

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

LÁZARO LUIZ DUARTE NETO

CLASSIFICAÇÃO DE MOVIMENTOS DA MÃO BASEADO EM SINAIS
EMG E LDA PARA CONTROLE DE PRÓTESES DE MEMBROS
ARTIFICIAIS

Uberlândia

2023

LÁZARO LUIZ DUARTE NETO

CLASSIFICAÇÃO DE MOVIMENTOS DA MÃO BASEADO EM SINAIS
EMG E LDA PARA CONTROLE DE PRÓTESES DE MEMBROS
ARTIFICIAIS

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia como requisito parcial para obtenção do título de bacharel em Engenharia Biomédica.

Área de concentração: Engenharias

Orientador: Alcimar Barbosa Soares, PhD

Uberlândia

2023

Dedico este trabalho a todos os que estiveram
comigo durante a minha caminhada.

AGRADECIMENTOS

Agradeço primeiramente a Deus por me permitir chegar até aqui com saúde e condições de estar realizando esse trabalho.

Agradeço a minha família por todo o apoio, em especial a minha vó e minha mãe, por estarem comigo durante toda essa jornada.

Agradeço ao professor Alcimar, por me proporcionar a oportunidade de ser orientado por ele e por me ensinar a buscar o conhecimento necessário para a execução deste trabalho.

Agradeço a todos os que tiveram comigo e me apoiaram de alguma forma durante todo esse tempo.

“A ciência é, portanto, uma perversão de si mesma, a menos que tenha como fim último, melhorar a humanidade.”

(NIKOLA TESLA)

RESUMO

A amputação de membros superiores é um problema que desencadeia outros durante a vida, tais como dificuldades para comer e realizar as atividades do dia-a-dia. Existem diferentes níveis de amputação, que podem ser divididos em seis níveis nos membros superiores (desarticulação de ombro, amputação transumeral, desarticulação de cotovelo, amputação transradial, desarticulação do punho e desarticulação parcial de mão). Para minimizar as dificuldades decorrentes da amputação, os sujeitos podem fazer uso de dispositivos protéticos. Dependendo da estratégia de controle, as próteses podem ser classificadas como passivas (estéticas), ativas (controle mioelétrico) ou híbridas. O presente trabalho apresenta uma estratégia para a classificação de movimentos da mão e possível uso em dispositivo protético mioelétrico. A estratégia adotada consiste no uso do algoritmo *Linear Discriminant Analysis* (LDA) para classificação de movimentos, realizando todo o processo de aquisição de características do sinal EMG, treinamento do modelo e uso do mesmo. O algoritmo LDA foi escolhido pois apresenta grande simplicidade computacional, fato que se confirma no presente trabalho. Para avaliação do algoritmo foram utilizadas as métricas de acurácia que são amplamente empregadas em problemas de aprendizado de máquina. A respeito de seu baixo custo computacional quando comparado a outras estratégias de aprendizado de máquina, os resultados mostram que o classificador LDA provê altas taxas de acerto permitindo seu uso em sistemas embarcados para controle de próteses de membros artificiais.

Palavras-chave: LDA; Prótese; Aprendizado de máquina;

ABSTRACT

Upper limb amputation is a problem that triggers others throughout life, such as difficulties in eating and performing activities of daily living. There are different levels of amputation, which can be divided into six levels in the upper limbs (Shoulder Disarticulation, Transhumeral Amputation, Elbow Disarticulation, Transradial Amputation, Wrist Disarticulation, and Partial Hand Disarticulation). To minimize the damage caused by amputation, there are prosthetic devices, which can be esthetic, active, myoelectric, or hybrid. The present work presents a strategy for hand motion classification and possible use in a myoelectric prosthetic device. The adopted strategy consists of using the linear discriminant analysis (LDA) algorithm for motion classification, performing the whole process of EMG signal feature acquisition, model training, and model use. LDA was chosen because it presents great computational simplicity, a fact that is confirmed in the present work. To evaluate the algorithm we used the accuracy metrics that are widely used in machine learning problems. Regarding its low computational cost when compared to other machine learning strategies, the results show that the LDA classifier provides high success rates allowing its use in embedded systems to control prosthetic limbs.

Keywords: LDA; Prosthesis; Machine Learning;

LISTA DE FIGURAS

Figura 1 - Sinal EMG.	11
Figura 2 - Eletrodos passivos.	12
Figura 3 - Sensor EMG simples diferencial.	12
Figura 4 - Sensor EMG duplo diferencial.	12
Figura 5 - Diagrama de blocos de um sistema para aquisição de sinais EMG.....	13
Figura 6 – Modelo genérico de uma Rede Neural Artificial.	16
Figura 7 - Exemplo de Hiperplanos SVM.	17
Figura 8 - Mudança de coordenadas nas SVMs não lineares.	18
Figura 9 - Exemplo LDA.....	19
Figura 10 - Esquema de um sistema de controle de próteses mioelétricas.....	22
Figura 11 - Arrays de eletrodos utilizados para captura dos sinais EMG.	24
Figura 12 - Movimentos da mão realizados pelos voluntários.....	25
Figura 13 - Diagrama de funcionamento do sistema.....	25
Figura 14 - Gráfico de acurácia do modelo treinado para diferentes quantidades de eletrodos.	29
Figura 15 - Gráfico da validação cruzada.....	32

LISTA DE TABELAS

Tabela 1 – Dados dos voluntários e intervalos entre sessões de coleta.....	21
Tabela 2 - Acurácia média para cada sujeito utilizando os 16 canais.	27
Tabela 3 – Acurácia média para cada sujeito utilizando 8 canais.	27
Tabela 4 – Acurácia média para cada sujeito utilizando 4 canais.	28
Tabela 5 – Acurácia média para cada sujeito utilizando 2 canais.	29
Tabela 6 – Validação cruzada de 16 canais.....	30
Tabela 7 – Validação cruzada de 8 canais.....	30
Tabela 8 – Validação cruzada de 4 canais.....	31
Tabela 9 – Validação cruzada de 2 canais.....	31
Tabela 10 - Tempos de execução de diferentes partes do algoritmo.....	33

LISTA DE ABREVIATURAS E SIGLAS

EMG	Eletromiografia
HD-sEMG	EMG de superfície de alta densidade
K-NN	<i>K-Nearest Neighbors</i>
LDA	Análise Discriminante linear
MAV	Média de valores absolutos
MF	Frequência mediana
MNF	Frequência média
PKF	Frequência de pico
RMS	Média quadrática
SVM	Máquinas de vetores de suporte
VAR	Variância
WL	Comprimento de onda
ZC	Cruzamentos por zero
ZCR	Taxa de cruzamentos por zero

SUMÁRIO

1	INTRODUÇÃO	9
2	OBJETIVO.....	10
3	ELETROMIOGRAFIA.....	11
3.1	O sinal eletromiográfico (EMG).....	11
3.2	Aquisição e pré-processamento de sinais EMG.....	11
3.3	Características do sinal EMG	13
4	ESTRATÉGIAS DE APRENDIZADO DE MÁQUINA SUPERVISIONADO.....	16
5	MATERIAIS E MÉTODOS	21
5.1	Materiais utilizados.....	21
5.2	Metodologia.....	22
5.3	Métricas para avaliação da performance do modelo.....	25
6	RESULTADOS E DISCUSSÕES	27
6.1	Acurácia.....	27
6.2	Validação cruzada:.....	30
6.3	Tempo de execução	32
7	DISCUSSÃO.....	34
8	CONCLUSÃO	35
9	TRABALHOS FUTUROS.....	35
10	REFERÊNCIAS	36
11	APÊNDICE A – REPOSITÓRIO GITHUB COM O CÓDIGO DESENVOLVIDO....	38

1 INTRODUÇÃO

Amputação é o termo utilizado para caracterizar a retirada total ou parcial de um membro, sendo um método para o tratamento de diversas doenças. A amputação deve ser considerada dentro de um contexto geral de tratamento, cujo objetivo é melhorar a qualidade de vida do paciente (Ministério da Saúde, 2013).

Os níveis de amputação podem ser divididos em amputação dos membros superiores e inferiores e, essas classes, podem ser subdivididas em seis níveis de amputação do membro superior (Desarticulação de ombro, Amputação transumeral, Desarticulação de cotovelo, Amputação transradial, Desarticulação do punho e Desarticulação parcial de mão) e seis níveis nos membros inferiores (Hemipelvectomia, Desarticulação de quadril, Amputação transfemoral, Desarticulação de joelho, Amputação transtibial e Amputação de pé) (CONFORPES).

Para a substituição do membro amputado e possível reabilitação das capacidades funcionais do mesmo, é utilizado um aparato chamado prótese, que consiste em um dispositivo acoplado ao corpo para substituir a ausência de uma parte do mesmo. Uma prótese deve ser prescrita de acordo com a avaliação da condição clínica, do nível de atividade prévia além da expectativa estética do paciente acometido pela amputação (CASTANEDA, 2021).

As próteses de membro superior, tema deste trabalho, são classificadas de acordo com sua funcionalidade, confecção e tipo de funcionamento. Aquelas que exercem papel puramente estético, classificadas como sendo próteses estéticas ou passivas, são próteses que não priorizam a função do movimento e são usadas em qualquer nível de amputação. Próteses empregadas na restauração das capacidades funcionais do membro são classificadas em três tipos: ativa, mioelétrica e híbrida, conforme será visto a seguir:

- **Próteses Ativas:** São caracterizadas como dispositivos acionados pelo próprio paciente por meio da tração de tirantes, tendo seu movimento iniciado pela musculatura do coto e da articulação. Esses dispositivos são recomendados para todos os níveis de amputação (CASTANEDA, 2021).
- **Próteses Mioelétricas:** A movimentação desses dispositivos é ativada de forma eletrônica, sendo alimentada por uma fonte de energia externa e comandada por um sistema composto de eletrodos fixados a pele, que detectam a atividade elétrica muscular devido a contração da musculatura remanescente do coto e os envia para um microcontrolador que associa tal atividade com o comando a ser efetuado pela prótese. É recomendada para todos os níveis de amputação de membros superiores, sendo que nesse cenário o paciente deve ter controle da contração muscular do coto (CASTANEDA, 2021).
- **Próteses Híbridas:** Esses dispositivos consistem em um sistema de controle ativo e mioelétrico, atuando em articulações distintas. Recomendados para a amputação acima do cotovelo, esses dispositivos contam com o acionamento da articulação do cotovelo via tirantes em conjunto com uma prótese mioelétrica (CASTANEDA, 2021).

A reabilitação dos pacientes acometidos por amputação de membro superior é dividida em quatro etapas, sendo inicialmente composta pelos cuidados pós operatórios, seguidos pelo treinamento pré-prótese, o treinamento protético básico e o treinamento avançado de habilidades funcionais (CASTANEDA, 2021).

As próteses, idealmente, devem compensar o membro perdido em todos os aspectos, porém o mesmo não ocorre e esses dispositivos ainda são acometidos por vários problemas. Segundo os pesquisadores russos Unanyan e Belov, as próteses de membros superiores necessitam de melhorias na usabilidade e funcionalidade, redução do preço dos dispositivos, alta confiabilidade e alta velocidade de resposta ao estímulo recebido.

Para o desenvolvimento de dispositivos protéticos mioelétricos são utilizadas várias técnicas de processamento de sinal eletromiográfico (EMG), conforme o objetivo a ser alcançado. Alguns estudos tem como finalidade comparar metodologias e desenvolver novos métodos, que é o caso do estudo realizado na Universidade Federal do Espírito Santo (UFES), realizado por MAYOR et al, comparando vários autores e suas respectivas metodologias entre 2002 e 2015 e desenvolvendo o controle de alguns gestos.

Os principais meios matemáticos utilizados para a classificação de sinais EMG por esses autores são *Linear Discriminant Analysis* (LDA), *K-nearest neighbors* (KNN) e *multi-class support vector machine* (SVM) (MAYOR, 2017). Os maiores complicadores na utilização da maioria destes modelos matemáticos em próteses reais é o alto custo computacional e a necessidade de um hardware poderoso para que possam ser implementados.

Neste cenário, o classificador baseado em LDA se mostra vantajoso, uma vez que demanda baixa capacidade de hardware (CPU e memória), permitindo seu uso em sistemas embarcados como os utilizados para controle de próteses mioelétricas. No entanto, a eficácia do modelo LDA depende de diversos fatores, como, por exemplo, a quantidade de canais EMG utilizados e as características selecionadas para processamento da atividade mioelétrica.

2 OBJETIVO

Diante do exposto, o presente trabalho tem como objetivo desenvolver e avaliar um algoritmo para classificação de movimentos da mão baseado em sinais mioelétricos utilizando LDA, buscando verificar a quantidade de sítios (canais EMG) adequada para fornecer resultados satisfatórios, simplificando o treinamento do amputado e, ao mesmo tempo, mantendo a confiabilidade dos comandos executados com tempo de processamento adequado.

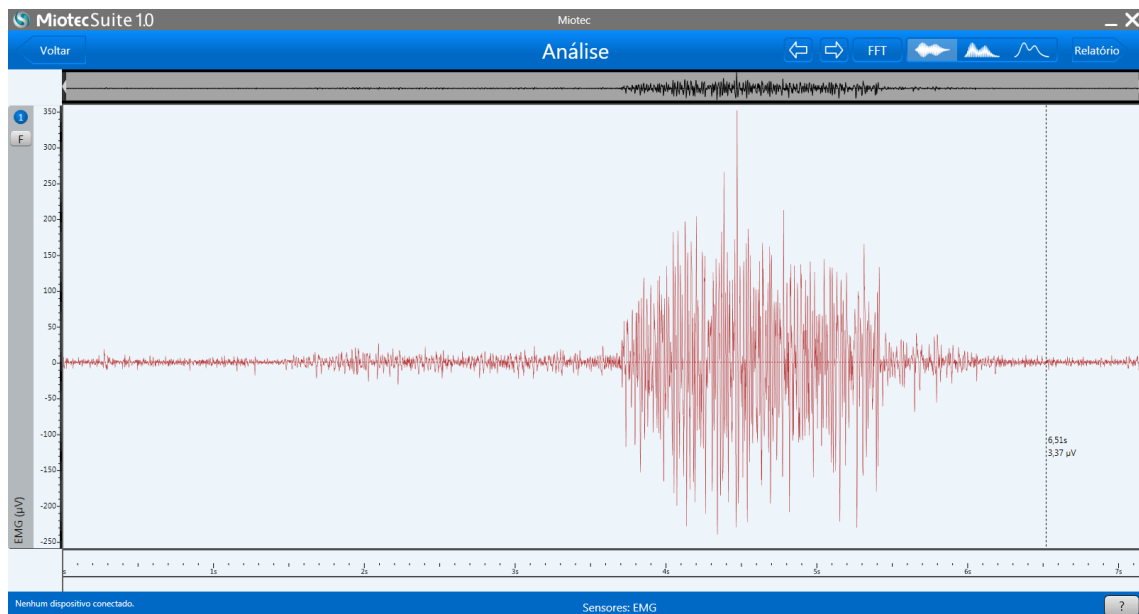
3 ELETROMIOGRAFIA

3.1 O sinal eletromiográfico (EMG)

O sinal EMG consiste em um sinal elétrico devido ao potencial de ação que percorre a fibra muscular. Em todas as células do corpo humano, praticamente, existem diferenças de potenciais entre suas membranas. Contudo, algumas células são excitáveis, sendo assim, geram impulsos elétricos e usam desses para a transmissão de sinais ao longo das membranas (BARROS, 2005).

Cada fibra muscular, como uma célula excitável, possui um potencial de ação. O potencial de ação consiste em impulsos elétricos que são provenientes da despolarização da membrana celular, onde ocorre momentaneamente a inversão de polaridade. Tais impulsos viajam por toda a membrana celular, propagando um potencial de ação. A soma dos potenciais de ação vistos por meio de um conjunto de eletrodos posicionados sobre a pele, acima de um músculo, ou de forma intramuscular, corresponde ao sinal EMG.

Figura 1 - Sinal EMG.



Fonte: MIOTEC

3.2 Aquisição e pré-processamento de sinais EMG

O sinal EMG pode ser adquirido por dois meios: de forma intramuscular e na superfície da pele. A aquisição intramuscular é usada, geralmente, quando o sinal a ser analisado provém de um músculo muito pequeno e superficial, onde os eletrodos posicionados acima da pele não são tão eficientes.

A aquisição de sinais por meio de eletrodos na superfície da pele deve considerar o músculo a ser analisado para a definição do tipo de eletrodo a ser usado. Os eletrodos superficiais não invasivos são divididos entre eletrodos passivos e ativos.

- **Eletrodos passivos:** Geralmente são compostos por Ag/AgCl e são utilizados em conjunto com um gel ou pasta condutora para reduzir a impedância entre a interface eletrodo-pele. Esses eletrodos apresentam várias limitações, dentre elas o ruído devido aos cabos que ligam esses eletrodos ao sistema de pré amplificação.

Figura 2 - Eletrodos passivos.



Fonte: Google imagens

- **Eletrodos ativos:** Esses eletrodos são aqueles que possuem o sistema de pré amplificação embutido neles. Apresentam boa imunidade a ruídos, pois não existe a conexão por cabos entre o eletrodo posicionado e o sistema de pré amplificação. Os eletrodos ativos são subdivididos em duas principais categorias, os eletrodos bipolar/diferencial e os eletrodos duplo diferencial.
- **Eletrodos Bipolares/Diferenciais:** Nessa configuração o sinal é captado a partir da subtração dos sinais provenientes de dois eletrodos. Apresenta a vantagem de eliminar boa parte do sinal em modo comum, que é aquele comum aos dois eletrodos.

Figura 3 - Sensor EMG simples diferencial.



Fonte: Google imagens

- **Eletrodos duplo diferencial:** Utiliza três eletrodos de captação (I, II e III) e um de referência. Três diferenciações são realizadas, sendo a primeira e a segunda entre os pares de eletrodos (I e II, II e III) e a terceira entre o sinal resultante das outras duas.

Figura 4 - Sensor EMG duplo diferencial.



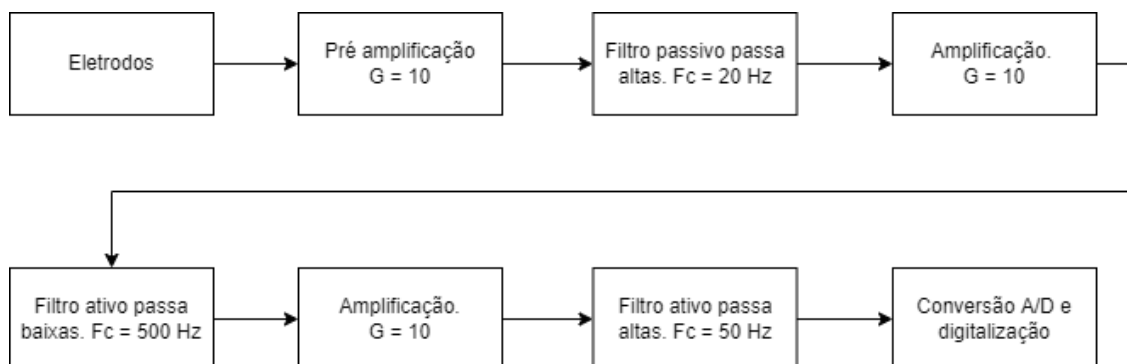
Fonte: Google imagens

Após a pré-amplificação, é realizada a amplificação e filtragem por meio de hardware, sendo que a mesma é realizada por meio de associação de filtros analógicos e amplificadores. A topologia de filtros mais utilizada na aquisição de sinais EMG é a Butterworth, sendo utilizados filtros com ordem superior a 2. Filtros passa-baixas associados com filtros passa-alta formam um filtro passa-banda, que limita o sinal dentro dos limites de frequência estabelecidos.

Sinais EMG possuem amplitude que varia de 0 a 10 mV (pico a pico), sendo assim é necessária à amplificação a níveis legíveis pelo sistema microcontrolado. Geralmente a amplificação é dividida em etapas, sendo a pré amplificação com ganho máximo usualmente em 20 V/V. Após isso, outras etapas são empregadas, fazendo com que a amplitude do sinal chegue na faixa que possibilite a melhor leitura do sinal pelo sistema.

Após o hardware analógico, o sinal é discretizado via conversão analógico-digital e enviado para o microcontrolador. Pode ser necessária a filtragem digital do sinal e, a mesma é feita por meio da convolução dos valores de entrada com os coeficientes do filtro a ser empregado.

Figura 5 - Diagrama de blocos de um sistema para aquisição de sinais EMG.



Fonte: Autoria própria

3.3 Características do sinal EMG

Algumas características são analisadas no sinal EMG, que podem ser usadas para a identificação de anomalias ou o controle de sistemas eletrônicos. Pode-se dividir essas características em duas classes, as características no domínio do tempo e da frequência.

As principais características utilizadas no domínio do tempo para classificações e detecção de anomalias no sinal EMG são as médias de valor absoluto (MAV), o valor absoluto do sinal (RMS), a quantidade de cruzamentos por zero do sinal, a variância e o desvio padrão e a envoltória do sinal.

- **MAV (Média de valor absoluto):** Para a obtenção dessa característica é necessário analisar um trecho de sinal EMG. O emprego dessa metodologia é feito por meio do janelamento do sinal, onde o mesmo é subdividido em partes menores por meio de janelas de tempo com quantidade de pontos definida. A MAV pode ser calculada da seguinte forma:

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i|$$

- **RMS (Root Mean Square):** Consiste na raiz quadrada da potência média do sinal EMG para determinada janela de tempo. Tal valor pode ser usado para identificar a quantidade de picos do sinal, sendo esses os valores cuja amplitude é maior do que o valor RMS.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i|^2}$$

- **Desvio padrão (STD):** Corresponde a diferença entre cada amostra do sinal e a média da janela de tempo empregada.

$$STD = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2}$$

- **Variância (VAR):** Provém a potência do sinal EMG no domínio do tempo e auxilia na identificação da diferença entre a musculatura relaxada e contraída.

$$VAR = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2$$

- **Cruzamentos por zero (ZC):** Essa característica mostra a quantidade de vezes que há a inversão do sinal, sendo definida pela quantidade de vezes que há a passagem por zero.

$$ZC = \sum_{i=1}^N \text{sgn}(-x_i * x_{i-1})$$

$$\text{sgn}(x) = \begin{cases} 1, & \text{se } x > 0 \\ 0, & \text{em outros casos} \end{cases}$$

- **Comprimento da onda (WL):** Essa métrica provém informações acerca da complexidade do sinal, por meio da soma das derivadas da janela de amostra.

$$WL = \sum_{i=1}^N (|x_i - x_{i-1}|)$$

Além das características citadas, existem as características no domínio da frequência, que correspondem a aquelas obtidas por meio da transformada rápida de Fourier (FFT). O espectro de frequências do sinal EMG de superfície está situado entre 0 e 1000 Hz, porém a maior parte da potência espectral está situada entre 50 Hz e 500 Hz. Para a análise espectral do sinal EMG é necessária a filtragem do mesmo, pois os ruídos provenientes do meio externo e de artefatos de movimento alteram o resultado verdadeiro de tal caracterização. As métricas mais utilizadas nessa análise são:

- **Frequência média (MNF):** É a frequência média do sinal analisado. O cálculo é realizado por meio da potência do sinal, onde o mesmo pondera a média.

$$MNF = \frac{\sum_{j=1}^M (f_j * p_j)}{\sum_{j=1}^M (p_j)}$$

- **Frequência mediana (MF):** Corresponde a frequência que divide o espectro de potência do sinal EMG ao meio.

$$MF = \frac{\sum_{j=1}^M (p_j)}{2}$$

- **Frequência de pico (PKF):** Define-se como a frequência onde a há a máxima potência do sinal no espectro de frequências.

4 ESTRATÉGIAS DE APRENDIZADO DE MÁQUINA SUPERVISIONADO

Nesse tópico serão apresentados conceitos acerca dos principais mecanismos de aprendizado supervisionado empregados no controle de próteses mioelétricas.

O aprendizado supervisionado é empregado quando se tem o padrão esperado de saída esperada para a entrada recebida e é utilizado na etapa de classificação do sinal EMG, onde são extraídas informações acerca da tomada de decisão baseada no sinal.

O primeiro dispositivo de aprendizado supervisionado são as redes neurais artificiais, que segundo a IBM são “*um subconjunto do aprendizado de máquina e estão no núcleo dos algoritmos de deep learning*”. (IBM, 2020)

As redes neurais são inspiradas no cérebro humano, imitando a interação entre neurônios. Compostas por camadas, essas podem ser subdivididas em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, ambas essas formadas por neurônios.

Cada nó da rede neural é composto por um neurônio e o mesmo funciona de acordo com a seguinte premissa: Um sinal é enviado a entrada do neurônio, onde o mesmo pode ser composto por uma ou mais entradas. Esse sinal é multiplicado por um número (peso) e suas entradas são somadas, produzindo um nível de atividade. Caso esse nível de atividade exceda um certo limiar (threshold), o sistema produz uma determinada resposta na saída, podendo essa ser zero ou um. (ICMC-USP)

O neurônio pode ser equacionado da seguinte forma:

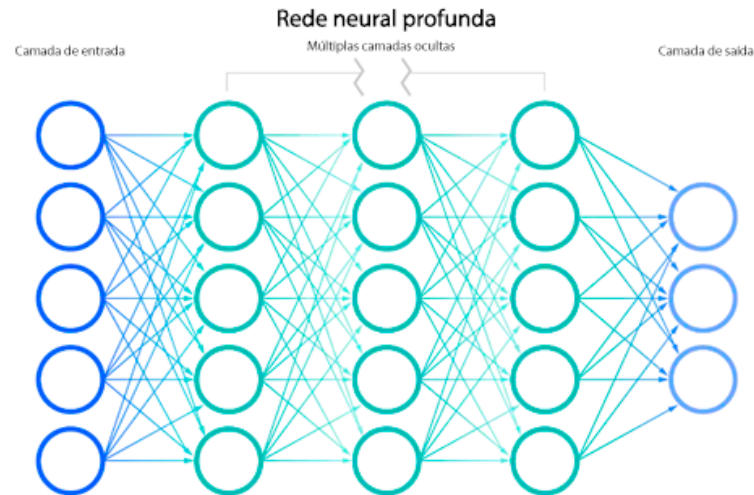
$$a = w_1 * x_1 + w_2 * x_2 + w_3 * x_3 \dots + w_n * x_n$$

$$\begin{cases} y = 1, se a \geq t \\ y = 0, se a < t \end{cases}$$

onde w são os pesos, x são as entradas do neurônio, t é o limiar de ativação do neurônio e y é a saída.

Com a junção de todas essas subunidades (neurônios), se formam as camadas das redes neurais artificiais. A saída de um neurônio é conectada a entrada de outro, possibilitando o aprendizado de padrões por meio de exemplos. A seguir podemos ver a arquitetura de uma rede neural artificial:

Figura 6 – Modelo genérico de uma Rede Neural Artificial.



Fonte: IBM (Modificado)


O treinamento de uma rede neural consiste em ajustar seus pesos e os limiares de ativação de cada neurônio, que é o ponto onde há a mudança de resposta de cada neurônio, de acordo com a base de dados fornecida. Um dos algoritmos utilizados no treinamento de uma rede neural é o *backpropagation*.

O algoritmo de *backpropagation* consiste em algumas etapas, sendo a primeira delas definir a topologia da rede neural. Após isso se inicia a fase de *forward*, onde se define a saída da rede neural de acordo com os padrões de entrada. Esse algoritmo consiste em comparar a saída da rede neural com o que se é esperado, estabelecendo um erro e o propagando nó a nó. Com o valor do erro desejado na saída, realiza-se o ajuste dos pesos da rede neural na fase *backward* para que o mesmo seja atingido. Os pesos são ajustados de acordo com uma taxa, chamada de taxa de aprendizagem. Algumas técnicas de otimização numérica são utilizadas para reduzir o tempo de convergência de uma rede neural, tais como a do gradiente descendente (BARCA et al,2005).

Além das redes neurais artificiais, máquinas de vetores de suporte (SVM) são utilizadas na classificação de sinais EMG. Uma SVM consiste em um algoritmo de aprendizado supervisionado que pode ser usado tanto em problemas de classificação quanto de regressão, porém são mais utilizados em problemas de classificação.

As SVM's realizam a classificação utilizando a separação linear do conjunto de dados em hiperplanos. Pontos são plotados no plano ou no espaço e o melhor hiperplano ou reta que separa os conjuntos de dados é alcançado no processo de classificação. No caso de um conjunto de dados bidimensional, com coordenadas x e y , são separados por meio de uma reta. Abaixo segue uma figura que exemplifica a aplicação das SVM's:

Figura 7 - Exemplo de Hiperplanos SVM.



Fonte: Analytics Vidhya

Sejam y_1 e y_2 os hiperplanos que separam o conjunto de dados. Sendo assim, sabe-se que


$$\begin{cases} w * xi + b \geq 1, \text{ sendo } y_1 = 1 \\ w * xi + b \leq -1, \text{ sendo } y_2 = -1 \end{cases}$$

Como o algoritmo das SVM realizam a separação linear, é necessária a transformação de dados não separáveis linearmente para que os mesmos possam ser separados pelo algoritmo. Para isso, se utiliza do mapeamento dos dados a um espaço dimensional superior. Tal operação é realizada por meio da mudança de variáveis e coordenadas, vide o exemplo abaixo:

Figura 8 - Mudança de coordenadas nas SVMs não lineares.

SVM Não-Linear

- O espaço de atributos original pode ser mapeado em um espaço de atributos de dimensão maior onde o conjunto de treinamento é linearmente separável:



Fonte: Edirlei Lima.

Outro método bastante utilizado no aprendizado supervisionado é o algoritmo K-NN (*K-nearest neighbors*), que utiliza a distância entre pontos no plano para realizar classificações.

Esse algoritmo pode ser usado tanto em problemas de classificação, quanto em regressão, assumindo que pontos similares se encontram próximos um ao outro (IBM).

As distâncias são calculadas seguindo alguma métrica matemática, como a distância Euclidiana. Porém outras distâncias podem ser utilizadas, como a distância Manhattan e Minkowski. No uso de dados booleanos ou textuais (strings), utiliza-se a distância Hamming. (IBM)

A distância Euclidiana é calculada de acordo com a seguinte equação:

$$d = \sqrt{x^2 + y^2}$$

A realização da classificação no algoritmo K-NN é feita através do parâmetro k , que determina a quantidade de vizinhos a serem checados para determinar certo ponto. A quantidade de vizinhos determina a variância e o nível de tendência da predição, sendo que quanto maior o número de vizinhos, maior a tendência e menor a variância. O valor de k define se ocorrerá *overfitting* ou *underfitting*:


- **Overfitting:** Esse cenário ocorre quando o algoritmo literalmente decora o que deveria ser feito, tendo um funcionamento excelente com a base de dados de treino, porém não tem um bom desempenho com os dados de teste.
- **Underfitting:** Nesse caso ocorre o oposto, sendo que o modelo apresenta desempenho ruim no treinamento. O modelo não encontra relação entre as variáveis, devendo o mesmo ser descartado.

Outro método de aprendizado supervisionado é o *Linear Discriminant Analysis* (LDA), que é uma ferramenta muito utilizada na redução de dimensionalidade. O algoritmo LDA consiste em reduzir a dimensionalidade do conjunto de dados, de forma a maximizar a variância e encontrar um eixo que maximize a separação entre múltiplas classes. LDA é uma generalização do discriminante linear de Fisher, que é um método utilizado para encontrar uma combinação linear que faz a separação de duas ou mais classes.

Figura 9 - Exemplo LDA.

LDA:

Maximizando os componentes dos eixos para a separação de classes



Fonte: Google imagens

Para aplicação do LDA, busca-se uma matriz de projeção \mathbf{W} , que leva o conjunto de dados para um novo sistema de coordenadas, onde há a maior separabilidade entre classes, ou seja, a distância entre as médias de cada classe é maximizada por meio do aumento da dispersão entre classes (\mathbf{S}_b) e a dispersão dentro das classes é minimizada (\mathbf{S}_w). Sendo assim, o algoritmo pode ser empregado pelos seguintes passos:

$$S_b = \sum_{i=1}^C N_i (\mu_i - \mu) (\mu_i - \mu)^T$$

$$S_w = \sum_{i=1}^C \sum_{j=1}^{N_i} N_i (x_j - \mu_i) (x_j - \mu_i)^T$$

Onde, C é o número da classe, N_i é o número de amostras da classe, μ é a média geral de todas as classes, μ_i é a média de cada classe e x_j se refere ao vetor de características para cada amostra da classe. A matriz W pode ser obtida da seguinte forma:

$$j(W) = \frac{\det(W^T S_b W)}{\det(W^T S_w W)}$$

Então a matriz de características original é projetada da seguinte forma, maximizando a separação entre os clusters:

$$y = W^T x$$

5 MATERIAIS E MÉTODOS

5.1 Materiais utilizados

Para a execução do presente trabalho foram utilizados dados de uma base aberta na internet (physionet.org/ -- <https://doi.org/10.13026/dzhr-nj10>), contendo sinais EMG de alta definição (HD-sEMG), com 256 canais. Os dados foram coletados de 20 voluntários com os dedos intactos, sendo 12 homens e 8 mulheres, todos na faixa de idade entre os 22 e 34 anos. Na tabela abaixo são apresentados os dados de cada participante e da coleta dos mesmos.

Tabela 1 – Dados dos voluntários e intervalos entre sessões de coleta.

Sujeito	Idade (anos)	Gênero	Altura (cm)	Peso(kg)	Intervalo entre sessões de coleta (dias)
1	32	Masculino	173	78	7
2	24	Masculino	170	71	7
3	22	Masculino	177	59	3
4	21	Masculino	175	75	4
5	22	Masculino	191	95	5
6	22	Feminino	162	50	3
7	22	Feminino	168	60	5
8	26	Masculino	168	61	17
9	30	Masculino	175	80	4
10	30	Masculino	175	80	18
11	26	Feminino	170	56	25
12	22	Feminino	158	52	10
13	23	Masculino	183	86	8
14	29	Feminino	158	50	4
15	32	Masculino	178	75	11
16	34	Masculino	170	87,5	22
17	23	Feminino	158	47	4
18	27	Feminino	160	55	7
19	31	Feminino	165	53	3
20	33	Masculino	174	70	3

Fonte: (JIANG et al, 2021)

Foram coletados sinais EMG da musculatura do antebraço e do punho, durante a realização de 34 tarefas dinâmicas de movimentos da mão e dos dedos, com um segundo de duração cada, bem como de persistência, onde o movimento foi realizado e mantido por 4 segundos.


O *dataset* em questão contém outros dados coletados pelos autores, como amostras de sensores de força colocados nos dedos dos participantes, não utilizados neste trabalho. Para execução deste trabalho, optou-se pelo uso dos dados brutos associados apenas às tarefas dinâmicas, pois o objetivo do presente trabalho é propor uma estratégia que se adeque ao controle em tempo real de próteses mioelétricas.

Para o pré-processamento dos dados, aquisição das características, classificação, predição e avaliação do modelo se utiliza das ferramentas presentes na linguagem de programação Python, por ser uma linguagem de programação e possibilitar o uso futuro desse algoritmo em outras aplicações.

5.2 Metodologia

O foco do presente trabalho são as etapas de pré-processamento, obtenção de características e classificação de movimentos utilizando sinais EMG. Considerando o esquema visto abaixo de um sistema de controle de próteses eletromiográficas, as etapas de coleta do sinal, filtragem e amplificação e ação de controle da prótese não serão tratados no exposto. Contudo, essas etapas são importantes quando se trata do controle em tempo real de próteses mioelétricas de membros superiores, podendo contribuir negativamente caso tais passos sejam negligenciados.

Figura 10 - Esquema de um sistema de controle de próteses mioelétricas.



Fonte: Autoria própria.

Finalizadas as etapas de coleta, filtragem analógica e amplificação do sinal EMG, pode-se proceder a etapa de pré-processamento.

O pré-processamento dos sinais EMG no controle de próteses mioelétricas em tempo real pode ser dividido em duas etapas, sendo elas:

- Aplicação de um filtro passa-banda digital composto por um filtro passa-altas com frequência de corte em 20 Hz e um filtro passa-baixas com frequência de corte em 500 Hz, mantendo a região do sinal com maior energia.
- Aplicação de um filtro rejeita-faixa em 50 Hz ou 60 Hz, dependendo da frequência em que opera a rede elétrica do local da coleta.

Na etapa de pré-processamento os primeiros 0,25 s de cada amostra foram removidos, conforme foi feito pelo autor do *dataset* no artigo que define os dados, em seguida foi aplicado um filtro passa-banda Butterworth de décima ordem com frequência de corte inferior igual a 20 Hz e frequência de corte superior igual a 500 Hz, em seguida aplicou-se um filtro Notch configurado em 50 Hz e fator de qualidade igual a 30.


Para a classificação de movimentos utilizando sinais EMG é necessária a extração de características dos sinais que serão inseridas no classificador, sendo essa a próxima etapa após o pré-processamento. Nessa etapa foram escolhidas as seguintes características:

- Valor RMS;
- Valor do comprimento de onda (WL);
- Taxa de cruzamento por zeros (ZCR);
- Variância (VAR);

Todas as características escolhidas estão no domínio do tempo, porém algumas apresentam maior variação conforme a frequência, como a taxa de cruzamentos por zero, que representa a soma de todos os cruzamentos por zero em um intervalo e aumenta ou diminui conforme a frequência do sinal. Todos os sinais foram janelados em janelas de 150 ms com sobreposição de 75 ms e todas as características foram calculadas para cada janela.

O posicionamento dos eletrodos é importante quando se trata do reconhecimento de padrões, pois os mesmos devem captar sinais distintos para que as características sejam distintas e permitam distinguir os movimentos realizados. Como um dos objetivos a serem alcançados é a descoberta da quantidade mínima de eletrodos necessária para a correta classificação de movimentos, optou-se por realizar a coleta de sinais provenientes de eletrodos alinhados em forma de bracelete, conforme a imagem a seguir:

Figura 11 - Arrays de eletrodos utilizados para captura dos sinais EMG.




Fonte: (JIANG et al, 2021)

A localização dos eletrodos utilizados neste trabalho está mostrada pela linha verde na figura, sendo o canal 1 do *dataset* preparado o primeiro eletrodo do *array* 2, da direita para a esquerda, e o canal 16 o último eletrodo do *array* 4, da direita para a esquerda. Foram utilizadas quatro configurações desses eletrodos, sempre dividindo a quantidade de eletrodos por 2 a cada nova configuração, retirando o primeiro eletrodo, mantendo o segundo, retirando o terceiro, assim sucessivamente de forma que os últimos dois eletrodos estejam separados 180 graus entre si.

Por fim, foram escolhidos quatro movimentos para classificação, de acordo com tarefas cotidianas como pentear o cabelo, escovar os dentes, segurar algumas coisas, comer, apontar para algo ou utilizar o dedo indicador em alguma tarefa como apertar o botão de um elevador e segurar algum objeto utilizando apenas o polegar e o indicador para realizar alguma tarefa. Para isso, escolheu-se os movimentos de extensão do polegar e do dedo indicador (12), extensão dos dedos médio, anelar e mínimo (28), fechamento da mão (30) e abertura da mão (31).

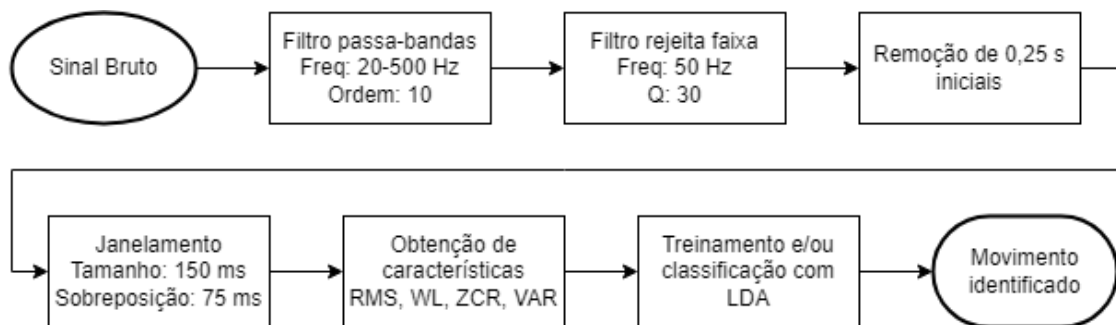
Figura 12 - Movimentos da mão realizados pelos voluntários.



Fonte: (JIANG et al, 2021)

O sistema de pré processamento do sinal e classificação do movimento pode ser descrito de acordo com o diagrama de blocos a seguir:

Figura 13 - Diagrama de funcionamento do sistema



Fonte: Autoria própria

5.3 Métricas para avaliação da performance do modelo

Para a avaliação do modelo utilizou-se de duas técnicas clássicas, a acurácia que representa a relação entre a quantidade de valores previstos corretamente e a quantidade de previsões totais e a validação cruzada, que consiste em dividir a base de dados de k formas aleatórias, com aproximadamente a mesma quantidade de amostra e utilizar uma para teste e o

restante para treinamento do modelo. O modelo de validação cruzada é utilizado para avaliar se há a presença de *overfitting*, que é quando o modelo “memoriza” a base de dados em vez de generalizar o aprendizado. Para a avaliação da acurácia, o conjunto de dados foi separado seguindo o esquema 80/20, com 80% dos dados para treinamento e 20% para teste/validação.

6 RESULTADOS E DISCUSSÕES

6.1 Acurácia

Para a avaliação da acurácia do modelo, foi obtida a acurácia de cada sujeito em cada uma das duas sessões de coleta e, após isso, obtida a acurácia média de cada sujeito e a média geral de todas as acurácias para cada configuração de eletrodos, conforme as tabelas a seguir:

- **16 canais:**

Tabela 2 - Acurácia média para cada sujeito utilizando os 16 canais.

Sujeito	Acurácia_sessão1	Acurácia_sessão2	Acurácia_média
Sujeito 1	97.87	97.87	97.87
Sujeito 2	100	100	100
Sujeito 3	97.87	97.87	97.87
Sujeito 4	100	95.74	97.87
Sujeito 5	95.74	100	97.87
Sujeito 6	91.49	93.62	92.55
Sujeito 7	100	100	100
Sujeito 8	97.87	97.87	97.87
Sujeito 9	100	100	100
Sujeito 10	95.74	97.87	96.81
Sujeito 11	100	100	100
Sujeito 12	97.87	85.11	91.49
Sujeito 13	100	97.87	98.94
Sujeito 14	95.74	93.62	94.68
Sujeito 15	97.87	97.87	97.87
Sujeito 16	80.85	97.87	89.36
Sujeito 17	100	100	100
Sujeito 18	93.62	100	96.81
Sujeito 19	100	97.87	98.94
Sujeito 20	93.62	97.87	95.74
Média	96.81	97.45	97.13

Fonte: Autoria própria

- **8 canais:**

Tabela 3 – Acurácia média para cada sujeito utilizando 8 canais.

Sujeito	Acurácia_sessão1	Acurácia_sessão2	Acurácia_média
Sujeito 1	100	95.74	97.87
Sujeito 2	95.74	97.87	96.81
Sujeito 3	93.62	100	96.81
Sujeito 4	100	95.74	97.87
Sujeito 5	97.87	97.87	97.87
Sujeito 6	95.74	80.85	88.3
Sujeito 7	97.87	97.87	97.87

Sujeito 8	93.62	97.87	95.74
Sujeito 9	100	97.87	98.94
Sujeito 10	95.74	100	97.87
Sujeito 11	95.74	97.87	96.81
Sujeito 12	87.23	93.62	90.43
Sujeito 13	100	93.62	96.81
Sujeito 14	91.49	91.49	91.49
Sujeito 15	100	95.74	97.87
Sujeito 16	76.6	85.11	80.85
Sujeito 17	100	97.87	98.94
Sujeito 18	91.49	100	95.74
Sujeito 19	97.87	93.62	95.74
Sujeito 20	89.36	93.62	91.49
Média	95	95.21	95.11

Fonte: Aatoria própria

○ **4 canais:**

Tabela 4 – Acurácia média para cada sujeito utilizando 4 canais.

Sujeito	Acurácia_sessao1	Acurácia_sessao2	Acurácia_media
Sujeito 1	91.49	95.74	93.62
Sujeito 2	95.74	93.62	94.68
Sujeito 3	72.34	95.74	84.04
Sujeito 4	100	85.11	92.55
Sujeito 5	93.62	95.74	94.68
Sujeito 6	91.49	85.11	88.3
Sujeito 7	89.36	97.87	93.62
Sujeito 8	95.74	87.23	91.49
Sujeito 9	97.87	91.49	94.68
Sujeito 10	85.11	95.74	90.43
Sujeito 11	89.36	95.74	92.55
Sujeito 12	91.49	74.47	82.98
Sujeito 13	97.87	87.23	92.55
Sujeito 14	100	80.85	90.43
Sujeito 15	95.74	82.98	89.36
Sujeito 16	78.72	80.85	79.79
Sujeito 17	100	87.23	93.62
Sujeito 18	91.49	91.49	91.49
Sujeito 19	91.49	85.11	88.3
Sujeito 20	87.23	80.85	84.04
Média	91.81	88.51	90.16

Fonte: Aatoria própria

○ **2 canais:**


Tabela 5 – Acurácia média para cada sujeito utilizando 2 canais.

Sujeito	Acurácia_sessao1	Acurácia_sessao2	Acurácia_média
Sujeito 1	82.98	82.98	82.98
Sujeito 2	91.49	82.98	87.23
Sujeito 3	65.96	72.34	69.15
Sujeito 4	100	78.72	89.36
Sujeito 5	85.11	87.23	86.17
Sujeito 6	93.62	80.85	87.23
Sujeito 7	85.11	80.85	82.98
Sujeito 8	78.72	72.34	75.53
Sujeito 9	97.87	82.98	90.43
Sujeito 10	80.85	91.49	86.17
Sujeito 11	82.98	87.23	85.11
Sujeito 12	87.23	68.09	77.66
Sujeito 13	97.87	100	98.94
Sujeito 14	82.98	85.11	84.04
Sujeito 15	82.98	87.23	85.11
Sujeito 16	65.96	82.98	74.47
Sujeito 17	87.23	95.74	91.49
Sujeito 18	80.85	80.85	80.85
Sujeito 19	87.23	89.36	88.3
Sujeito 20	78.72	68.09	73.4
Média	84.79	82.87	83.83

Fonte: Autoria própria

A Figura 13, consolida os resultados médios de acurácia para diferentes quantidades de eletrodos.

Figura 14 - Gráfico de acurácia do modelo treinado para diferentes quantidades de eletrodos.



Fonte: Autoria própria

6.2 Validação cruzada:

Para validação cruzada do modelo, o algoritmo foi configurado para separar os dados em cinco “*folds*”, representando 20% dos dados em cada um deles. Em seguida a validação cruzada foi separada em duas métricas: validação cruzada média e desvio padrão médio da validação cruzada para cada indivíduo.

- **16 canais:**

Tabela 6 – Validação cruzada de 16 canais

Sujeito	crossval_medio	crossval_std_medio
Sujeito 1	96.15	3.75
Sujeito 2	93.125	6.26
Sujeito 3	93.54	5.435
Sujeito 4	93.31	2.825
Sujeito 5	95.915	2.555
Sujeito 6	93.315	3.62
Sujeito 7	97.015	4.02
Sujeito 8	95.055	4.335
Sujeito 9	95.93	3.605
Sujeito 10	95.465	4.06
Sujeito 11	95.49	3.415
Sujeito 12	89.49	6.96
Sujeito 13	94.84	4.58
Sujeito 14	94.615	3.4
Sujeito 15	97.215	4.06
Sujeito 16	84.73	7.9
Sujeito 17	99.565	0.53
Sujeito 18	94.84	3.53
Sujeito 19	96.13	2.81
Sujeito 20	89.265	6.825
Média	94.25	4.225

Fonte: Autoria própria

- **8 canais:**

Tabela 7 – Validação cruzada de 8 canais

Sujeito	crossval_medio	crossval_std_medio
Sujeito 1	95.715	4.16
Sujeito 2	94.86	5.535
Sujeito 3	90.315	4.725
Sujeito 4	92.47	1.95
Sujeito 5	96.995	1.89
Sujeito 6	89.885	5.18
Sujeito 7	96.37	4.66
Sujeito 8	91.185	6.045
Sujeito 9	95.07	3.935
Sujeito 10	93.32	2.57

Sujeito 11	93.985	3.78
Sujeito 12	91.22	6.55
Sujeito 13	93.35	5.025
Sujeito 14	91.825	5.175
Sujeito 15	93.135	5.78
Sujeito 16	81.245	6.335
Sujeito 17	98.5	2.205
Sujeito 18	94.19	3.12
Sujeito 19	92.9	4.32
Sujeito 20	87.725	1.85
Média	92.715	4.24

Fonte: Autoria própria

○ **4 canais:**

Tabela 8 – Validação cruzada de 4 canais

Sujeito	crossval_medio	crossval_std_medio
Sujeito 1	93.555	4.465
Sujeito 2	87.995	7.435
Sujeito 3	80.235	8.955
Sujeito 4	91.36	3.46
Sujeito 5	93.325	3.465
Sujeito 6	88.585	4.805
Sujeito 7	89.45	4.195
Sujeito 8	86.645	7.665
Sujeito 9	93.54	2.365
Sujeito 10	89.87	5.05
Sujeito 11	90.555	6.44
Sujeito 12	85.19	8.38
Sujeito 13	93.31	1.63
Sujeito 14	87.075	4.32
Sujeito 15	88.165	6.675
Sujeito 16	77.8	5.315
Sujeito 17	95.295	3.6
Sujeito 18	87.065	4.57
Sujeito 19	87.535	6.17
Sujeito 20	81.465	4.885
Média	88.4	5.195

Fonte: Autoria própria

○ **2 canais:**

Tabela 9 – Validação cruzada de 2 canais

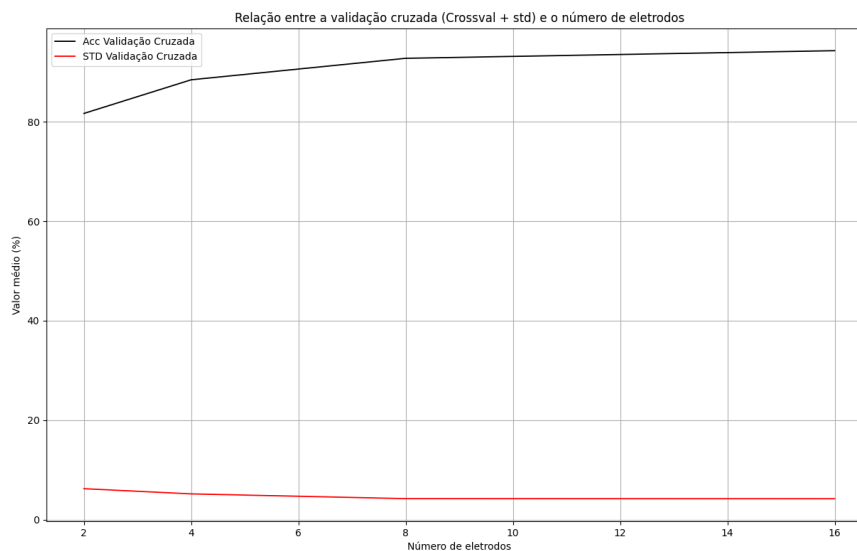
Sujeito	crossval_medio	crossval_std_medio
----------------	-----------------------	---------------------------

Sujeito 1	87.07	6.32
Sujeito 2	81.97	8.31
Sujeito 3	63.635	8.285
Sujeito 4	91.155	4.26
Sujeito 5	86.47	6.985
Sujeito 6	82.985	6.405
Sujeito 7	83.45	6.17
Sujeito 8	67.235	9.44
Sujeito 9	88.805	4.14
Sujeito 10	86.615	3.83
Sujeito 11	83.67	6.905
Sujeito 12	78.475	6.535
Sujeito 13	90.545	5.18
Sujeito 14	85.545	5.435
Sujeito 15	82.09	8.31
Sujeito 16	73.045	5.965
Sujeito 17	86.235	4.21
Sujeito 18	78.86	5.95
Sujeito 19	82.57	5.115
Sujeito 20	72.39	7.07
Média	81.64	6.24

Fonte: Autoria própria

A Figura 14, consolida os resultados médios de acurácia em validação cruzada para diferentes quantidades de eletrodos.

Figura 15 - Gráfico da validação cruzada.



Fonte: Autoria própria

6.3 Tempo de execução

O tempo de execução do algoritmo é uma métrica importante a ser avaliada para considerar o uso em predições em tempo real. A Tabela 10 mostra os tempos de execução para treinamento e classificação dos sinais EMG com diferentes quantidades de eletrodos e o tempo para se realizar uma única predição.

Tabela 10 - Tempos de execução de diferentes partes do algoritmo

Tarefa	Tempo de execução
Treinamento e classificação 16 eletrodos	1.3 s
Treinamento e classificação 8 eletrodos	0.9 s
Treinamento e classificação 4 eletrodos	0.9 s
Treinamento e classificação 2 eletrodos	0.8 s
Classificação por gesto 16 eletrodos	1 ms
Classificação por gesto 8 eletrodos	1 ms
Classificação por gesto 4 eletrodos	1 ms
Classificação por gesto 2 eletrodos	1 ms

Fonte: Autoria própria

Equipamento utilizado: Intel Core I7 1165G7 e 24 GB de memória ram.

7 DISCUSSÃO

Conforme visto nos gráficos e nas tabelas acima, percebe-se uma variação significativa na performance e nos tempos de execução ao se variar a quantidade de eletrodos, sendo menor a performance quanto menor for a quantidade de eletrodos. Para melhor aferir as variações destacadas nas tabelas, calculou-se o desvio padrão para cada quantidade de eletrodos, mostrando que ocorre o aumento do mesmo quando há a diminuição da quantidade de eletrodos. Essa variação ocorre, pois os grupos musculares envolvidos no movimento vão deixando de serem detectados à medida que o número de eletrodos diminui. Por esse motivo, é importante posicionar os mesmos acima do ventre muscular dos principais músculos envolvidos nos movimentos a serem classificados. No caso dos eletrodos dispostos em linha e na posição em que foi escolhida para esse trabalho, os resultados acima de 90% de acurácia são obtidos a partir de quatro eletrodos.

O algoritmo apresenta baixo tempo de execução, quando executado em um computador padrão (Intel Core I7 1165G7 e 24 GB de memória RAM). Contudo, o algoritmo foi escrito na linguagem de programação Python, que é interpretada, apresentando performance menor do que se fosse escrito em uma linguagem compilada, como a linguagem C.

8 CONCLUSÃO

Os experimentos realizados e os resultados obtidos permitem inferir que o algoritmo LDA apresenta boa performance quando utilizado em problemas de classificação de sinais EMG. O mesmo é de simples implementação, uma vez que, utiliza somente características no domínio do tempo. Desta forma, é uma boa alternativa para implementação de modelos de aprendizado de máquina para a classificação de movimentos em próteses mioelétricas em tempo real.

9 TRABALHOS FUTUROS

Determinada a viabilidade do modelo LDA como base para classificação de sinais mioelétricos, propõe-se os seguintes trabalhos para verificação de seu funcionamento em situações clínicas:

- a) Verificação da performance do modelo com usuários amputados, uma vez que os dados aqui utilizados foram coletados de voluntários não amputados;
- b) Implementação do modelo em um sistema embarcado dedicado para classificação de sinais EMG e controle de próteses de membros superiores;
- c) Testes e validação do modelo com usuários amputados.

10 REFERÊNCIAS

- BARCA, Maria Carolina Stockler; SILVEIRA, Tiago Redondo de Siqueira; MAGINI, Marcio. Treinamento de redes neurais artificiais: o algoritmo Backpropagation. IX Encontro Latino Americano de Iniciação Científica, V Encontro Latino Americano de Pós-Graduação – Universidade do Vale do Paraíba, Anais. Jacareí, 2005.
- BARROS, Kety Rosa de. Low computational power methodology for EMG classification for use in prosthesis control. 2005. 110 f. Dissertação (Mestrado em Engenharias) - Universidade Federal de Uberlândia, Uberlândia, 2005.
- Brasil. Ministério da Saúde. Secretaria de Atenção à Saúde. Departamento de Ações Programáticas Estratégicas. Diretrizes de atenção à pessoa amputada / Ministério da Saúde, Secretaria de Atenção à Saúde, Departamento de Ações Programáticas Estratégicas. 1. ed. 1. reimp. – Brasília: Ministério da Saúde, 2013.
- CARVALHO, André Ponce de Leon F. de. Redes Neurais Artificiais – ICMC – USP. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/#links> Acesso em: 07 de Junho de 2022
- CASTANEDA, Luciana. Próteses de membros superiores e inferiores: indicações e confecção. In: UNIVERSIDADE ABERTA DO SUS. UNIVERSIDADE FEDERAL DO MARANHÃO. Atenção à pessoa com deficiência I: transtornos do espectro do autismo, Síndrome de Down, pessoa idosa com deficiência, pessoa amputada e órteses, próteses e meios auxiliares de locomoção. Prescrição, Concessão, Adaptação e Manutenção de Órteses, Próteses e Meios Auxiliares de Locomoção. São Luís: UNA-SUS; UFMA, 2021.
- CONFORPES. “O que é nível de amputação”. Disponível em: <https://blog.conforges.com.br/dr-responde/o-que-e-nivel-de-amputacao/> Acesso em: 01 de Junho de 2022.
- IBM. Redes neurais. Disponível em: <https://www.ibm.com/br-pt/cloud/learn/neural-networks#:~:text=As%20redes%20neurais%2C%20tamb%C3%A9m%20conhecidas,dos%20algoritmos%20de%20deep%20learning.> Acesso em: 07/06/2022
- IBM. What is the k-nearest neighbors algorithm?. Disponível em: <https://www.ibm.com/topics/knn> Acesso em: 07 de Junho de 2022
- MAYOR, John Jairo Villarejo et al. Dexterous hand gestures recognition based on low-density sEMG signals for upper-limb forearm amputees. Res. Biomed. Eng., Rio de Janeiro, v. 33, n. 3, p. 202-217, Sept. 2017. Disponível em: http://old.scielo.br/scielo.php?script=sci_arttext&pid=S2446-47402017000300202&lng=en&nrm=iso. Acesso em: 01 de Junho de 2022. <https://doi.org/10.1590/2446-4740.08516>.
- SHAIKH, R. Cross Validation Explained: Evaluating estimator performance. Disponível em: <https://towardsdatascience.com/cross-validation-explained-evaluating-estimator-performance-e51e5430ff85> Acesso em 07/06/2022
- UNANYAN, Narek N. BELOV, Alexey A. Design of upper limb prosthesis using real-time motion detection method based on EMG signal processing. **Biomedical Signal Processing and**

Control, v. 70, 2021, 103062, ISSN 1746-8094. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1746809421006595>. Acesso em: 01 de Junho de 2022. <https://doi.org/10.1016/j.bspc.2021.103062>

WANG, Nianfeng. CHEN, Yulong. ZHANG Xianmin. The recognition of multi-finger prehensile postures using LDA. *Biomedical Signal Processing and Control*, v. 8, 2013, p 706-712.

X. JIANG et al., "Open Access Dataset, Toolbox and Benchmark Processing Results of High-Density Surface Electromyogram Recordings," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 29, pp. 1035-1046, 2021, doi: 10.1109/TNSRE.2021.3082551.

11 APÊNDICE A – REPOSITÓRIO GITHUB COM O CÓDIGO DESENVOLVIDO

<https://github.com/lazarod2311/CLASSIFICATION-OF-HAND-MOVEMENTS-BASED-ON-EMG-SIGNALS-AND-LDA-FOR-CONTROL-OF-ARTIFIC-LIMB-PROSTHESES>