

Modelo computacional para classificação de sinais EEG

Automatização do processo para acionamento de cadeira de rodas inteligente

Luiza Andrade da Costa Tourinho

Programa de Pós-graduação em Automação, Controle e Robótica
SENAI CIMATEC
Salvador, Brasil
luizatourinho@hotmail.com

Oberdan Rocha Pinheiro

Programa de Pós-graduação em Automação, Controle e Robótica
SENAI CIMATEC
Salvador, Brasil
oberdan.pinheiro@gmail.com

Resumo— Pessoas com comprometimentos motores e neurológicos possuem pouco controle sobre partes do corpo, por isso têm grande dificuldade de locomoção. Os sinais de eletroencefalograma (EEG) podem ser utilizados como fonte de informação que permita a comunicação entre o cérebro e uma cadeira de rodas inteligente (CRI). Várias técnicas têm sido propostas para reconhecer padrões durante a imaginação do movimento por meios da análise de EEG. As redes neurais artificiais são amplamente utilizadas para a tarefa de classificação por apresentarem um referencial teórico vasto e um bom desempenho diante de problemas complexos. Este trabalho de investigação teve por objetivo o desenvolvimento de um modelo computacional para análise, classificação e acionamento de uma CRI através de sinais EEG provenientes da imaginação motora de movimentos do punho esquerdo, direito, ambos os punhos e ambos os pés. O modelo é composto de três módulos: aquisição de sinal, processamento do sinal e acionamento da CRI. Os sinais EEG foram adquiridos através do banco de dados *eegmidb – EEG Motor Movement/Imagery Dataset*, capturado através do sistema BCI2000, foram utilizadas amostras de sinais EEG de 9 indivíduos. Os resultados obtidos mostram que o modelo computacional teve um desempenho acima de 81% na classificação correta da imaginação de movimentos. O método baseado em árvore de decisão (C4.5) apresentou melhor desempenho em relação os métodos de máquinas de vetores de suporte (SVM) e redes neurais (RN). As técnicas utilizadas são promissoras, podendo ser utilizadas na classificação de padrões de imagem de movimentos, tornando viável a sua utilização em uma interface cérebro-computador.

Keywords— *Interface cérebro-computador; Cadeira de rodas inteligente; EEG.*

I. INTRODUCTION

O ser humano tem necessidade de interagir com o ambiente ao seu redor, as pessoas com mobilidade reduzida acaba modificando sua rotina passando a ocupar-se de atividades pouco ativas, reduzindo seu desempenho físico, suas habilidades motoras e sua capacidade de coordenação. Esses efeitos não favorecem a manutenção de um estilo de vida saudável, levando essas pessoas ao isolamento social e à solidão, as interfaces cérebro-computador são tecnologias de comunicação que permitem as pessoas interagirem com diferentes tipos de

equipamentos ou máquinas. Uma interface cérebro-computador é um sistema que propicia um canal de comunicação ou controle para um indivíduo através de sinais puramente cerebrais, sem que haja necessidade de atividade neuromuscular para realizar ação codificada no sinal cerebral [1]. Pessoas com mobilidade reduzida sofrem déficit de aptidões físicas, força e mobilidade, o que limita a independência e capacidade funcional dessas pessoas. Trata-se de limitações que compromete a independência funcional e na socialização, contribuindo negativamente à qualidade de vida dessas pessoas. Portanto, faz-se necessário o desenvolvimento de tecnologias que promova a melhoria na qualidade de vida, tanto das pessoas com comprometimentos motores e neurológicos como de familiares, aumentando as capacidades físicas remanescentes e independência no cotidiano.

Embora as dificuldades de mobilidade das pessoas com comprometimentos motores e neurológicos possam ser diminuídas com o uso de cadeiras de rodas motorizadas, em alguns casos, a sua utilização de forma independente ainda é um desafio [2]. Nos últimos anos houve um grande avanço no desenvolvimento tecnológico das interfaces cérebro-computador, uma das áreas em que essas tecnologias têm tido grande aplicabilidade é na ampliação da mobilidade para pessoas com graves deficiências motoras. Através das técnicas de processamento de sinais e reconhecimento de padrões é possível extrair informações importantes dos sinais emitidos por um processo de EEG. Entretanto, a interpretação das diversas faixas de frequências dos sinais cerebrais de uma forma mais precisa ainda representa grandes desafios [3].

As ondas cerebrais são captadas através de eletrodos, posicionados em pontos específicos da cabeça, geralmente através de sua superfície externa, as interface cérebro-computador possibilita a pessoas com mobilidade reduzida um novo meio de comunicação, uma vez que não dependem dos canais de saída normais como nervos e músculos [4]. É importante ressaltar que devido a baixa resolução espacial, da grande atenuação e espalhamento sofridos pelo sinal na passagem pelo crânio, é necessário usar técnicas de processamento de sinais e reconhecimento de padrões para

melhorar a relação sinal-ruído e o desempenho das interfaces cérebro-computador baseadas em EEG.

Dessa forma, este trabalho de investigação pretende desenvolver um modelo computacional para análise, classificação e acionamento de uma CRI através de sinais EEG provenientes da imaginação motora de movimentos do punho esquerdo, direito, ambos os punhos e ambos os pés, com o objetivo de minimizar a dependência social que as pessoas com comprometimentos motores e neurológicos tem da sociedade.

II. INTERFACE CÉREBRO-COMPUTADOR

Uma interface cérebro-computador é um sistema que propicia um canal de comunicação ou controle para um indivíduo através de sinais puramente cerebrais, sem que haja necessidade de atividade neuromuscular para realizar a ação codificada no sinal cerebral [5]. Os indivíduos com paralisia neuromuscular severa são os que representam o público alvo das interfaces cérebro-computador [6]. A eletroencefalografia é um método para medição de potenciais elétricos no escalpo do indivíduo, resultantes de atividade elétrica neuronal no encéfalo. Os primeiros estudos relacionados aos potenciais elétricos do cérebro foram realizados no ano de 1875, pelo fisiologista inglês Richard Caton [7]. Existem quatro elementos essenciais para o funcionamento correto de uma interface cérebro-computador, esses elementos têm que trabalhar em conjunto para compreenderem e executarem a intenção do usuário [5], são eles:

- Aquisição de sinal - é uma medição em tempo real do estado eletrofisiológico do cérebro. A atividade do cérebro é normalmente medida por diferenças de voltagem gravadas por eletrodos.
- Processamento de sinal – a análise das características do sinal e a conversão do sinal em comandos de máquina.
- Dispositivo de saída – objeto controlado através de funções e comandos enviados pela interface.
- Protocolo – regras implementadas para comunicação entre componentes da interface e os dispositivos de Saída.

A aquisição dos sinais cerebrais utiliza técnicas e métodos para o procedimento, que se dividem em duas principais categorias:

- Invasiva – utilizam eletrodos intracranianos para aquisição dos dados, o que permite um sinal com menos ruído e um alto nível de controle sobre os dispositivos. Os estudos com eletroencefalografia invasiva teve início na década de 60 pelo cientista alemão Eberhard Fetz, através da análise dos neurônios localizados no córtex motor primário, associados ao processo de movimento corporal. Estes estudos tinham a intenção de levar os movimentos comandados pelo cérebro à dispositivos eletrônicos [8]. Os desenvolvimentos feitos utilizando esse método tem sido feito em macacos. Em 2000, em [9] foram instalados entre 32 e 96 microeletrodos em diferentes áreas do córtex motor. Após um período de treino os macacos conseguiram controlar um dispositivo robótico nas três dimensões. Em 2006 começaram a ser

feitos estudo em humanos, uma matriz de 96 microeletrodos foi implantada no córtex motor de um paciente tetraplégico [10]. A intenção de movimento das mãos gerou atividade de grupos de neurônios no córtex motor primário que foi usada para mover um cursor.

- Não Invasiva – Os primeiros estudos com eletroencefalograma não invasiva foram realizados durante os anos 60, e permitiram que pessoas controlassem os seus níveis de concentração e atenção [8]. As ondas cerebrais são produzidas principalmente quando estamos acordados de olhos fechados, e estão associadas à inativação de áreas do córtex que não estão sendo utilizadas [6], assim pessoas foram capazes de controlar os padrões das ondas alfa através de técnicas de relaxamento. Esse método não necessita da introdução de eletrodos no interior do crânio ou mesmo de qualquer tipo de procedimento cirúrgico. Esta técnica é menos precisa quando se trata de qualidade de sinal e mesmo quanto ao maior nível de ruído produzido, por outro lado é mais simples [8]. Os sinais são obtidos com uma largura de banda mais limitada, suscetíveis a sobreposições e interferências de sinais diversos. Entretanto, possui aplicabilidade suficiente para ativar comandos computacionais, por exemplo, mover uma cadeira de rodas inteligente.

Pessoas com mobilidade reduzida sofrem déficit de aptidões físicas, força, mobilidade e exibibilidade, o que limita a independência e capacidade funcional dessas pessoas. Trata-se de limitações que compromete a independência funcional e na socialização, contribuindo negativamente à qualidade de vida dessas pessoas. Portanto, faz-se necessário o desenvolvimento de tecnologias que promova a melhoria na qualidade de vida, tanto das pessoas com comprometimentos motores e neurológicos como de familiares, aumentando as capacidades físicas remanescentes e independência no cotidiano. Os avanços alcançados na área da neurociência possibilita o desenvolvimento de sistemas baseados em interface cérebro-computador. Através das técnicas de processamento de sinais e reconhecimento de padrões é possível extrair informações importantes dos sinais emitidos por um processo de eletroencefalograma. Entretanto, a interpretação das diversas faixas de frequências dos sinais cerebrais de uma forma mais precisa ainda representa grandes desafios [11].

III. TRABALHOS RELACIONADOS

Cadeiras de rodas inteligentes são alvos de investigações desde o início da década de 80 e foram desenvolvidas em vários países [13]. Existe interesse no uso das interfaces baseadas em captação de sinais emitidos pelo córtex cerebral como forma de interação entre as pessoas e o meio que as rodeiam. Alguns grupos de pesquisas desenvolveram conceitos fundamentais para a criação de interfaces voltadas para pessoas com graves deficiências motoras. [14] realizaram uma avaliação das principais tecnologias usadas por pessoas com tetraplegia para interagir com computadores. [15] pesquisaram formas alternativas de comunicação, destacando o uso de biosinais como alternativa à pessoas com deficiências motoras graves. [16] apresentou um trabalho aplicável a pessoas com tetraplegia, com foco no controle de cadeiras de rodas motorizadas, que

envolve além de diversas interfaces de entrada também a eletrônica de controle e potência da cadeira de rodas motorizada.

Interfaces cérebro-computador permite melhorar a qualidade de vida de pacientes com deficiência e deixá-los interagir com o ambiente ao seu redor. [17] descreve um sistema baseado em interface cérebro-computador que controla uma cadeira de rodas que se move em apenas uma direção, frente. [18] usa três comandos possíveis: esquerda, direita e frente. Em [19] o sinal EEG foi capturado por oito eletrodos, a transformada wavelet foi usado para a extração de características e redes neural foi utilizada para classificar os movimentos pré-definidos.

O projeto IntellWheels coordenado pelo Professor Luís Reis da Faculdade de Engenharia da Universidade do Porto (Laboratório de Inteligência Artificial e Ciência de Computadores - LIACC) tem como objetivo aumentar a autonomia a e qualidade de vida de pessoas com mobilidade bastante reduzida e consiste numa plataforma que permite transformar qualquer cadeira de rodas elétrica numa cadeira de rodas inteligente. Este projeto inclui todas as funcionalidades habitualmente utilizadas neste tipo de sistemas tal como o reconhecimento facial, controle por voz, por sensores, visualização por computador para apoio na navegação, desvio de obstáculos, planeamento de tarefas de alto nível e a capacidade de comunicação com outros dispositivos [20]. O projeto já foi premiado cinco vezes por várias entidades nacionais e internacionais. A última distinção deve-se ao artigo "Manual, automatic and shared methods for controlling an intelligent wheelchair: Adaptation to cerebral palsy users", desenvolvido por [21]. [22] apresenta um sistema autônomo de controle de uma CRI, aborda uma interface que utiliza eletroencefalografia com um sistema que envolve o monitoramento de sinais que não são criados de uma forma espontânea pela pessoa, mas sim por meio de estímulos visuais e/ou auditivos. [23] conta com um sistema baseado em interface cérebro-computador, utilizando potenciais evocados P300, como forma de comunicação, entre a pessoa e a CRI, existe um módulo de segurança através do controle da trajetória da cadeira de rodas motorizada com o objetivo de tornar a navegação segura.

Observa-se que os projetos de CRI preocupam-se com a adaptabilidade ao indivíduo e com os requisitos de segurança, tendo-se em conta que o objetivo destes projetos são o apoio a pessoas deficientes, o foco deve ser em como complementar as habilidades dessas pessoas. Desta forma, as investigações e os desenvolvimentos não se concentram em criar apenas sistemas autônomos, mas sim, cadeiras de rodas inteligentes que operem de forma semi-autônoma. O projeto de uma interface cérebro-computador é um dos principais pontos a serem abordados no desenvolvimento de uma CRI.

IV. PROJETO DO MODELO COMPUTACIONAL

O projeto mensura a atividade do cérebro, esta atividade é interpretada de modo a detectar diferentes padrões, em seguida comunica-se com o sistema de acionamento da CRI. A Fig. 1 apresenta a arquitetura os componentes da arquitetura do modelo computacional. Os sinais EEG brutos são lidos, em seguida, calcula-se a SFFT dos sinais EEG. O sistema de controle recebe as informações de amplitude e frequência do sinal EEG e os armazenam em um vetor, os quais serão utilizados na fase de

treinamento e caracterização do modelo. Na fase de treinamento e classificação os sinais EEG são analisados durante uma janela de 1 segundo, que se desloca em intervalos de 0.5 segundos, evitando que eventos que ocorrem entre 1 segundo e outro não sejam detectados.

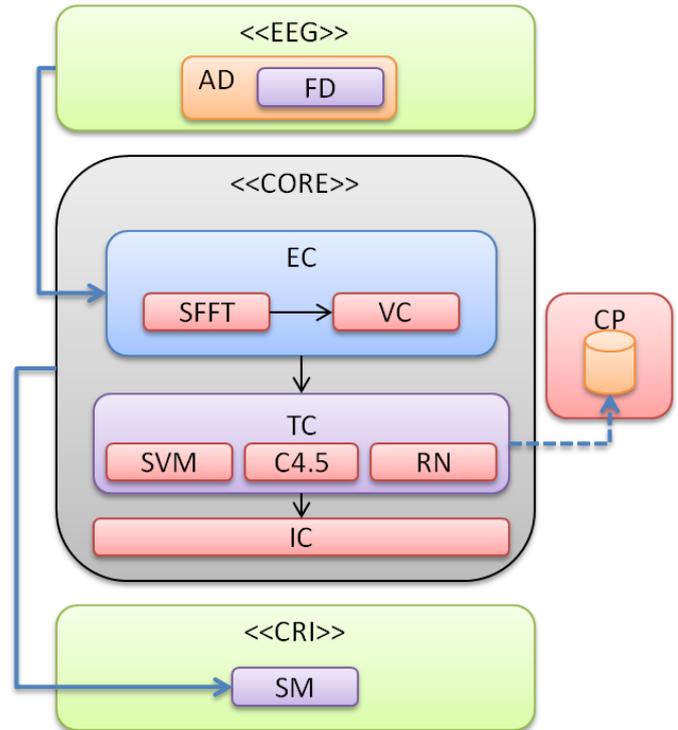


Fig. 1. Arquitetura do modelo computacional.

Durante a fase de treinamento o modelo utiliza 70% das amostras para realizar o treinamento e 30% para validação do mesmo, são utilizados três métodos para treinamento e classificação, a saber:

- SVM (Máquinas de vetores de suporte) – O objetivo de uma SVM é encontrar a melhor função de classificação que permita a distinção entre membros de duas classes num conjunto de treino, são embasadas pela teoria de aprendizado estatístico, desenvolvida por [24]. Para um conjunto de dados linearmente separados, uma função de classificação linear corresponde a um hiperplano $f(x)$ que divide duas classes. No momento em que esta função é determinada, a nova instância x_n é classificada de acordo com o sinal da função $f(x_n)$, x_n pertence à classe positiva se $f(x_n) > 0$ [25]. Uma vez que existe um número extremamente vasto de hiperplanos, o recurso a uma SVM garante que a melhor função é encontrada depois de maximizada a margem entre as duas classes. A margem em questão é a quantidade de espaço ou separação existente entre essas duas classes. Em termos geométricos, a margem corresponde à distância mais curta entre um conjunto de pontos mais próximos entre si e um determinado ponto no hiperplano.
- C4.5 (Árvore de decisão) – Tem como objetivo gerar um modelo classificador na forma de uma árvore de decisão, apresentando dois estados durante o processo, os quais

são: folha que indica um ponto no final da classificação, sendo atribuída a uma classe e nó de decisão, onde baseando-se no atributo em análise, poderá conter uma ramificação seguida de uma folha ou uma subárvore para cada possível valor encontrado na base [26]. O C4.5 gera um classificador capaz de agir como um especialista, classificando inclusive casos desconhecidos. O algoritmo constrói a árvore de decisão através do conjunto de treinamento, combinando uma estrutura de dados em árvore que pode ser usada para classificar novos exemplos. Na construção da árvore de decisão o C4.5 lida com conjuntos de treinamentos que possuem exemplos com valores de atributos desconhecidos, avaliando o ganho considerando apenas registros que possuem atributos definidos [26]. Para a construção da árvore de decisão, inicialmente a mesma é disposta sob a aplicação da regra em que a construção da árvore é finalizada quando todos os exemplares associados a um nó pertencem a mesma classe ou se algum critério de parada for especificado. Em seguida, é realizada uma simplificação da árvore de decisão, cada subárvore é avaliada e reduzida a uma fração equivalente, as que forem consideradas insignificantes no processo de aumento significativo da precisão do conjunto.

- RN (Redes neurais) – É um processador maciçamente e paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso [27]. O algoritmo de aprendizagem da rede neural tem por objetivo atualizar os valores dos pesos sinápticos entre os neurônios da rede, de modo que a rede se adapte ao problema e evolua para achar uma solução. O fundamental no processo de aprendizagem é definir como tais pesos serão alterados quando se requer que a rede aprenda uma nova informação. Para o modelo de aprendizado, existe um supervisor que determina a resposta que a rede deverá dar para uma entrada determinada. O supervisor verifica a saída da rede e, caso ela não coincida com a saída desejada, faz um ajuste nos pesos das conexões visando minimizar esta diferença. O ajuste é realizado visando minimizar o erro cometido, ou seja, a diferença entre a saída da rede e a saída desejada.

Após o treinamento do modelo utilizando os três métodos (SVM, C4.5 e RN), o modelo realiza testes de classificação e ao final compara o percentual de acerto entre os três métodos, dessa forma o modelo seleciona o melhor entre os métodos e registra uma instância da classe do classificado para posterior utilização do sistema.

Os componentes da arquitetura, especificados resumidamente a seguir têm funções específicas.

A. AD (Aquisição de dados)

O componente AD é responsável pelo registro da atividade elétrica cerebral, com boa relação sinal-ruído. Os sinais EEG amplificados são filtrados através do componente FD (Filtro digital) passa-faixa, cujas frequências variam de acordo com o potencial analisado, nesse projeto os sinais foram filtrados em uma faixa de 0,5 a 42 Hz, por estarem relacionados ao

movimento e à imaginação do movimento [28], esquema ilustrado na Fig. 2.

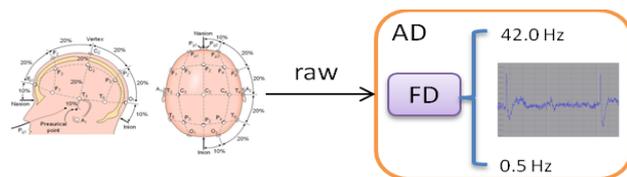


Fig. 2. Comportamento do componente AD.

B. EC (Extração de características)

O componente EC é responsável pela recepção dos dados brutos filtrados pelo componente FD, após a recepção desses dados o componente EC cria uma instância do componente SFFT (*Sparse Fast Fourier Transform*), esse componente, por sua vez, calcula a transformada Fourier de curto tempo do sinal de entrada. Pode-se observar na Fig. 3, que após o cálculo da SFFT o componente VC (Vetor de características) calcula a partir do sinal de entrada alguns os atributos.

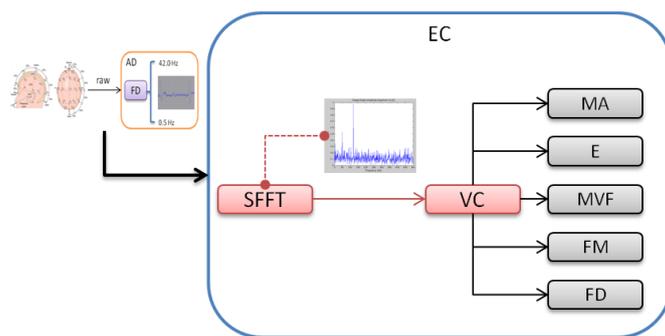


Fig. 3. Comportamento do componente EC.

O vetor de características é composto por alguns atributos que contém o padrão a ser analisado pelo componente de treinamento e classificação. Esses atributos são:

- MA (Média aritmética) – Representa o valor médio do sinal o atributo é calculado pela (1).

$$m(s) = \frac{1}{N} \sum_{n=1}^N s[n] \quad (1)$$

- E (Energia) – Representa à área sob a curva descrita pela função do sinal elevada ao quadrado, conforme (2).

$$E_2(s) = \frac{1}{N} \sum_{n=1}^N |s[n]|^2 \quad (2)$$

- MVF (Máximo valor da transformada de Fourier) – Representa o ponto onde ocorre o máximo valor da curva da SFFT, conforme (3).

$$MVF(s) = \max(S[n]) \quad (3)$$

- FM (Mínimo valor da transformada de Fourier) – Representa o ponto onde ocorre o valor mínimo da transformada de Fourier, conforme (4).

$$FM(s) = \min(S[n]) \quad (4)$$

- FD (Frequência dominante) – Representa a frequência que possui maior amplitude. A Fig. 4 ilustra a frequência principal que é 0.914183 Hz.

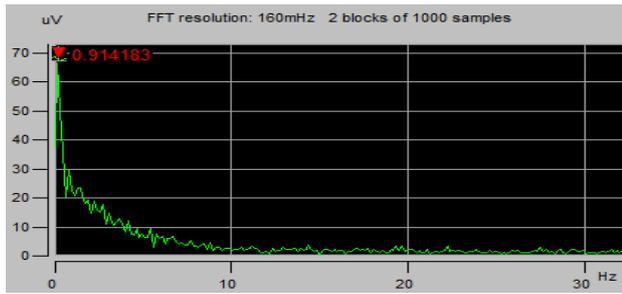


Fig. 4. Frequência dominante.

A frequência dominante é a coordenada X do ponto onde ocorre o máximo valor da curva da FFT.

C. TC (Treinamento e classificação)

O componente TC é responsável pelo treinamento e criação dos classificadores do modelo. A Fig. 5 apresenta o esquema de comportamento do componente TC.

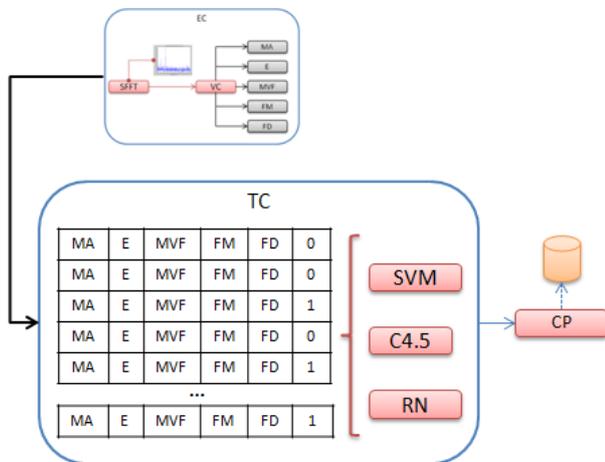


Fig. 5. Comportamento do componente TC.

Durante a fase de treinamento, o TC extrai os dados do vetor de características, em seguida cria um novo vetor contendo dados para o treinamento, obedecendo a seguinte ordem de atributos:

- Primeiro atributo – Contém o registro da média aritmética do sinal.
- Segundo atributo – Contém o registro da energia do sinal.
- Terceiro atributo – Contém o registro do máximo valor da transformada de Fourier.
- Quarto atributo – Contém o registro do mínimo valor da transformada de Fourier.
- Quinto atributo – Contém o registro da frequência dominante.
- Sexto atributo – Contém a informação que caracteriza a classe referente ao conjunto de dados: 0 (corresponde a

um exemplo falso) e 1 (corresponde a um exemplo verdadeiro).

Os dados extraídos são utilizados pelos algoritmos de treinamento (SVM, C4.5 e RN), cujo objetivo é identificar as características ou padrões úteis à classificação correta dos dados. Após o aprendizado ter sido realizado, é aplicada uma avaliação, onde podemos verificar medidas estatísticas dos resultados alcançados. A avaliação do algoritmo treinado deve ser realizada utilizando dados não vistos pelo algoritmo. A utilização de dados inéditos fornecerá medidas realistas sobre o desempenho do algoritmo. O conjunto de dados é dividido em dados de treinamento e de teste, sendo 70% para treinamento e 30% para validação. O modelo utiliza aprendizagem supervisionada, ou seja, utiliza dados com a classe especificada, cada instância contém um atributo classe que especifica a qual classe ela pertence (0 ou 1), uma instância é uma linha do vetor de treinamento. Após essas tarefas o modelo compara o percentual de acerto entre os três algoritmos de classificação (SVM, C4.5 e RN) e armazena o classificador que teve o maior percentual de acerto durante a fase de testes, através do componente CP (Classificador padrão).

Essa etapa é utilizada para cada uma das possíveis direções, ou seja, serão criados quatro classificadores especializados, cada um representando uma intenção de direção: direita, esquerda, frente e parar. O TC só envia o comando de acionamento a CRI caso o somatório dos quatro classificadores seja igual a 1. A estratégia de especialização dos classificadores permite aumentar o desempenho de detecção de padrões e discriminar corretamente os padrões alvos, reduzindo os falsos positivos.

D. IC (Interface de controle)

O componente IC é responsável pelo acionamento da CRI, o IC simula em sua saída os mesmos sinais analógicos do joystick original da cadeira de rodas, consistindo em uma adaptação do circuito já existente. A Fig. 6 apresenta o esquema de comportamento do componente IC.

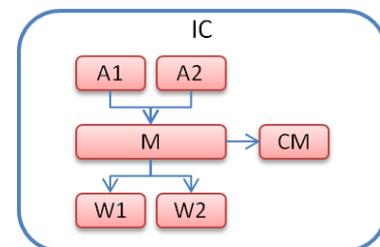


Fig. 6. Comportamento do componente IC.

Inicialmente o IC passa por um processo simples de reconhecimento de sinais medidos em volts, esse processo consiste na leitura das faixas de tensões do joystick original da cadeira de rodas, os componentes A1 e A2 representam duas entradas analógicas respectivamente, cujo objetivo é realizar a leitura dos sinais de entrada do circuito microcontrolado da cadeira de rodas e a partir dessa leitura armazenar os valores de tensão que representam as direções: frente, direita, esquerda e parar, em seguida esses valores são registrados pelo componente CM (Chip de memória), responsável por manter os registros dos

algoritmo C4.5 apresentou maior percentual de classificação correta para a imaginação de movimento que representa a direção direita, ou seja, das 441 amostras utilizadas nos testes, 363 foram classificadas corretamente, totalizando um percentual de acertos de 82.31%, é possível observar que o índice de confiabilidade (*kappa*) do algoritmo C4.5 obteve o valor 0.23, maior valor entre os métodos SVM e RN, ambos com valor 0.

Para o treinamento e validação do classificador frente, foram selecionadas 1491 instâncias. A tabela III apresenta os resultados obtidos para o classificador frente.

TABLE III. RESULTADO DO CLASSIFICADOR FRENTE

Método	Classificação correta	Classificação incorreta	Kappa
RN	79.4183 %	20.5817 %	0.1055
C4.5	89.038 %	10.962 %	0.6554
SVM	78.5235 %	21.4765 %	0

O método baseado no algoritmo C4.5 apresentou maior percentual de classificação correta para a imaginação de ambos os punhos que representa a direção frente, ou seja, das 447 amostras utilizadas nos testes, 398 foram classificadas corretamente, totalizando um percentual de acertos de 89%, é possível observar que o índice de confiabilidade (*kappa*) do algoritmo C4.5 obteve maior valor entre todos, sendo 0.65.

Para o treinamento e validação do classificador parar, foram selecionadas 1680 instâncias. A tabela IV apresenta os resultados obtidos para o classificador.

TABLE IV. RESULTADO DO CLASSIFICADOR PARAR

Método	Classificação correta	Classificação incorreta	Kappa
RN	80.754 %	19.246 %	-0.0078
C4.5	81.3492 %	18.6508 %	0.0883
SVM	81.1508 %	18.8492 %	0

O método baseado no algoritmo C4.5 apresentou maior percentual de classificação correta para a imaginação de ambos os punhos que representa a direção frente, ou seja, das 504 amostras utilizadas nos testes, 410 foram classificadas corretamente, totalizando um percentual de acertos de 81,34%, é possível observar que o índice de confiabilidade (*kappa*) do algoritmo C4.5 obteve maior valor entre todos, sendo 0.08.

Em um segundo momento avaliou-se o sistema de interface de acionamento da CRI, foi necessário realizar a aquisição dos valores de tensão do joystick original de uma cadeira de rodas comercial, utilizamos joystick da cadeira de rodas motorizada “Freedom Carbon”. O joystick da cadeira de rodas envia sinais para um circuito embarcado, dessa forma, de acordo com o movimento executado na alavanca do joystick são enviados dois sinais de tensão ao circuito do microcontrolador, que por sua vez interpreta e envia outros sinais ao sistema de motorização da cadeira de rodas para realizar os movimentos desejados. A Fig. 8 ilustra o circuito do microcontrolador, destacando-se o

PIC e barramento onde são enviados os sinais do joystick diretamente ao circuito.



Fig. 8. Sistema de acionamento da cadeira de rodas.

Dessa forma desenvolvemos um circuito que faz a mesma função do joystick, enviando sinais de saída PWM ao circuito do microcontrolador para controlar os movimentos da cadeira de rodas. Em resumo, o circuito simula em sua saída os mesmos sinais analógicos do joystick original da cadeira de rodas, consistindo em uma adaptação do circuito já existente. Para o desenvolvimento da interface de acionamento da cadeira de rodas, foi utilizado o arduino UNO®, justifica-se a escolha do arduino, por se tratar de uma plataforma *opensource* baseada em *hardware* e *software* de fácil utilização. A Fig. 9 ilustra o esquema com os fios de ligação do circuito do microcontrolador original do joystick.

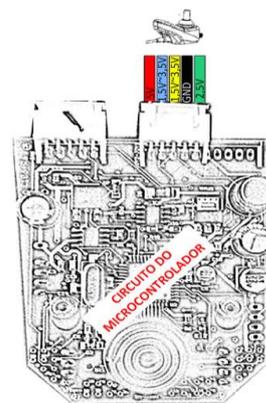


Fig. 9. Esquema de conexão entre o joystick e o circuito do microcontrolador.

O joystick controla as tensões que são enviadas aos fios azul e amarelo dos barramentos. O fio azul controla as ações de ir para frente ou ir para trás, enquanto que o fio amarelo controla as ações de ir para esquerda ou direita. Para que o sistema de acionamento pudesse aprender os valores de tensões e posteriormente controlar a cadeira de rodas, foi necessário conectar os sinais de saídas do joystick original em duas entradas analógicas do arduino. A tabela V apresenta os respectivos valores de tensão dos sinais do barramento controlado pelo joystick original e de que forma eles alteram o movimento da cadeira de rodas. Esses valores foram registrados pela interface de acionamento para posterior aplicação dos mesmos no circuito de controle da cadeira de rodas.

TABLE V. TENSÃO DOS SINAIS DO BARRAMENTO CONTROLADO PELO JOYSTICK E OS MOVIMENTOS

<i>Entrada</i>	<i>Parado</i>	<i>Direita</i>	<i>Esquerda</i>	<i>Frente</i>
A0	2.5 volts	2.5 volts	2.5 volts	3.5 volts
A1	2.5 volts	1.5 volts	3.5 volts	2.5 volts

É possível controlar os movimentos da cadeira de rodas variando os valores de tensão, assim, basta à interface de acionamento enviar os respectivos sinais a esses pinos. No entanto, vale destacar que a interface de acionamento tem algumas proteções de erro, de forma que enviando tensões fora das faixas especificadas nos respectivos fios faz com que a cadeira seja travada e nenhum movimento possa ser realizado.

VI. CONCLUSÃO

Este trabalho de investigação propõe um modelo computacional para análise e classificação de sinais EEG através da imaginação de movimentos com o objetivo de contribuir para a melhoria da qualidade de vida das pessoas com graves comprometimentos motores e neurológicos disponibilizando-lhes um meio de interação adaptado as suas limitações. Interfaces cérebro-computador permitem um método de comunicação baseado na atividade cerebral, independentemente da não realização dos movimentos musculares que os comandos cerebrais geram. Neste trabalho a coleta de sinais EEG utilizou o método não invasivo, o modelo avaliou três métodos de classificação para identificar padrões a partir de sinais cerebrais que correspondam a movimentos (esquerda, direita, frente e parar) originados a partir da imaginação de movimentos do punho esquerdo, punho direito, ambos os punhos e ambos os pés. Os testes foram realizados através dos sinais EEG de 9 indivíduos, extraídos a partir do banco de dados *egmmidb – EEG Motor Movement/Imagery Dataset*. A partir dos resultados dos experimentos foi possível observar que o método C4.5 teve percentual de acerto superior em relação aos métodos RN e SVM. O modelo contempla classificadores especialistas em cada uma das direções, o objetivo da especialização é minimizar os falsos positivos. O classificador esquerdo alcançou o percentual de acerto igual 87.65%, o classificador direito alcançou 82.31% de acerto, o classificador frente alcançou 89% e o classificador parar alcançou 81,34%. Como trabalhos futuros pretende-se testar o modelo a partir de um sensor EGG comercial, realizar mais testes entre a interface de acionamento e a CRI e por fim avaliar o desempenho do sistema de forma *online*.

REFERENCES

- [1] J. R. Wolpaw, N. Birbaumer, W. J. Heetderks, D. J. McFarland, P. H. Peckham, G. Schalk, E. Donchin, L. A. Quatrano, C. J. Robinson and T. M. Vaughan, "Brain-computer interface technology: a review of the first international meeting," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 164-173, Jun 2000.
- [2] M. Petry, A Vision-based Approach Towards Robust Localization for Intelligent Wheelchairs. University of Porto, Porto, 2013.
- [3] E.J. Tehovnik, L.C. Woods and W.M. Slocum, Transfer of information by BMI, *Neuroscience*, Volume 255, 26 December 2013, Pages 134-146.
- [4] Wenjie Xu, Cuntain Guan, Chng Eng Siong, S. Ranganatha, M. Thulasidas and Jiankand Wu, "High accuracy classification of EEG signal," *Pattern Recognition*, 2004. ICPR 2004. Proceedings of the 17th International Conference on, 2004, pp. 391-394 Vol.2.
- [5] J. R. Wolpaw *et al.*, "Brain-computer interface technology: a review of the first international meeting," in *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 164-173, Jun 2000.
- [6] J. R. Wolpaw *et al.*, "BCI meeting 2005-workshop on signals and recording methods," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 14, no. 2, pp. 138-141, June 2006.
- [7] L. F. Haas, Hans berger (1873-1941), richard caton (1842-1926), and electroencephalography. *Journal of Neurology, Neurosurgery Psychiatry*, v. 74, n. 1, p. 9, 2003.
- [8] J. R. Wolpaw. Brain-computer interfaces as new brain output pathways. *Physiology*, v. 579, n. 3, p. 613-619, Jan 2007.
- [9] K. Chapin, J. Kim, J. Biggs, A. Srinivassan and A. Nicolelis, Real-time prediction of hand trajectory by ensembles of cortical neurons in primates. *Nature*, v. 408, p. 361-365, Nov 2000.
- [10] L.R. Hochberg, M.D. Serruya, G.M. Friehs, J.A. Mukand, M. Saleh, A.H. Caplan, A. Branner, D. Chen, R.D. Penn and J.P. Donoghue, Neuronal ensemble control of prosthetic devices by a human with tetraplegia. *Nature*, v. 442, p. 164-171, Jul 2006.
- [11] E.J. Tehovnik, L.C. Woods and W.M. Slocum, Transfer of information by BMI, *Neuroscience*, Volume 255, p. 134-146, 2013.
- [12] Héctor A. Caltenco , Björn Breidegard , Bodil Jönsson and Lotte N.S. Andreasen Struijk, Understanding computer users with tetraplegia: Survey of assistive technology users. Taylor & Francis Group, v. 28, n. 4, p. 258-268, 2012.
- [13] R. C. Simpson, Smart wheelchairs: A literature review. *Journal of Rehabilitation Research Development*, v. 42, n. 4, p. 423 - 438, 2005.
- [14] H. A. Caltenco, B. J. Breidegardb, B. Jönssonb and L. N. S. Andreasen Struijka, Understanding computer users with tetraplegia: Survey of assistive technology users. Taylor & Francis Group, v. 28, n. 4, p. 258-268, 2012.
- [15] C. G. Pinheiro, L. M. N. Eduardo, P. Pierre, L. Etienne, A. O. Adriano and B. Guy, Alternative communication systems for people with severe motor disabilities: a survey. *Biomedical engineering online*, v. 10, n. 1, p. 10 - 31, 2011.
- [16] M. Mazo, An integral system for assisted mobility [automated wheelchair]. *IEEE Robotics Automation Magazine*, v. 8, n. 1, p. 46-56, Mar 2001.
- [17] R. Leeb, V. Settgast, D. Fellner and G. Pfurtscheller, *International Journal of Bioelectromagnetism*, Vol. 9, No.4, pp. 237 - 244, 2007.
- [18] A. Fattouh, O. Horn and, G. Bourhis. Emotional BCI Control of a Smart Wheelchair. *IJCSI International Journal of Computer Science Issues*, Vol. 10, Issue 3, No 1, May 2013.
- [19] V. Khare, J. Santhosh, S. Anand and M. Bhatia. Brain Computer Interface Based Real Time Control of Wheelchair Using Electroencephalogram. *International Journal of Soft Computing and Engineering (IJSCE)* ISSN:2231-2307, Volume-1, Issue-5, Nov. 2011.
- [20] R. A. M. Braga, M. Petry, L. P. Reis, and A. P. Moreira, *Intellwheels: Modular development platform for intelligent wheelchairs*. v. 48, n. 9, p. 1061-1076, 2011.
- [21] B.M. Faria, L. P. Reis, N. Lau, Manual, automatic and shared methods for controlling an intelligent wheelchair: Adaptation to cerebral palsy users. In: *Autonomous Robot Systems (Robotica)*, 2013 13th International Conference on. [S.l.: s.n.], p. 1-6, 2013.
- [22] B. Rebsamen *et al*, A brain controlled wheelchair to navigate in familiar environments. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 18, n. 6, p. 590-598, Dec 2010.
- [23] T. Carlson and J. R. Millan, Brain-controlled wheelchairs: A robotic architecture. *IEEE Robotics Automation Magazine*, v. 20, n. 1, p. 65-73, Mar. 2013.
- [24] V. N. Vapnik. The nature of Statistical learning theory. Springer-Verlag, New York, 1995.
- [25] Xindong Wu, Vipin Kumar, J. Ross Quinlan, Joydeep Ghosh, Qiang Yang, Hiroshi Motoda, Geoffrey J. McLachlan, Angus Ng, Bing Liu, Philip S. Yu, Zhi-Hua Zhou, Michael Steinbach, David J. Hand, and Dan Steinberg. Top 10 algorithms in data mining. London: Springer-Verlag, 2007.

- [26] J. R. Quinlan, C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers, 1993.
- [27] S. Haykin. Unsupervised Adaptive Filtering, Volume 1: Blind Source Separation, John Wiley & Sons, 2000.
- [28] David Prutchi and Michael Norris, Design and Development of Medical Electronic Instrumentation: A Practical Perspective of the Design, Construction, and Test of Medical Devices, New Jersey: John Wiley Sons, 2005.
- [29] G. Pfurtscheller, et al. 15 years of bci research at graz university of technology: current projects. IEEE Transactions on Neural Systems and Rehabilitation Engineering, v. 14, n. 2, p. 205-210, Jun 2006.
- [30] J. G. Webster, Medical Instrumentation Application and Design. 4th edition. ed. Nova York: John Wiley Sons, 2009.
- [31] G. Schalk, D.J. McFarland, T. Hinterberger, N. Birbaumer, J.R. Wolpaw, BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. IEEE Transactions on Biomedical Engineering 51(6):1034-1043, 2004.
- [32] Schalk G. et al. BCI2000: a general-purpose braincomputer interface (BCI) system. IEEE Trans Biomed Eng, v. 51, n. 6, p. 1034–1043, jun. 2004.