012] Manfredo Atzori, Arjan Gijssberts, S. H. A.-G. M. H. O. D. P. v. d. S. C. C. B. C. and Muller, H. (2012). Building the ninapro database: A resource for the biorobotics community. *IEEE International Conference on Biomedical Robotics and Biomechatronics (BioRob 2012)*.
- [Miller et al., 2008] Miller, L. A., Lipschutz, R. D., Stubblefield, K. A., Lock, B. A., Huang, H., Williams, T. W., Weir, R. F., and Kuiken, T. A. (2008). Control of a six degree of freedom prosthetic arm after targeted muscle reinnervation surgery. *Archives of Physical Medicine and Rehabilitation*, 89(11):2057–2065.
- [N. Xavier, 2005] N. Xavier, e. a. (2005). A critical review of interfaces with the peripheral nervous system for the control of neuroprostheses and hybrid bionic systems. *Journal of the Peripheral Nervous System*.
- [Perry BN, 2018] Perry BN, Moran CW, A. R. P. P. V. J. T. J. (2018). Initial clinical evaluation of the modular prosthetic limb. *Front Neurol*.
- [Philip P. Vu, 2020] Philip P. Vu, e. e. (2020). A regenerative peripheral nerve interface allows real-time control of an artificial hand in upper limb amputees. *SCIENCE TRANSLATIONAL MEDICINE | RESEARCH ARTICLE*.
- [Vaswani et al., 2017] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2017). Attention is all you need.
- [Xu and Todorov, 2019] Xu, Z. and Todorov, E. (2019). Implantable neural interfaces and wearable tactile systems for bidirectional neuroprosthetics systems. *Advanced Healthcare Materials*.