

Classification of Hand Movements from EMG Signals for People with Motor Disabilities

Francisco J. Prado Júnior, Flávio V. dos Santos and C. Alexandre R. Fernandes

Abstract—People with disabilities correspond to about 25% of the Brazilian population. A great part of these people have physical impairments that difficult the use computer peripherals. This article presents the development of a system for detection of hand movements through the acquisition and classification of electromyographic (EMG) signals using machine learning techniques. The purpose of the proposed system is to be used by people with disabilities to control an adapted text editor. The signals are capture by surface EMG electrodes and used to the detect 4 different hand movements. In addition, a database with 3200 EMG signals generated by the hand movements was created, made by one user diagnosed with cerebral palsy and another user without diagnosed motor disabilities. Several tests were carried out, showing the good accuracy of the proposed system, with a success classification rate of 96% to 98%.

Index Terms—EMG signals, assistive technology, human-machine interface, machine learning, text editor.

I. INTRODUÇÃO

Um ser humano é considerado como Pessoa Com Deficiência (PcD) quando possui algum impedimento de longo prazo, podendo ser de natureza física, mental, intelectual ou sensorial, fazendo com que essa pessoa seja impedida de exercer atividades cotidianas, impossibilitando assim uma vida social em igualdade com as demais pessoas [1]. Segundo dados da Organização Mundial da Saúde (OMS), a população mundial contém cerca de 14% de pessoas com algum tipo de deficiência, com 80% destas pessoas vivendo em países sub-desenvolvidos, sendo em sua maioria crianças e adolescentes com menos de 18 anos [2]. Só no Brasil, estima-se cerca de 46 milhões de PcD, o que equivale a 25% de sua população. Dessas, 38,8% conseguem algum grau de escolaridade básica e apenas 6,7% conseguem o atingir o nível superior [3].

As dificuldades que as PcD encontram em suas vidas podem ser caracterizadas como tudo aquilo que impõe limites ou impeça a sua participação na sociedade e o uso de seus direitos. Dentre as principais barreiras encontradas pelas PcD, listadas no Estatuto da PcD [3], se encontram as “Barreiras tecnológicas”, que estão relacionadas às dificuldades ou impedimentos ao acesso da pessoa com deficiência às tecnologias. Todas essas barreiras, atreladas às dificuldades físicas e mentais das

pessoas com deficiência, geram a exclusão social das mesmas [3].

Neste contexto, as chamadas Tecnologias Assistivas (TAs) [4], [5] possuem um papel fundamental. As TAs são um conjunto de serviços e ferramentas para auxiliar às PcD e, em especial, a categoria “Recursos de acessibilidade ao computador” tem possibilitado o uso de computadores na Educação Inclusiva (EI). De fato, para que o computador seja usado adequadamente na educação inclusiva, é necessário que haja uma Interface Homem-Máquina (IHM) que possibilite ao usuário com deficiência física motora nos membros superiores controlar suas ferramentas sem maiores dificuldades.

Muitos pesquisadores vêm trabalhando para desenvolver soluções inovadoras para o uso do computador pelas PcD, desde a confecção de periféricos, como mouses e teclados adaptados [6], até o uso de técnicas de aprendizagem de máquina (AM) para a classificação de sinais biológicos (sinais produzidos pelo corpo humano) para a realização do controle de máquinas. Um exemplo de sinal biológico são os sinais eletromiográficos (EMG), que estão sendo constantemente usados para a criação de novas interfaces com diversas utilizações, como controle de próteses e cadeiras de rodas motorizadas [7].

A proposta deste trabalho é desenvolver um sistema para detecção de movimentos das mãos através da aquisição e classificação de sinais biológicos EMG usando técnicas de AM. O objetivo do sistema proposto é ser usado por PcD para controlar um editor de texto adaptado. Os sinais são capturados por um sistema de aquisição que possui 2 pares de eletrodos de EMG de superfície, duas placas de aquisição *open source* (Shield EKG/EMG Olimex) e uma placa Arduino. Algumas técnicas de AM são usadas para a classificação dos sinais EMG correspondentes a quatro movimentos diferentes da mão. São testados 3 diferentes classificadores, em conjunto com a técnica Análise de Componentes Principais (PCA): Máquina de Vetores de Suporte (SVM), *K-Nearest Neighbors* (KNN) e *Multilayer Perceptron* (MLP).

Como atributos para o vetor de características, foram testadas diversas combinações de atributos envolvendo Transformada de Fourier (TF), Transformada de *Wavelet* (TW) e parâmetros diversos no domínio do tempo e frequência. Vale a pena mencionar que foi desenvolvido um editor de texto adaptado, cuja funcionalidade dispensa o uso do teclado convencional, para que o usuário consiga digitar palavras usando apenas o sistema de detecção de movimentos desenvolvido. O editor de texto necessita apenas de três movimentos de mão para funcionar. Desta forma, pode-se escolher os 3 movimentos que forneceram os melhores resultados, dentre os 4 movimentos detectados pelo sistema proposto.

Ao final do trabalho, são apresentados os resultados obtidos

F. J. P. Junior is with the Electrical and Computer Engineering Graduate Program, Universidade Federal do Ceará, Ceará, Brasil, e-mail: juniorevnnn@gmail.com

F. V. dos Santos and C. A. R. Fernandes are with the Department Computer Engineering, Universidade Federal do Ceará, Ceará, Brasil, e-mail: flavio-tub@hotmail.com, alexandrefernandes@ufc.br.

Os autores deste trabalho gostariam de agradecer à Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP/CE/Brasil) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq/Brasil - processo n. 304053/2016-3) pelo financiamento parcial deste trabalho.

na realização dos testes com o objetivo de medir da eficiência do sistema desenvolvido no reconhecimento dos movimentos realizados pelos usuários. Para este fim, foi construído um banco de dados com 3200 sinais EMG emitidos pelos músculos do antebraço produzidos pela execução de movimentos de mão de dois usuários, sendo um dos usuários uma PcD com deficiência motora nos braços e um sem deficiência diagnosticada. Os testes apresentados são divididos em duas partes: testes *offline*, realizados com a base de dados (fases de treinamento e validação), e testes *online*, realizados com sinais não contidos na base de dados, processados em tempo real (fase de testes).

Pode-se resumir as contribuições e vantagens do sistema proposto no presente trabalho da seguinte forma:

- Baixo custo, pois utiliza placas de aquisição de baixo custo e *open source*, bem como eletrodos reutilizáveis e cabos de baixo custo.
- Não invasivo, pois usa apenas sensores EMG de superfície em braceletes elásticos, sem necessidade de uso de introdução de agulhas no músculo do usuário.
- Integração ao editor de texto adaptado.
- Testes realizados em tempo real, assim como usando amplo banco de dados com 3 diferentes classificadores e diversas configurações de atributos.
- Boa acurácia.

O restante do presente artigo se divide nas seguintes partes. Na Seção II, é apresentada uma revisão do estado da arte relacionada à temática deste artigo. Na Seção III, será detalhado o sistema de detecção de movimentos de mão proposto. Na Seção IV, é apresentado o banco de dados de amostras de sinais EMG. Na Seção V, são fornecidos os resultados dos testes realizados, enquanto na Seção VI são apresentadas as conclusões e perspectivas do presente trabalho.

II. TRABALHOS RELACIONADOS

A seguir, serão apresentados trabalhos que utilizam sinais biológicos e técnicas de AM para o desenvolvimento de periféricos de acesso ao computador acessível às PcDs.

Em [8], propõe-se uma interface voltada para auxiliar pessoas com paralisia cerebral (PC). A interface baseia-se em *Emotiv Epoc* e usa sinais cerebrais captados por um “capacete” posto na cabeça do usuário. Neste trabalho, é proposto um *software* que foi desenvolvido para interagir com impulsos cerebrais. Uma das metas abordadas foi a análise emocional do usuário.

Já em [9], avalia-se o controle de próteses de pernas em pacientes amputados. Para isso, é utilizada a classificação de sinais EMG produzidos pela movimentação do joelho do usuário. Para a classificação, foi utilizado como classificador uma rede neural MLP, cujos dados de treino foram extraídos de uma pessoa sadia enquanto caminhava. A rede já treinada recebe sinais do usuário real (pessoa amputada) e efetua o controle de sua prótese.

No trabalho [10], avalia-se o uso de um dispositivo de controle chamado MYO, composto por um bracelete com 8 pares de eletrodos, um transmissor sem fio e uma central de processamento. O dispositivo é colocado no braço do usuário

e reconhece três tipos de movimentos distintos. Esse mesmo dispositivo (MYO) foi utilizado no artigo [11], em que se registra a classificação de 6 movimentos de mão utilizando redes neurais e TW. A proposta é que a classificação desses sinais sirva para o controle de robôs.

Em [12], propôs-se uma IHM para auxílio de pessoas com membros superiores amputados no controle de próteses mecânicas. A IHM usa sinais EMG captados por 8 pares de eletrodos bipolares. Para a captação também usou-se o MYO posicionado na região do cotoco (extremidade do membro amputado). Foi utilizado o *Linear Discriminant Analysis* (LDA) como classificador para reconhecimento de 5 movimentos simples de braço, sendo 82,37% a melhor taxa de acerto encontrada.

Em [13], observa-se o uso de MLP e *Convolutional Neural Network* (CNN) para a classificação de sinais EMG e EEG. Nesse trabalho avalia-se o uso de treino cruzado da CNN usando a resposta do treino dos sinais EMG para o EEG e vice-versa, obteve-se nesse experimento uma taxa máxima de acerto de 93,82% de acerto para os sinais EEG e 85,12% para os sinais EMG.

O trabalho [14] apresenta uma IHM baseada em sinais EMG faciais (fEMG) e eletroencefalografia (EEG). Os sinais fEMG foram captados através de dois pares de eletrodos bipolares posicionados nos músculos laterais faciais. Já os sinais EEG foram captados por um par de eletrodos posicionados na região superior da cabeça do usuário. Nesse trabalho, conseguiu-se a classificação de 4 movimentos faciais com uma taxa máxima de acertos de 76,7%, além da detecção de sinais EEG com máxima precisão de 84,5%.

Em [15], utilizou-se uma rede neural linear com sete neurônios para classificação de sete movimentos de mão. Uma das diferenças deste trabalho em relação a [9] é o fato de, além do uso de sinais EMG, também serem usados sinais mecanomiográficos (MMG), que são sinais sonoros produzidos pelas unidades motoras durante a contração muscular. Para os sinais MMG, foram utilizados três microfones sensoriais, ambos posicionados no músculo inferior do antebraço.

Já em [16], destaca-se uma interface utilizando um *personal digital assistant* (PDA) para controle de uma cadeira de rodas motorizada. O controle se dá por meio de um apontador de cabeça e do auxílio de sinais EMG, EEG, *electrooculography* (EOG - sinais elétricos produzidos pelo movimento dos olhos) e vídeo-oculografia (VOG), sendo os dois primeiros captados por eletrodos de superfície e os dois últimos por meio de uma câmera. Além da movimentação da cadeira, o PDA também pode indicar expressões particulares do usuário.

No artigo [7], foi proposta uma IHM baseada em sinais EMG e EOG para controle de um editor de texto. O sinal EMG é captado através de um dispositivo semelhante a uma tiara que fica posicionada na região superior da cabeça e capta o sinal EMG facial. Já o sinal EOG é captado através de 5 eletrodos de superfície localizados próximo aos olhos. No editor proposto, as letras ficam dispostas na tela do computador e, ao detectar um sinal EOG, o sistema troca a seleção de caractere, enquanto que, ao detectar o sinal EMG, ele escreve o caractere selecionado.

Em [17], propõe-se o uso de sinais EMG para o controle de

um robô de monitoramento doméstico. O sinal EMG é extraído do antebraço por um par de eletrodos e, após a captação e processamento, o sinal é classificado com o auxílio de uma rede neural artificial, para então ser convertido em comandos de ações do robô.

No artigo [18], destaca-se a utilização de SVM para a classificação de sete movimentos de mão. O sinal classificado foi captado por quatro eletrodos de superfície localizados próximos à articulação do antebraço. Também em [19], avalia-se a eficácia do algoritmo SVM para classificar sinais EMG de seis movimentos de braço, para controle de um braço mecânico. Os sinais obtidos para esse experimento foram extraídos do biceps e antebraço, utilizando seis pares de eletrodos de superfície.

Em [20], é feito um comparativo entre o SVM e o KNN na classificação de sinais EMG. Para isso, foi utilizada uma base de dados retirada de UCI *Machine Learning Repository*. Essa base de dados contém sinais de seis movimentos de mão, captados através de um sistema de dois canais de aquisição. Constatou-se nesse estudo que o classificador SVM apresentou maior acurácia em relação ao classificador KNN.

Em [21], foi apresentada a utilização dos sinais EOG para controle das funcionalidades do mouse “mover o cursor” e “realizar cliques”. Utilizam-se quatro eletrodos de captação e um eletrodo de referência para a captação dos sinais. Para a classificação foram utilizados valores de limiarização, de acordo com o potencial captado pelos eletrodos.

III. SISTEMA DE DETECÇÃO DE MOVIMENTOS DE MÃO

Nesta seção, é apresentado o sistema para detecção de movimentos das mãos proposto, que foi pensado e desenvolvido com o objetivo de oferecer uma nova opção de controle do computador pelas PcD motora.

A. Visão Geral

O sistema proposto neste trabalho foi desenvolvido para amenizar as dificuldades que as PcD motora nos membros superiores possuem para manusear o *mouse* e teclado convencionais. Pensou-se então em um dispositivo que utilize a classificação de sinais EMG com eletrodos de superfície para o controle do computador, aplicando-se apenas movimentos de mão para seu funcionamento. O processo de funcionamento deste sistema se divide em diversas etapas, que são mostradas na Fig. 1 e explicadas na sequência.

B. Sistema de Aquisição e Pré-processamento

Foram utilizadas duas placas de aquisição *Olimex Shield EKG/EMG*. Trata-se de uma placa open-source de aquisição de sinais de eletrocardiograma (ECG) e EMG. Esta placa possui um sistema de blindagem eletromagnética que diminui consideravelmente a interferência de sinais ruidosos externos e possui um potenciômetro regulável, calibrado para sinais ECG/EMG e compatível com várias versões do Arduino 3V e 5V, incluindo o Arduino UNO, que é utilizado na aquisição do sinal [22].

Os sinais EMG foram captados usando dois pares de eletrodos passivos bipolares superficiais *Shield-EKG-EMG-PA*,

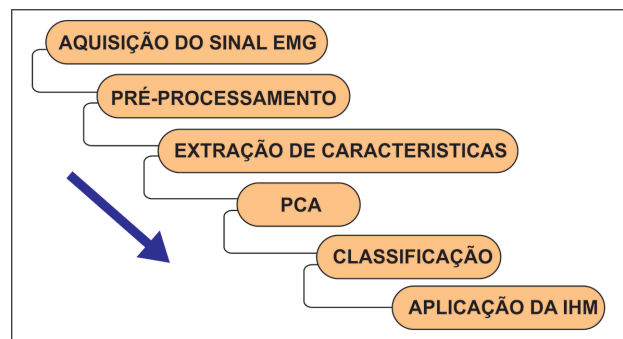


Fig. 1. Etapas do sistema para detecção de movimentos das mãos

ilustrados na Fig. 2. Além dos dois pares de eletrodos de captação, usaram-se ainda dois eletrodos de referência. Optou-se por esse tipo de eletrodo pelo fato de usarem braceletes elásticos para fixar os eletrodos nos pontos desejáveis ao invés de gel condutores, possibilitando a sua reutilização.




Fig. 2. Eletrodos passivos bipolares superficiais.

Os eletrodos de captação foram posicionados nas extremidades dos músculos superiores e inferiores do antebraço direito. Através de estudos e testes prévios descobriu-se que esses eram os músculos que mais reagiam aos movimentos escolhidos. Já os eletrodos de referência foram colocados próximos ao tornozelo da perna esquerda, região indicada pelo fabricante da placa de aquisição.

Cada par de eletrodos foi ligado a uma das duas placas de aquisição, captando simultaneamente dois sinais: canal 1 (Ch1) e canal 2 (Ch2), em que Ch1 capta a diferença de potencial causada pela contração/relaxamento do músculo superior do antebraço, e o Ch2 representa a diferença de potencial causada pela contração/relaxamento do músculo inferior do antebraço. Na Fig. 3, é ilustrado o esquema eletrodos-placas de aquisição, com a disposição dos eletrodos na parte superior e inferior do mesmo antebraço, enquanto na Fig. 4 é mostrada uma foto do posicionamento dos eletrodos no antebraço esquerdo.

As placas de aquisição *Olimex Shield EKG/EMG* recebem os sinais obtidos pelos eletrodos e realizam um pré-processamento destes sinais, através de operações analógicas de amplificação e filtragem. A placa de aquisição envia os

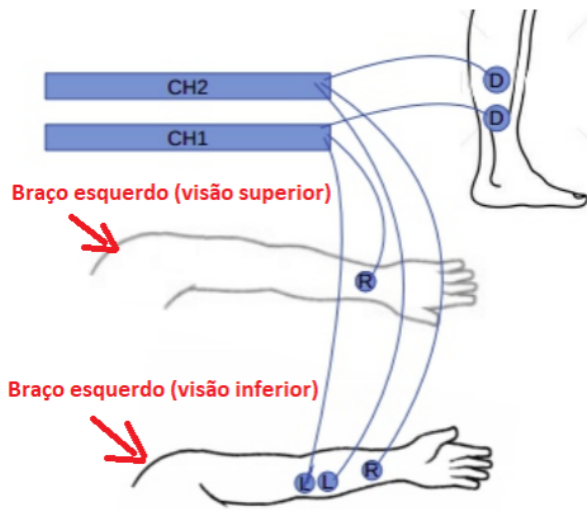


Fig. 3. Esquema eletrodos-placas de aquisição.



Fig. 4. Posicionamento dos eletrodos.

dados ao Arduino que realiza a transferência do sinal pré-processado para o computador.

Na Fig. 5, é mostrada a representação gráfica das amostras de sinal do movimento “Fechado” captadas pelos dois canais no domínio do tempo. O movimento “Fechado” está ilustrado na Fig. 6.b. Os quatro movimentos usados na base de dados serão detalhados na Seção V.




Fig. 5. Amostra de sinais captado pelo movimento “Fechado” no domínio do tempo.

Na Fig. 7, é mostrado o módulo da TF dos sinais referente à Fig. 5. Como se pode observar por estas figuras, o movimento

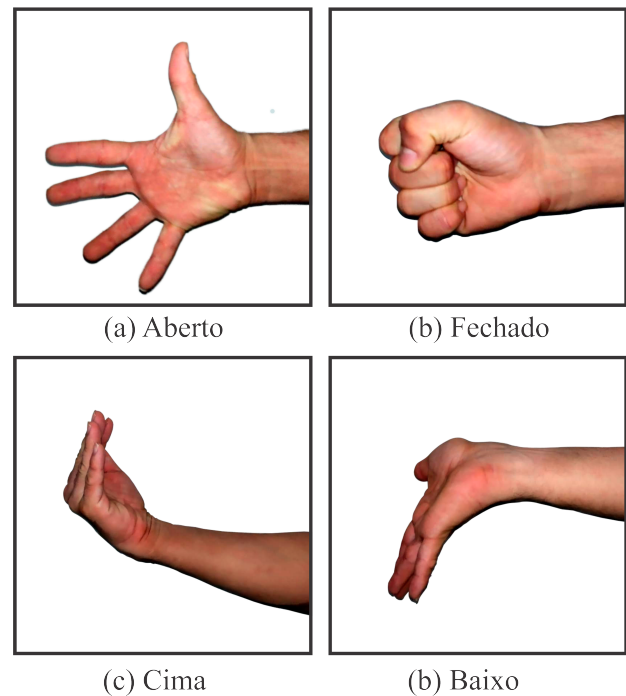


Fig. 6. Movimentos de mão escolhidos.

“Fechado” excita tanto os músculos da região superior do antebraço, captados pelo Ch1, quanto os músculos da região inferior, captados pelo Ch2, com maior intensidade na região inferior.




Fig. 7. Amostra de sinais captado pelo movimento “Fechado” no domínio da frequência.

C. Extração de Características

A primeira etapa do processo de classificação dos sinais EMG é a extração de características das amostras obtidas. Determinou-se 4 grupos de atributos que seriam extraídos de cada amostra para teste, são eles:

- Grupo 1 (G1): Nesse grupo, calculou-se o desvio padrão janelado da TF. Neste caso, a TF é dividida em vinte partes iguais e não sobrepostas, para então se calcular o desvio padrão do módulo de cada um desses intervalos. Extraíram-se desse grupo 40 atributos (20 atributos por canal).

- Grupo 2 (G2): Usou-se nesse grupo a TW. Selecionaram-se as baixas frequências da decomposição de quarta ordem da TW, gerando-se desse procedimento, 200 atributos (100 para cada canal).
- Grupo 3 (G3): Nesse grupo, a extração dos atributos deu-se de maneira semelhante ao grupo anterior, a diferença é que usaram-se os valores de baixa frequência da sexta decomposição da TW, extraindo 50 atributos (25 por canal).
- Grupo 4 (G4): Nesse grupo, utilizaram-se diversas operações para a extração dos atributos, são elas: média do sinal (tempo e frequência), valor máximo do sinal (tempo e frequência), assimetria (tempo e frequência), *zero cross rating* (tempo), curtose (tempo e frequência) e componente de frequência em qual a maior amplitude ocorre (frequência). No total, extraiu-se 20 atributos (10 por canal).

Como será detalhado na Seção V, durante as fases de treinamento e validação, foram realizados diversos testes com diferentes combinações destes atributos para se escolher o melhor vetor de características.

D. Análise de Componentes Principais (PCA)

A alta dimensionalidade do vetor de características acima descrito pode causar uma dispersão dos dados e o conhecido problema da “maldição da dimensionalidade”. Para evitar esse problema, a técnica PCA é usada para redução de dimensionalidade. Além de evitar esses problemas, o PCA também diminui o tempo de processamento. Durante as fases de treinamento e validação, foram realizados diversos testes com diferentes números de componentes do PCA para se avaliar o melhor valor para este parâmetro.

E. Classificador

A última etapa do sistema de detecção de movimentos de mão proposto é o algoritmo de classificação. Para isso, escolheu-se trabalhar com 3 classificadores: KNN, MLP e SVM. Esses classificadores já foram testados no contexto de sinais EMG, tal como mencionado na Seção II [20], [9], [13], [18], [19].

Como será visto na Seção V, a técnica SVM proporcionou os melhores resultados. Por este motivo, a maior parte dos resultados da simulação foram gerados usando este método. O classificador SVM realiza a separação das classes por meio de hiperplanos que são otimizados para gerar a maior distância possível entre as classes. Várias simulações foram realizadas a fim de comparar diferentes *kernels* de SVM e parâmetros de penalidade.

F. Editor de Texto Adaptado

Além dos problemas relacionados ao uso do mouse, muitas PcD motora nos membros superiores possuem dificuldades para usar o teclado convencional, por conta da localização de algumas teclas e também pela exatidão necessária em pressionar a tecla com o caractere desejado. Como aplicação do sistema de detecção de movimentos de mão, optou-se então

pelo desenvolvimento de um editor de texto adaptado. O editor possui uma interface simples semelhante a um editor de texto convencional, sendo desenvolvido na linguagem Java. Neste editor de texto, no lugar do teclado convencional para a escrita de caracteres, utiliza-se 3 movimentos de mão para tal ação, executando 3 comandos: passar caractere, escrever caractere e deletar caractere. Definiu-se seu funcionamento da seguinte maneira:

- Passar caractere: passa as letras em ordem alfabética e é ativado pelo movimento “Aberto” (Fig. 6.a).
- Escrever caractere: fixa o caractere escolhido e é ativado pelo movimento “Cima” (Fig. 6.c).
- Apagar caractere: Apaga último caractere escrito e é ativado pelo movimento “Baixo” (Fig. 6.d).

Como será detalhado na Seção V, foram utilizados os 3 movimentos do banco de dados que obtiveram melhores taxas de acerto na classificação, sendo descartado o movimento com pior acurácia. O desenvolvimento e validação deste editor de texto adaptado será detalhado em um trabalho futuro.

IV. BANCO DE DADOS

Para treinamento e validação dos classificadores, foi construído um banco de dados com um grande número de amostras de sinais EMG relativos a 4 tipos de movimentos de mão movimentos feitos por uma PcD e uma pessoa sem deficiência. Cada movimento é descrito na Tabela I, enquanto na Fig. 6 são ilustrados os 4 movimentos. Deve-se considerar que a posição de repouso, posição inicial para cada movimento, é a mão relaxada com a palma da mão apontada para cima.

TABELA I
DESCRIÇÃO DOS MOVIMENTOS DE MÃO

Movimento	Descrição	Representação
Aberto	Extensão dos dedos e abertura da palma da mão.	Fig. 6.a
Fechado	Fechamento total do punho, fazendo pressão com os dedos.	Fig. 6.b
Cima	Flexão de punho para cima e extensão dos dedos para cima.	Fig. 6.c
Baixo	Flexão de punho para baixo e extensão dos dedos para baixo	Fig. 6.d

A coleta inicia-se com a realização de um dos movimentos mostrados na Fig. 6. Quando é realizado o movimento, acontece uma contração do músculo superior e inferior do antebraço gerando um pico de sinal EMG. A duração das contrações e relaxamentos é de aproximadamente 1,6 segundo para cada movimento realizado. Quando um pico de tensão é detectado, uma amostra do sinal com 3200 valores é escrita em um arquivo de texto utilizando o pico como centro do sinal (1599 amostras antes e 1600 depois), com taxa de transferência de 1kHz. O número de valores de cada amostra é equivalente aos valores captados por Ch1 e Ch2 durante o intervalo de 1,6 segundos. Após a captação dos valores recebidos, é escrito o rótulo do movimento, um valor inteiro de 1 a 4 representando cada um dos movimentos.

Foram coletadas amostras de 2 participantes: Participante 1, diagnosticado com PC e primeiro autor deste artigo, e Participante 2, sem deficiências motoras diagnosticadas. O Participante 1 possui o seguinte perfil: sexo masculino, 30 anos, escolaridade superior completo, com diagnóstico de PC¹. Já o Participante 2 possui seguinte perfil: sexo masculino, 25 anos, escolaridade superior incompleto, sem deficiências motoras. Cada participante realizou um total de 1600 movimentos, sendo 400 amostras de cada movimento, gerando um banco de dados com 3200 amostras. A base de dados está disponibilizada no repositório “ZENODO”, através do link: <https://zenodo.org/record/3834919#.Xxuqy55KjIU>.

V. RESULTADOS

Nesta seção são apresentados os resultados dos testes realizados para a classificação das amostras coletadas. Os resultados apresentados são divididos em duas partes: resultados *offline*, realizados com a base de dados (fases de treinamento e validação), e resultados *online*, realizados com sinais não contidos na base de dados e processados em tempo real (fase de testes).

A. Resultado dos Testes com a Base de Dados

Os primeiros resultados apresentados possuem o objetivo de avaliar o desempenho de 3 diferentes classificadores (SVM, MLP e KNN). Para tanto, foram realizadas algumas simulações preliminares com o intuito de definir uma configuração base para os testes dos classificadores. Os resultados destas simulações preliminares, omitidos por simplicidade, mostraram que os atributos do grupo G1 (desvio padrão janelado da TF) e o PCA com 35 componentes forneceram bons resultados para todos os classificadores. Desta forma, para a padronização dos resultados dos classificadores, esta configuração de atributos e PCA foi utilizada. Ademais, nesta etapa, foi usado o método de validação cruzada *k-Fold*, com $k = 3$ (fases de treinamento e validação).

Para cada classificador, foram realizados vários testes para se encontrar os melhores parâmetros de cada técnica. No caso do SVM, testaram-se os *kernels* linear, polinomial, Gaussiano (RBF - *radial basis function*) e sigmoide, variou-se o parâmetro do *kernel*, a constante de relaxamento e a técnica usada para caso multiusuário (*one-vs-one* e *one-vs-all*). No caso do MLP, variou-se a função de ativação, o número de camadas e o número de neurônios por camada. Já no caso do KNN, variou-se o parâmetro k . Além disso, no KNN, usou-se a técnica *k-d tree* para melhorar o desempenho do classificador.

Os parâmetros que forneceram os melhores resultados de acurácia para cada classificador são mostrados na Tabela II, para o Participante 1 (com deficiência), e na Tabela III, para o Participante 2 (sem deficiência), enquanto as correspondentes taxas de acerto são apresentadas na Tabela IV, para o melhor caso de cada classificador.

Pode-se perceber pela Tabela IV que a técnica SVM forneceu a melhor taxa de acerto para ambos os participantes. Deve-se destacar ainda que se obteve uma melhor taxa de acerto

TABELA II
PARÂMETROS DE CONFIGURAÇÃO USADOS PARA OS CLASSIFICADORES (PARTICIPANTE 1)

Movimento	Parâmetros
SVM	<i>kernel</i> Gaussiano, $a = 0$; 25, $C = 7$ e <i>one-vs-one</i>
MLP	2 camadas ocultas, função de ativação sigmoide e 4 neurônios por camada.
KNN	$K = 3$ (com <i>k-d tree</i>)

TABELA III
PARÂMETROS DE CONFIGURAÇÃO USADOS PARA OS CLASSIFICADORES (PARTICIPANTE 2)

Movimento	Parâmetros
SVM	<i>kernel</i> Gaussiano, $a = 0$; 00055, $C = 10$ e <i>one-vs-one</i>
MLP	2 camadas ocultas, função de ativação sigmoide e 4 neurônios por camada.
KNN	$K = 3$ (com <i>k-d tree</i>)

TABELA IV
TAXA DE ACERTO DOS CLASSIFICADORES

Movimento	Participante 1	Participante 2
SVM	89,55%	93,13%
MLP	79,1%	73,44%
KNN	72,48%	72,39%

com o Participante 2 (93,13%) do que com o Participante 1 (89,55%). Isto se deve ao fato de o participante 1 ter espasmos musculares involuntários constantes, o que afeta as características extraídas. Desta forma, usando como critério de seleção a taxa de acerto, escolheu-se o classificador SVM para realizar o restante dos testes.

Os próximos resultados avaliam quais os melhores atributos a serem utilizados, bem como o melhor valor para o número de componentes do PCA, com o SVM. Foram testadas as seguintes 11 combinações de atributos: G1, G2, G3, G4, G1-G2, G1-G3, G1-G4, G2-G4, G3-G4, G1-G2-G4 e G1-G3-G4. Para cada combinação de atributos, foram testados diversos valores do número de componentes do PCA, para ambos os participantes.

São mostrados na Tabela V os melhores resultados dos testes realizados para as amostras dos dois participantes. Em cada tabela, mostrou-se as 3 maiores taxas de acerto obtidas quando se variou o número de componentes do PCA.

TABELA V
TAXAS DE ACERTO NOS MELHORES CASOS

Participante 1		Participante 2	
Grupo 2 e 4 (70 atributos)	Taxa	Grupo 1 e 2 (240 atributos)	Taxa
Nº comp. PCA		Nº comp. PCA	
10	91,10%	10	91,37%
20	95,38%	20	95,44%
30	97,12%	30	96,06%

A maior taxa de acerto encontrada para o Participante 1

¹CID10: G80 - Paralisia cerebral e F82 - Transtorno específico do desenvolvimento motor

foi de 97,12%, com 30 componentes de PCA e os atributos dos Grupos 2 e 4, enquanto que a maior taxa de acerto do Participante 2 foi 96,06%, com 30 componentes de PCA e com os atributos dos Grupos 1 e 2. Percebe-se que a taxa de acerto máxima do Participante 1 é ligeiramente maior do que a do Participante 2. Isto mostra que o ajuste fino dos atributos e do número de componentes do PCA conseguiu cancelar o efeito negativo que os espasmos musculares do Participante 1 causaram nas primeiras simulações. Ademais, pode-se observar que ambos os participantes obtiveram taxas de acerto bastante elevadas, acima de 96%.

São mostradas nas Tabelas VI e VII as tabelas de confusão com os números de acertos e erros de cada movimento, para os melhores casos dos Participantes 1 e 2, respectivamente. Ademais, nas Tabelas VI e VII, são mostradas as taxas de acerto para cada classe de movimento, para ambos os participantes. Pode-se concluir a partir destas tabelas que, para os dois participantes, o movimento “Fechar” obteve o pior desempenho, com 94% de acerto. Pode-se ainda observar que o pior desempenho deste movimento se deu pelo fato de estar sendo confundido com o movimento “Baixo”, no caso do Participante 1, e com o movimento “Aberto” do Participante 2.

Para efeitos de comparação, as taxas de acerto alcançadas em [12] e [13], que também realizam classificação de movimentos usando sinais EMG, foram 82,37 % e 88,55 %, respectivamente. Pode-se então deduzir que a taxa de acerto encontrada no presente trabalho é satisfatória, pois é significativamente superior às encontradas em [12] e [13], mesmo que utilizando um número menor de eletrodos.

TABELA VI

TABELA DE CONFUSÃO PARA O MELHOR RESULTADO (PARTICIPANTE 1)

	Aberto	Baixo	Cima	Fechar	Taxa de acerto
Aberto	395	3	0	2	98,75%
Baixo	1	393	1	5	98,25%
Cima	2	1	390	7	97,50%
Fechar	4	13	7	376	94,00%
Média					97,12%

TABELA VII

TABELA DE CONFUSÃO PARA O MELHOR RESULTADO (PARTICIPANTE 2)

	Aberto	Baixo	Cima	Fechar	Taxa de acerto
Aberto	383	1	1	15	95,75%
Baixo	3	389	2	6	97,25%
Cima	1	6	389	4	97,25%
Fechar	15	1	8	376	94,00%
Média					96,06%

B. Resultado dos Testes de Classificação em Tempo Real

Para os testes em tempo real (*online*), ou seja, com dados processados em tempo real, foram usados sinais não contidos na base de dados (fase de testes). Cada um dos 2 participantes realizou 400 movimentos, com 100 repetições para

cada movimento apresentado na Fig. 6. Usou-se o mesmo classificador e a mesma configuração de atributos e PCA do caso com melhor taxa de acerto na fase de valiação (usando a base de dados), tanto para as amostras do participante 1 quanto para as amostras do participante 2, ou seja, foram usadas a mesmas configurações utilizadas nas Tabelas VI e VII, respectivamente.

Nas Tabelas VIII e IX, são mostradas as tabelas de confusão com os números de acertos e erros de cada movimento nos testes *online* dos dois participantes, juntamente com as taxas de acerto para cada movimento. A partir destas tabelas, pode-se observar que, tal como nos testes com a base de dados, o movimento “Fechar” obteve o pior desempenho, para os dois participantes. Deve-se ainda ressaltar que as taxas de acerto médias obtidas nos testes em tempo real (81,75% e 82,75%) é significativamente menor do que aquelas obtidas com a base de dados. Este resultado é esperado, visto que os classificadores, o PCA e os atributos não foram configurados usando estes sinais. Ademais, vale ressaltar que o tempo de resposta para cada comando ficou entre 0,9 s e 1,8 s.

TABELA VIII

TABELA DE CONFUSÃO PARA O TESTE EM TEMPO REAL (PARTICIPANTE 1)

	Aberto	Baixo	Cima	Fechar	Taxa de acerto
Aberto	89	0	3	8	89,00%
Baixo	4	79	5	12	79,00%
Cima	2	1	86	11	86,00%
Fechar	5	10	12	73	73,00 %
Média					81,75%

TABELA IX

TABELA DE CONFUSÃO PARA O TESTE EM TEMPO REAL (PARTICIPANTE 2)

	Aberto	Baixo	Cima	Fechar	Taxa de acerto
Aberto	84	2	0	14	84,00%
Baixo	2	87	1	10	87,00%
Cima	1	1	88	10	88,00%
Fechar	9	12	7	72	72,00%
Média					82,75%

É válido ainda mencionar, como justificativa de uma possível aplicação, que, durante os testes em tempo real, o sistema de detecção de movimentos estava integrado ao editor de texto adaptado, com os movimentos “Aberto”, “Cima” e “Baixo” sendo escolhidos devido às suas taxas de acerto serem maiores do que o movimento “Fechado”. Foram feitos ainda, para efeitos de visualização, pequenos testes que resumem-se em escrever palavras curtas, escolhidas de forma aleatória, visto que o objetivo era apenas testar a viabilidade da sistema para controle de um editor de texto, substituindo o uso do teclado convencional por movimentos de mão. Ambos os participantes lograram sucesso em escrever as palavras com movimentos de mão, sem grandes dificuldades.

VI. CONCLUSÃO

Neste trabalho, foi apresentado um sistema para detecção de

movimentos de mãos usando sinais EMG e técnicas de AM, possibilitando a classificação de até 4 movimentos de mão. O objetivo do sistema proposto é ser usado como periférico de acesso ao computador por PcD para controlar um editor de texto adaptado. Foram realizados testes com um banco de dados com 3200 sinais EMG, bem como testes em tempo real, com um usuário diagnosticado com PC e outro usuário sem deficiências motoras diagnosticadas, usando atributos no domínio do tempo, frequência e TW.

Os testes mostraram que o sistema de classificação proposto forneceu boas taxas de acerto, com o classificador SVM obtendo o melhor resultado, sendo usado juntamente com a técnica PCA. Nos testes com a base de dados, foi obtida uma acurácia de 96% a 97%, enquanto que os teste em tempo real forneceram uma acurácia de 82% a 83%.

Em trabalhos futuros, pretende-se incrementar o sistema de aquisição de sinais usando acelerômetros e giroscópios, bem como serão realizados testes com um número maior de usuários com PC. Serão também testadas técnicas de aprendizagem profunda (*deep learning*) para a classificação dos movimentos. Ademais, serão feitas melhorias no editor de textos, tais como a introdução de um dicionário de palavras e um sistema de auto completude, bem como será feito um estudo envolvendo o desenvolvimento e a validação do editor de texto.

REFERÊNCIAS

- [1] C. d. D. Brasil, Lei no 13.146, de 6 de julho de 2015. institui a lei brasileira de inclusão da pessoa com deficiência (estatuto da pessoa com deficiência). Diário Oficial da União, 2015.
- [2] W. H. Organization, et al. "World report on disability 2011". [S.l.]: *World Health Organization*, 2011.
- [3] I. B. G. E. Brasil, "Instituto Brasileiro de geografia e Estatística". *Censo demográfico*, v. 2010, 2010.
- [4] M. R. C. Maciel, "Portadores de deficiência: a questão da inclusão social". *São Paulo em perspectiva, SciELO Brasil*, v. 14, n. 2, p. 51–56, 2000.
- [5] Hussey, S. M.; Cook, A. M. "Assistive Technologies: Principles and Practice". St. Louis, MO: Mosby, Year Book, Inc, 1995.
- [6] C. R. C. da Silva, A. M. Torres, J. L. T. Nogueira and L. C. S. Motta, Hardware adaptado para apoio ao desenvolvimento de portadores de síndrome de down. 2007.
- [7] H. S. Dhillon, R. Singla, N. S. Rekhi and R. Jha, "EOG and EMG based virtual keyboard: A brain-computer interface," 2009, *2nd IEEE International Conference on Computer Science and Information Technology*, Beijing, 2009, pp. 259–262.
- [8] García Ramírez, A.R.; Da Silva, J.F.; Savall, A.C.R.; Catecati, T.; Ferreira, M.G.G. "User's Emotions and Usability Study of a Brain-Computer Interface Applied to People with Cerebral Palsy". *Technologies*. Jun, 2018.
- [9] R. U. Ferreira, A. F. da Rocha, C. C. Jr, G. A. Borges, F. A. O. Nascimento and W. H. Veneziano, "Reconhecimento de padrões de sinais de emg para controle de prótese de perna," In *SN. XI Congresso Brasileiro de Biomecânica*. [S.l.], 2005. p. 1–5.
- [10] A. Patel, J. Ramsay, M. Intiaz and Y. Lu, "EMG-based Human Machine Interface Control,in " *12th International Conference on Human System Interaction (HSI)*, Richmond, USA, 2019, VA, pp. 127–131.
- [11] D. Oh, and Jo, Y. Emg-based hand gesture classification by scale average wavelet transform and cnn., p. 533–538, 2019.
- [12] O. W. Samuel et al., "Intelligent EMG Pattern Recognition Control Method for Upper-Limb Multifunctional Prostheses: Advances, Current Challenges, and Future Prospects". *IEEE Access*, vol. 7, pp. 10150–10165, 2019, doi: 10.1109/ACCESS.2019.2891350.
- [13] J. J. Bird, J. Kobylarz, D. R. Faria, A. Ekárt and E. P. Ribeiro, "Cross-Domain MLP and CNN Transfer Learning for Biological Signal Processing: EEG and EMG". *IEEE Access*, vol. 8, pp. 54789–54801, 2020, doi: 10.1109/ACCESS.2020.2979074.
- [14] K. Chuysud and Y. Punsawad, "Hybrid EEG-fEMG based Human-Machine Interface for Communication and Control Applications", in *16th International Joint Conference on Computer Science and Software Engineering (JCSSE)*, pp. 1–5. IEEE, 2019.
- [15] T. G. Amaral, O. P. Dias, A. Wolczowski and V. Fernão Pires, "Neural network based identification of hand movements using biomedical signals in," *IEEE 16th International Conference on Intelligent Engineering Systems (INES)*, Lisbon, 2012, pp. 125–129.
- [16] R. L. Silva, "Desenvolvimento de uma interface homem-máquina aplicada a uma cadeira de rodas robótica por meio de PDA". Universidade Federal do Espírito Santo, 2007.
- [17] J. Morón, T. DiProva, J. R. Cochrane, I. S. Ahn and Y. Lu, "EMG-based hand gesture control system for robotics, in" *IEEE 61st International Midwest Symposium on Circuits and Systems (MWSCAS)*, Canada, 2018, Windsor, ON, pp. 664–667.
- [18] M. Yoshikawa, M. Mikawa and K. Tanaka, "Real-time hand motion estimation using emg signals with support vector machines", in *IEEE. 2006 SICE-ICASE International Joint Conference*. 2006. [S.l.]. p. 593–598, .
- [19] L. Liao, Y. Tseng, H. Chiang and W. Wang, "EMG-based Control Scheme with SVM Classifier for Assistive Robot Arm," in *International Automatic Control Conference (CAC)*, Taoyuan, 2018, pp. 1–5.
- [20] Y. Paul, V. Goyal and R. A. Jaswal, Comparative analysis between svm & knn classifier for emg signal classification on elementary time domain features, in *IEEE. 4th International Conference on Signal Processing, Computing and Control (ISPCC)*. 2017, [S.l.]. p. 169–175.
- [21] H. Caetano and R. Souza, "Eletroulografia utilizada em interface homem-máquina como uma ferramenta de tecnologia assistiva." Núcleo de Tecnologias Assistivas UFU, 2015.
- [22] E.Olimex, "Shield manual, olimex, bulgaria (2014)". Disponível: <https://www.olimex.com/Products/Duino/Shields/SHIELD-EKGEMG>, 2015.



Francisco José Prado Junior possui graduação em Engenharia de Computação (2017) e Mestrando em Engenharia Elétrica e de Computação pela Universidade Federal do Ceará (UFC). Possui experiência em Educação Inclusiva, desenvolvimento de Tecnologias Assistivas e desenvolvimento de hardware e software.



Flávio Vasconcelos dos Santos é estudante do último semestre de Engenharia Elétrica pela Universidade Federal do Ceará (UFC - Campus Sobral). Possui conhecimento em machine learning, processamento digital de sinais, reconhecimentos de padrões e transmissão de ondas eletromagnéticas, além de experiência no tema de tecnologias assistivas.



Carlos Alexandre Rolim Fernandes possui graduação em Engenharia Elétrica pela Universidade Federal do Ceará - UFC (2003), mestrado pela UFC (2005) em Engenharia de Teleinformática, *Master 2 Recherche* pela *Université de Nice - Sophia Antipolis - UNSA/França* (2005) e doutorado em cotutela pela UNSA/FR e UFC (2009), na área de processamento de sinais. Foi professor substituto da UNSA/França em 2008/2009 e realizou pós-doutorado na UFC de jul/09 a fev/2010 na mesma área. Desde mar/10 é professor associado do curso

de Engenharia da Computação do Campus Sobral da UFC. É fundador e ex-coordenador do Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPGEEC) do Campus Sobral da UFC. Atualmente, é membro do PPGEEC/UFC Sobral e do Programa de Pós-Graduação em Engenharia de Teleinformática (PPGETI/UFC). É coordenador do Grupo de Tecnologias Assistivas e Educacionais (Grupo TAE), um grupo de pesquisa e extensão do Campus Sobral da UFC com diversos projetos concluídos e em andamento nas áreas de tecnologias assistivas para pessoas com deficiência e na área de tecnologias educacionais, em parceria com diversas instituições da sociedade. Seus principais temas de pesquisa envolvem tecnologias assistivas, processamento de sinais, reconhecimento de padrões, álgebra multilinear (tensorial), sistemas não lineares, comunicações sem fio, etc.