



SHEIKAH ARM: PRÓTESE MIOELÉTRICA COM RECONHECIMENTO DE PADRÕES DE EMG POR APRENDIZADO DE MÁQUINA



Resumo

O presente trabalho tem como objetivo o desenvolvimento de um protótipo de prótese mioelétrica de mão desenvolvida em uma impressora 3D, cuja intenção do usuário seja detectada pela utilização de técnicas de aprendizado de máquina para o reconhecimento de padrões de sinais mioelétricos de superfície (sEMG).

O modelo tem como principais características: modelo de prótese *open source*, leitura dos sinais sEMG utilizando o Myo Armband, processamento dos sinais através de algoritmos de aprendizado de máquina utilizando a ferramenta *Classification Learner do Matlab*, sistema *microcontrolado* embarcado para comando dos servomotores do protótipo e execução dos movimentos desejados.

Os resultados dos experimentos online mostraram uma acurácia média de 90,8% considerando cinco movimentos distintos: mão aberta, mão fechada, extensão do dedo indicador, extensão do polegar e pinça. Os resultados mostraram-se promissores, principalmente levando-se em conta os diferenciais da comunicação wifi que confere maior liberdade de movimento ao usuário e as taxas de acurácia obtidas em experimento online.

Contextualização

A prótese de mão é uma necessidade vital para a sociedade, pois promove inclusão e qualidade de vida aos indivíduos amputados. Além de restaurar habilidades perdidas, proporciona autonomia, autoestima e igualdade de oportunidades, assegurando a participação plena na sociedade.

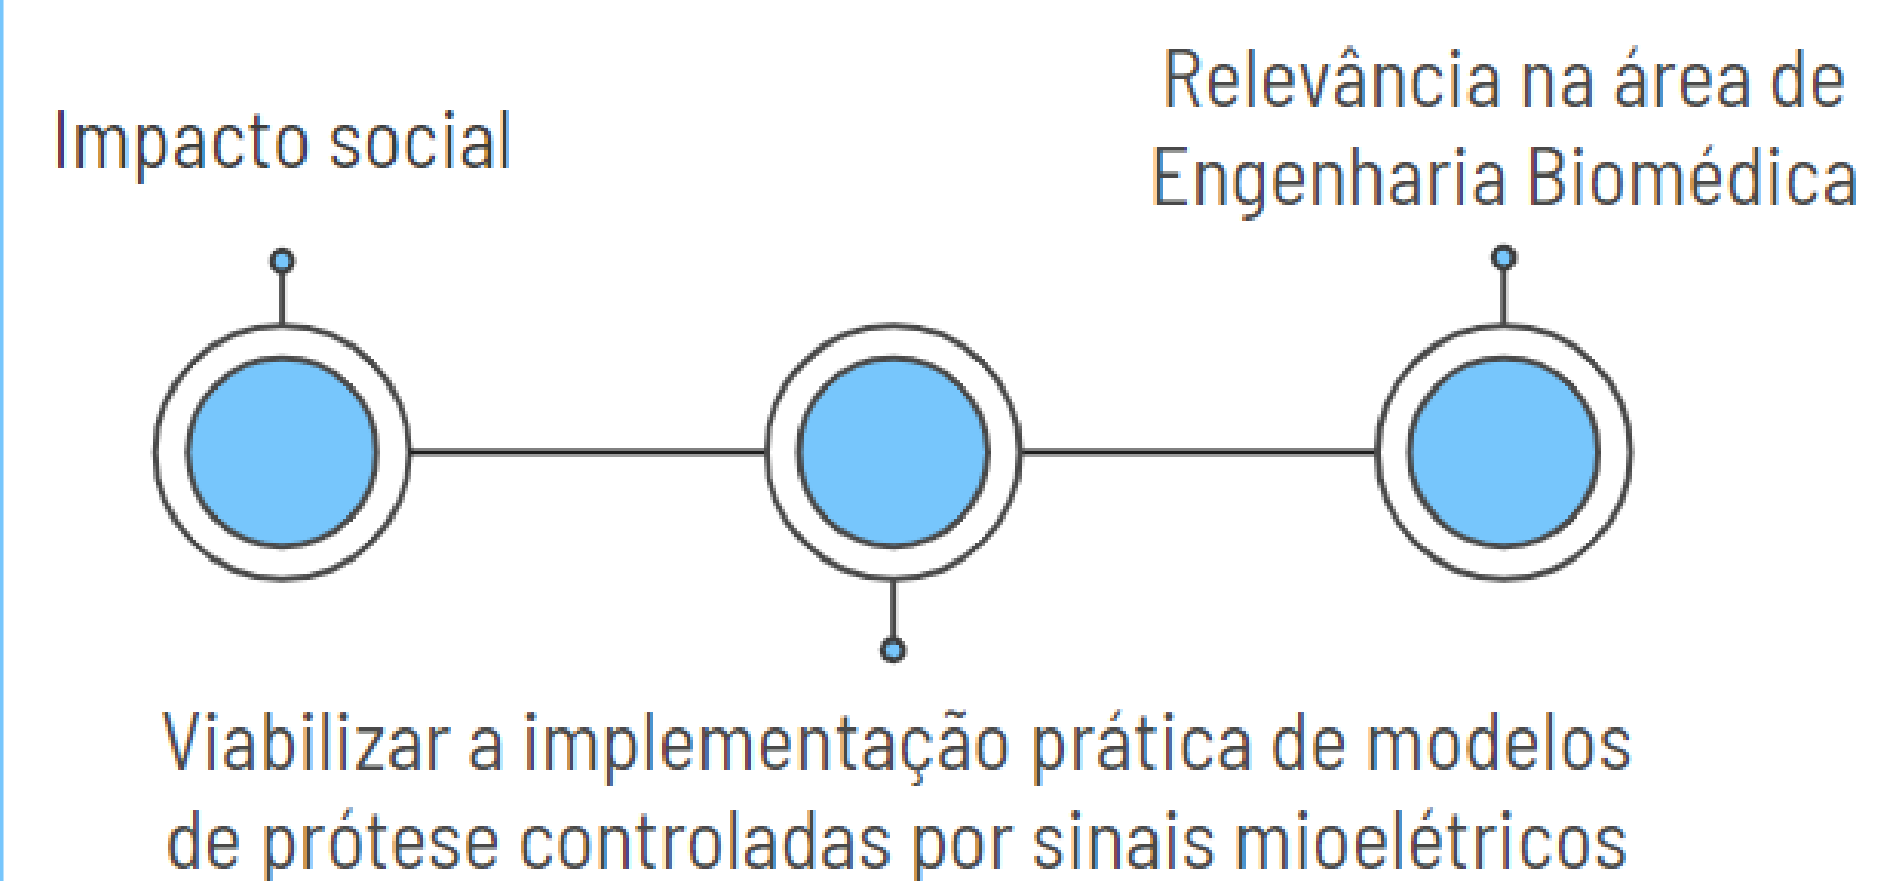
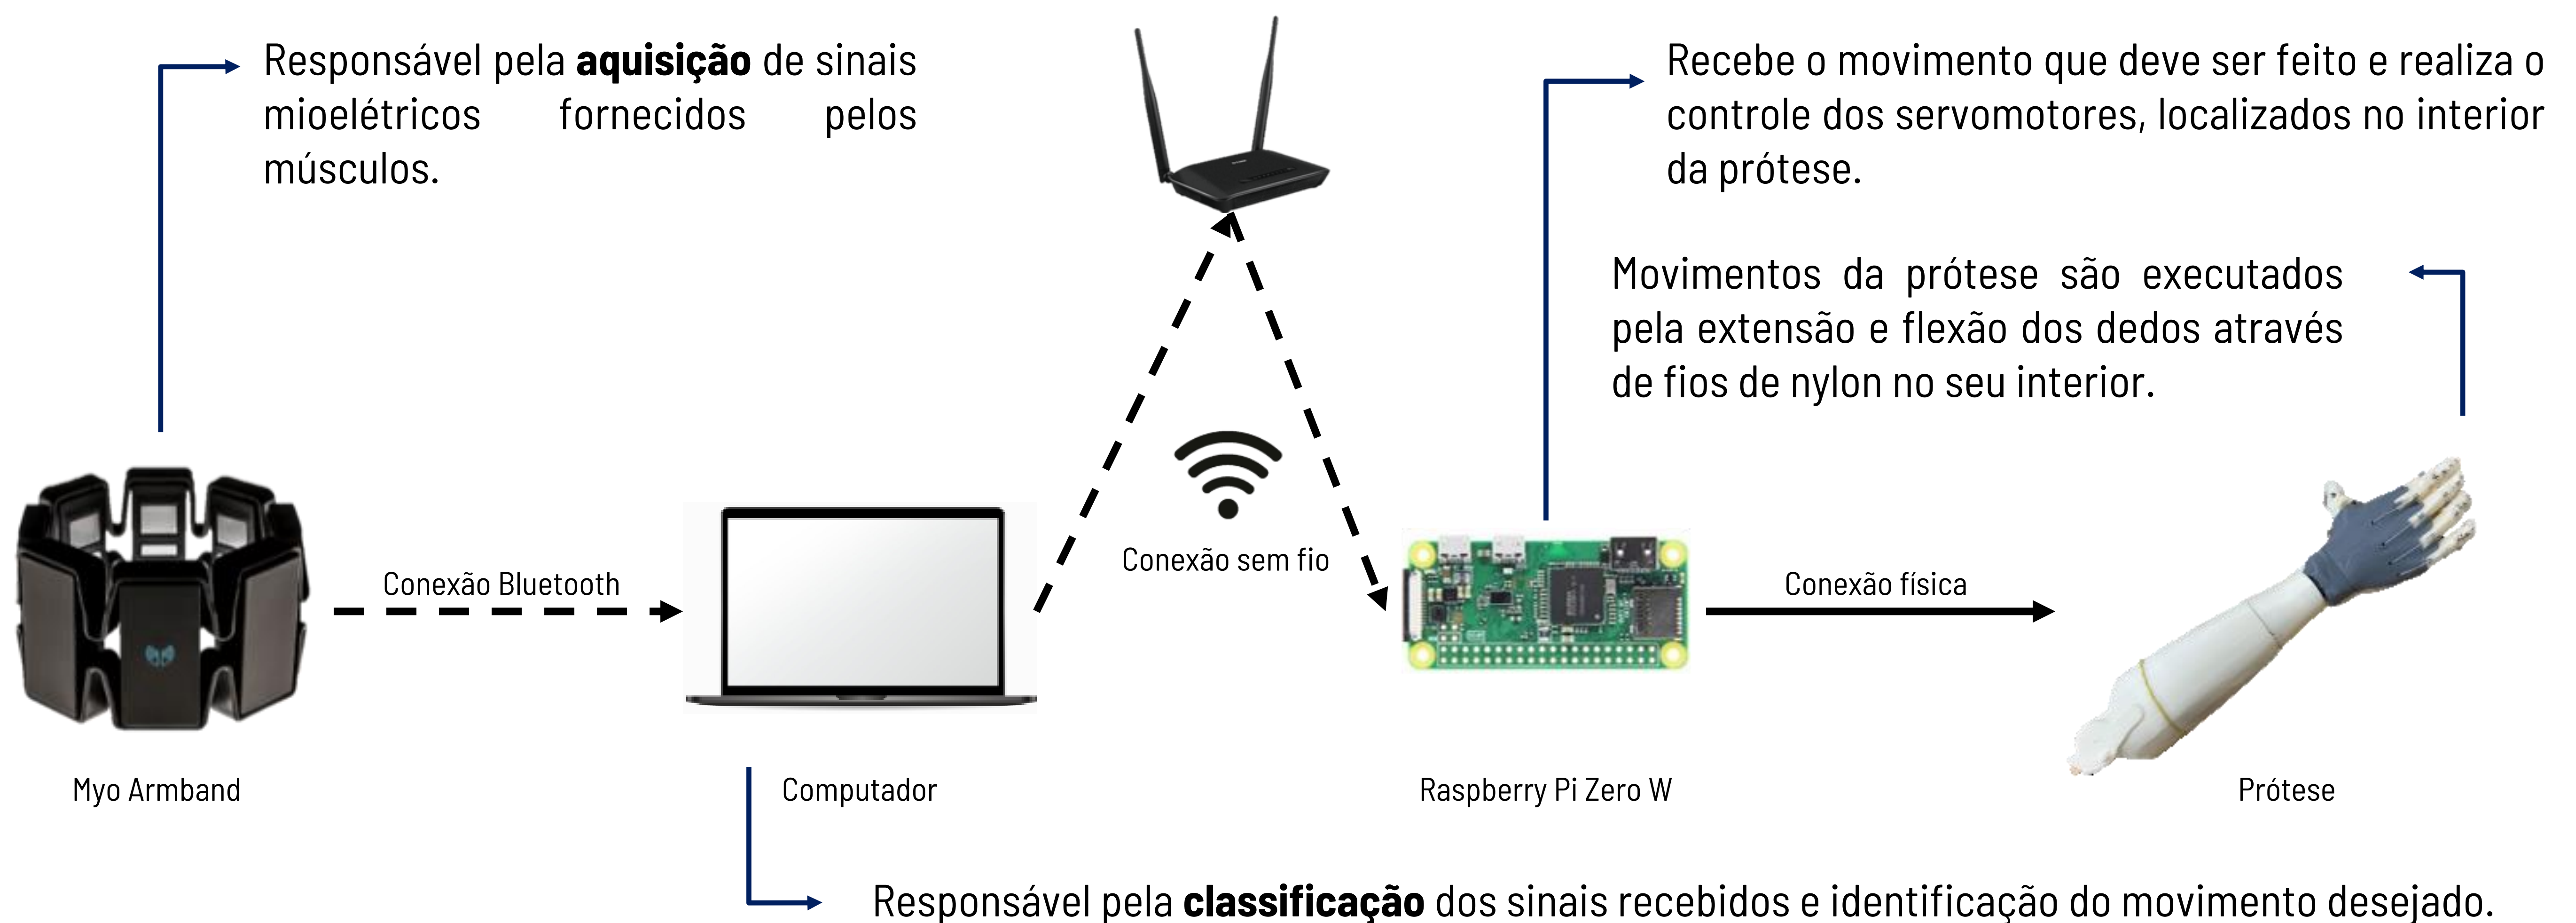


Diagrama de funcionamento do protótipo



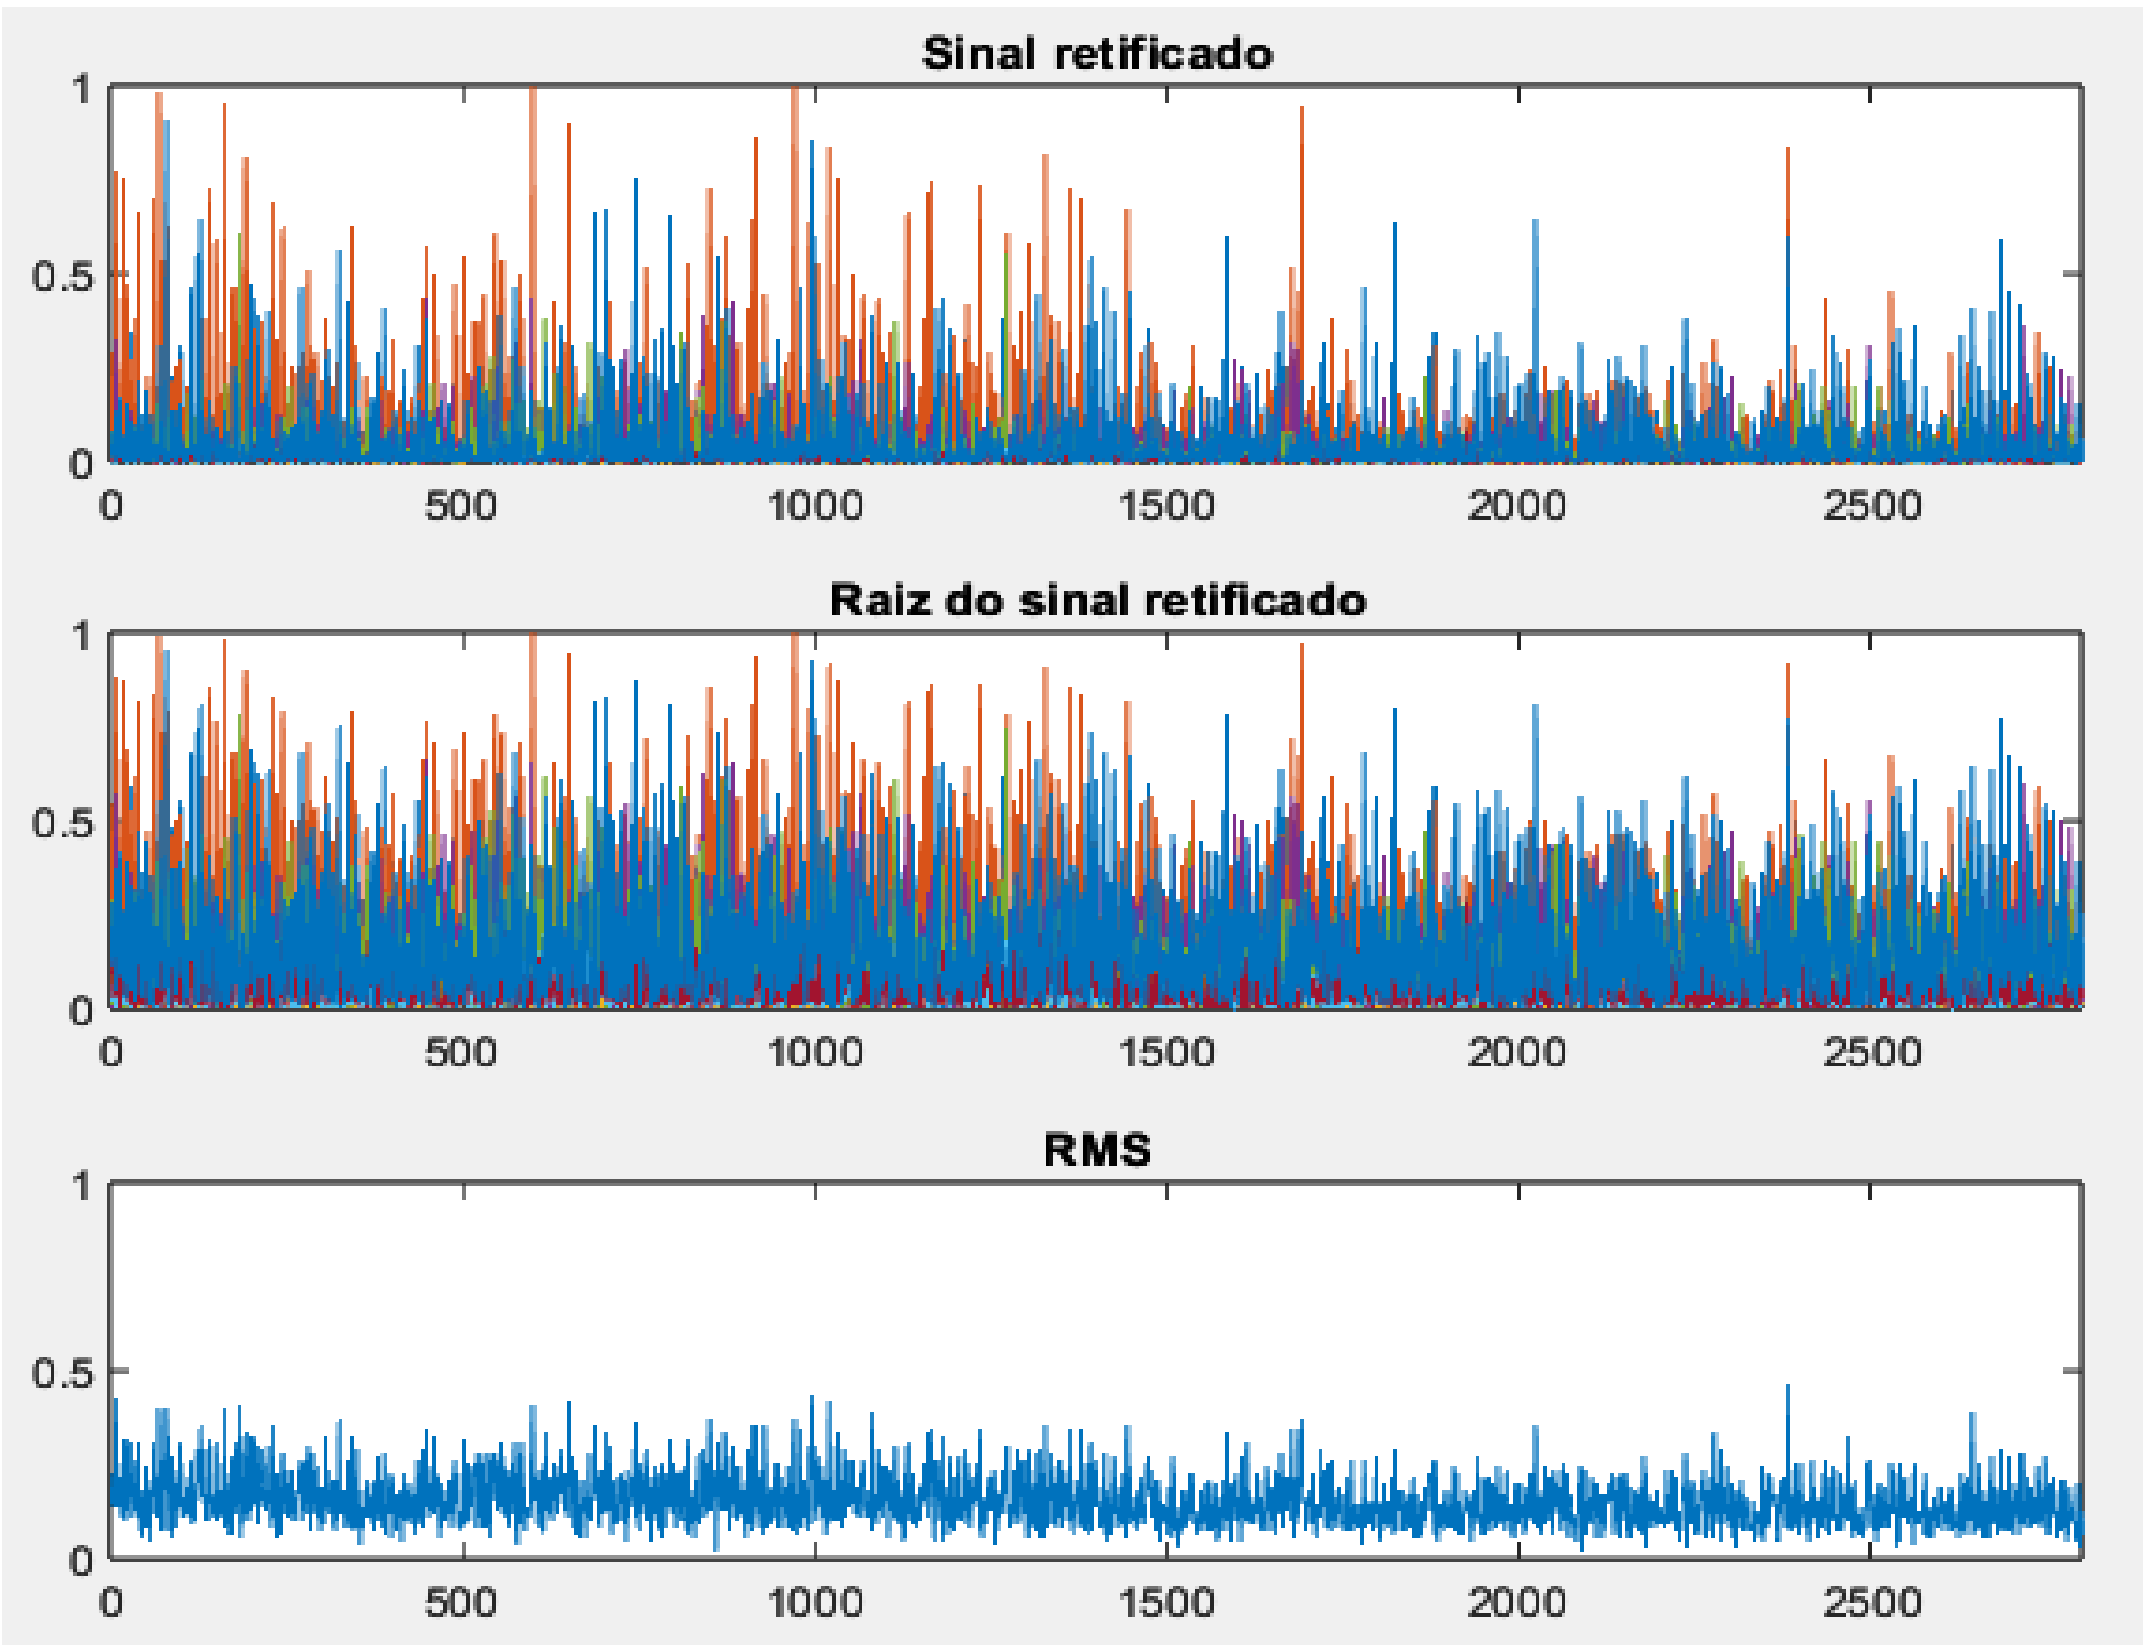
Para a classificação correta dos movimentos realizados pelo manipulador, foi preciso:

1. Criar um banco de dados de sinais sEMG adquiridos pela *Myo Armband*;
2. Utilizar técnicas de extração de características dos sinais sEMG;
3. Treinar modelos de aprendizado de máquina e escolher aquele com melhor desempenho;
4. Realizar o reconhecimento e classificação dos dados resultando na indicação do movimento correspondente;
5. Enviar o movimento desejado para o microcontrolador;
6. Executar o comando dos servomotores para realizar o movimento desejado.



SHEIKAH ARM: PRÓTESE MIOELÉTRICA COM RECONHECIMENTO DE PADRÕES DE EMG POR APRENDIZADO DE MÁQUINA

Métodos de Extração de Características e Treinamento de Modelos



Retificação do sinal: Realizada ao se elevar os valores do sinal sEMG adquirido ao quadrado.

Raiz do sinal retificado: Realizada ao extrair a raiz do sinal após a transformação anterior (Retificação do sinal).

Root Mean Square (RMS): Método de extração de características que calcula a raiz quadrada média de um conjunto de dados, nesse caso dos 8 sinais de EMG.

Resultado Médio*

Sem PCA: 78,5%

Com PCA: 72,1%

Sem PCA: 83,8%

Com PCA: 73,4%

Sem PCA: 53,7%

Com PCA: 53,7%

*Com SVM Quadrático

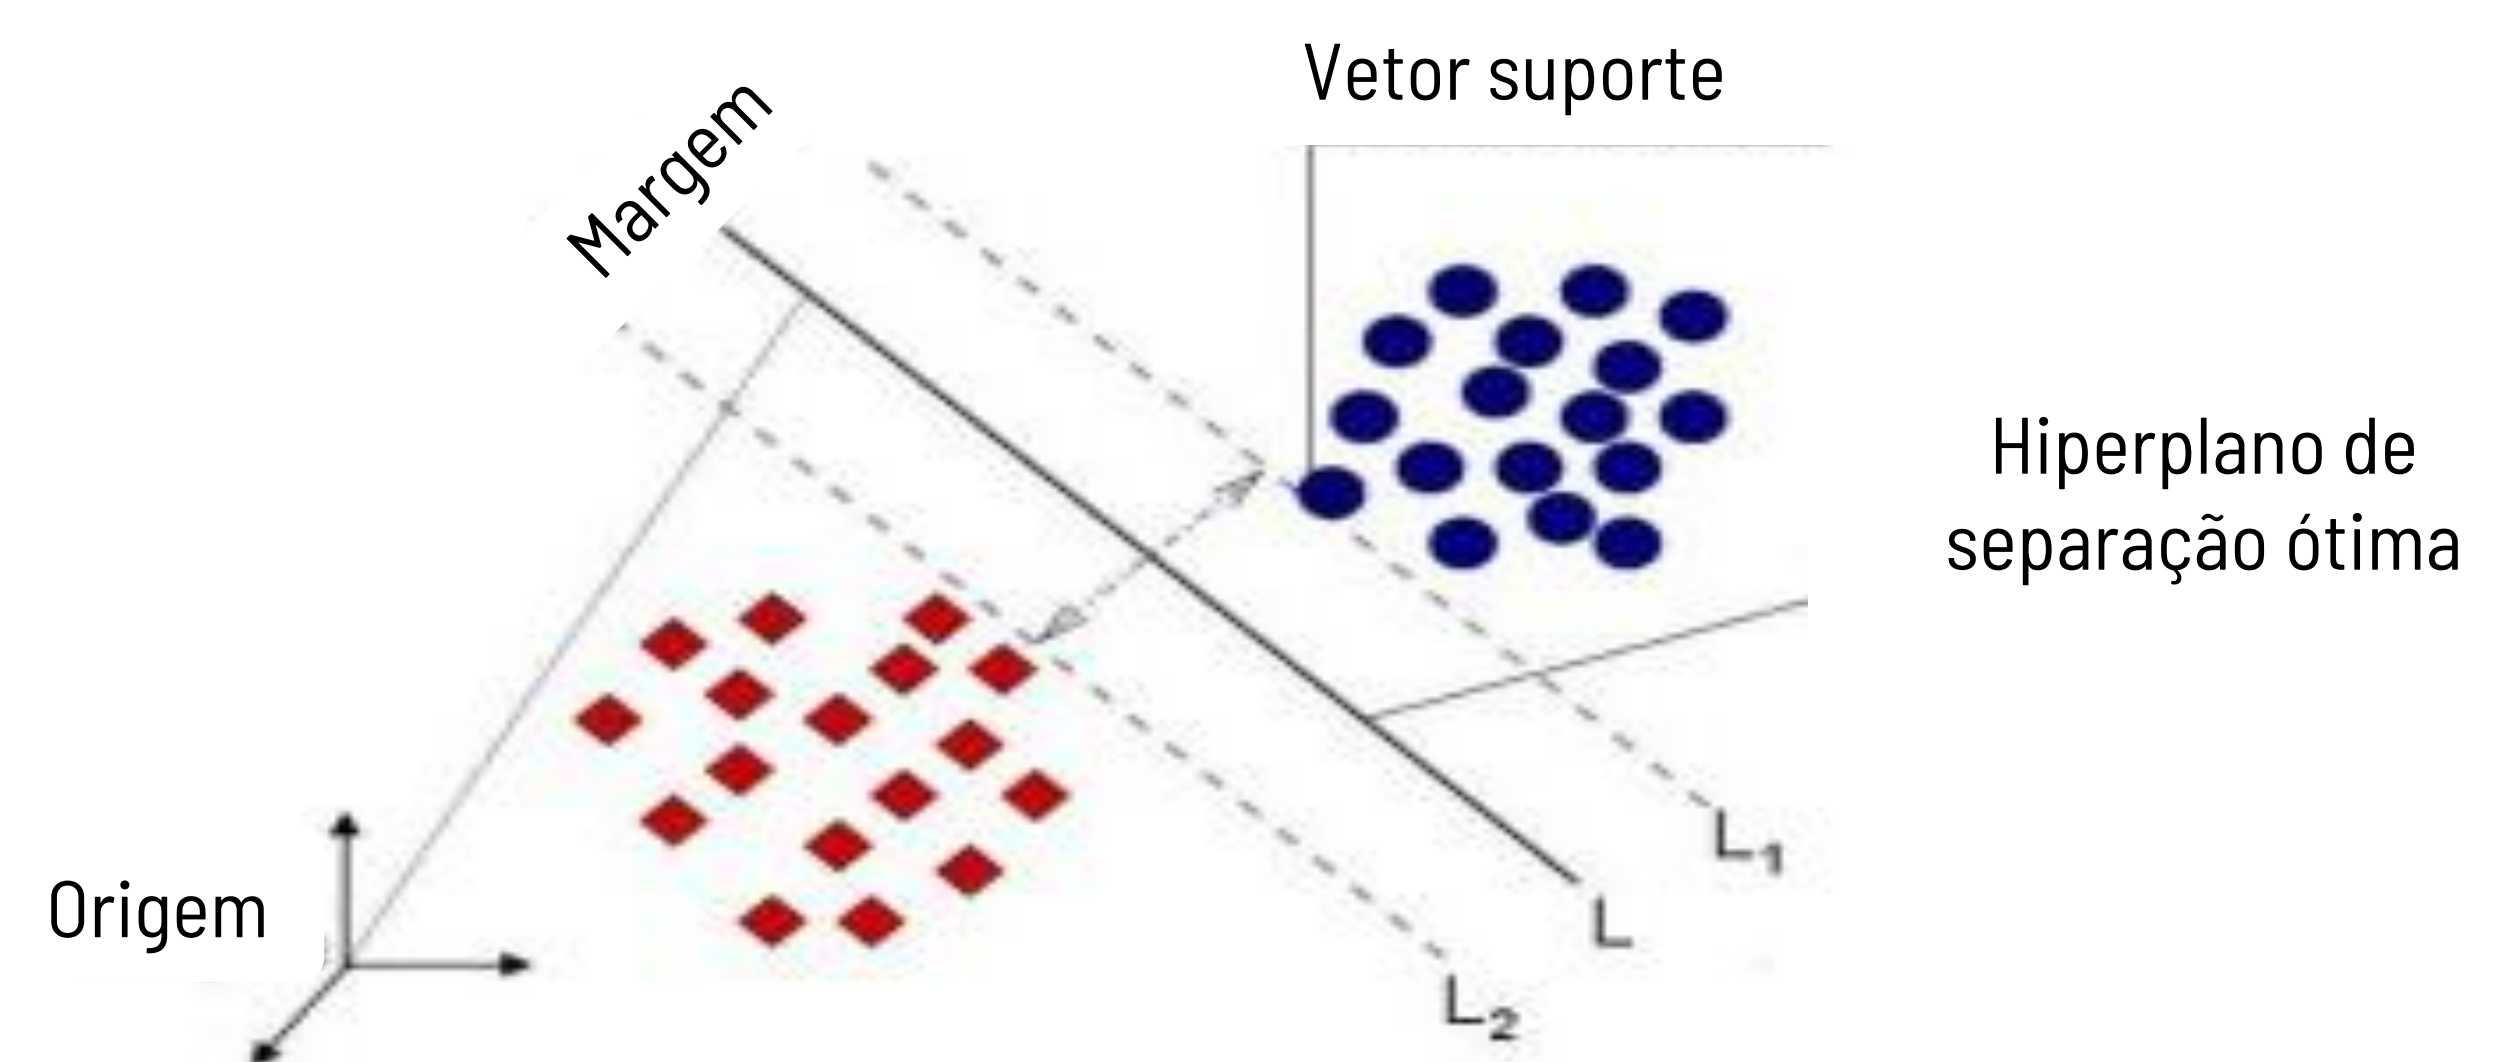
Técnica de Análise de Componentes Principais (PCA): método de redução de dimensionalidade usado em aprendizado de máquina para identificar e representar as principais características de um conjunto de dados.

Algoritmos de classificação testados

Algoritmo	Acurácia
Árvore fina (Fine Tree)	78,5%
Árvore média (Medium Tree)	71,5%
Árvore Grosseira (Coarse Tree)	53,6%
Discriminante linear (Linear Discriminant)	73,3%
Discriminante quadrático (Quadratic Discriminant)	82,5%
Naive Bayes Gaussiano (Gaussian Naive Bayes)	79,5%
Naive Bayes com Kernel (Kernel Naive Bayes)	79,7%
SVM Linear (Linear SVM)	81,4%
SVM Quadrático (Quadratic SVM)	83,8%
SVM Cúbico (Cubic SVM)	83,1%
SVM Gaussiano Fino (Fine Gaussian SVM)	76,4%
SVM Gaussiano Médio (Medium Gaussian SVM)	83,2%
SVM Gaussiano Grosso (Coarse Gaussian SVM)	81,4%
KNN Fino (Fine KNN)	74,7%
KNN Médio (Medium KNN)	80,4%
KNN Grosso (Coarse KNN)	78,5%
KNN Cosseno (Cosine KNN)	79,7%
KNN Cúbico (Cubic KNN)	80,4%
KNN Ponderado (Weighted KNN)	80,1%
Árvores Impulsionadas (Boosted Trees)	77,3%
Árvores Bagged (Bagged Trees)	80,3%
Discriminante de Subespaço (Subspace Discriminant)	73,7%
KNN de Subespaço (Subspace KNN)	59,4%
Árvores Impulsionadas por RUS (RUS Boosted Trees)	71,4%
Rede Neural Estreita (Narrow Neural Network)	83,5%
Rede Neural Média (Medium Neural Network)	83,7%
Rede Neural Larga (Wide Neural Network)	82,2%
Rede Neural de Duas Camadas (Bilayered Neural Network)	83,3%
Rede Neural de Três Camadas (Trilayered Neural Network)	83,4%
Kernel SVM (SVM Kernel)	70,8%
Regressão Logística com Kernel (Logistic Regression Kernel)	80,3%

Reconhecimento e Classificação

Máquinas de vetores de suporte (SVM): Busca por um hiperplano e o valor da margem entre dois pontos para distinguir entre dois tipos de objetos.



Validação cruzada: Divisões do conjunto de dados utilizados para avaliar o desempenho do modelo, garantindo uma avaliação mais robusta e confiável. Modelo final com 10 subconjuntos.

Métricas para algoritmo SVM Quadrático

	Sinal Retificado	Raiz do sinal retificado	RMS
Sensibilidade	78,52%	83,86%	53,65%
Especificidade	94,90%	96,31%	85,80%
Acurácia	78,52%	83,84%	53,65%
Precisão	78,87%	83,87%	52,63%

Sensibilidade: Capacidade do método de detectar com sucesso resultados classificados como positivos.

Especificidade: Capacidade do método de detectar resultados negativos.

Acurácia: Porcentual de acertos.

Precisão: Quantidade de verdadeiros positivos sobre a soma de todos os valores positivos.



SHEIKAH ARM: PRÓTESE MIOELÉTRICA COM RECONHECIMENTO DE PADRÕES DE EMG POR APRENDIZADO DE MÁQUINA

Montagem do protótipo

Modelo inicial - Kwawu Arm 2.0 - Socket Version



Modelo com alterações no pulso




Modelo Final - Sheikah Arm



Passagem de fios de nylon pelo interior da mão e punho



Interior da prótese com componentes eletrônicos




Detalhes da mão




Resultados

Mão Fechada



Indicador



Polegar




Mão Fechada



Indicador



Polegar



Mão Aberta




Pinça



Mão aberta



Pinça



Acurácia dos testes práticos

Movimentos	Acertos	Repetições	Acurácia
Mão Fechada	39	50	78%
Pinça	41	50	82%
Indicador	48	50	96%
Polegar	49	50	98%
Mão Aberta	50	50	100%
Total	227	250	90,8%

Tempo de funcionamento: ~6 horas

Peso total: ~750g

Força do aperto de mão: ~1Kg

Acurácia de treinamento (offline): 83,8%

Acurácia prática final (online): 90,8%

