

REDES NEURAIS ARTIFICIAIS APLICADAS NA DETECÇÃO DE PISCADAS DE OLHOS

DANIEL C. CAVALIERI, ALEXANDRE S. BRANDÃO, ANDRÉ FERREIRA, TEODIANO F. BASTOS FILHO,
MÁRIO SARCINELLI FILHO E ALESSANDRO B. BENEVIDES,

Dept^o de Engenharia Elétrica, Universidade Federal do Espírito Santo - UFES
Av. Fernando Ferrari, 514
CEP 29075-910 - Vitória ES, Brasil

*E-mails: {daniel, abrandao, andrefer, tfbastos,
mario.sarcinelli}@ele.ufes.br, sandrobotti@gmail.com*

Abstract— This work presents an automatic system for recognizing eye blinks, which uses signal processing techniques and neural networks. Initially, the peak value and the interval of duration of any eye blink are estimated. After, feed-forward neural networks are used, whose structure is based on an input layer, an intermediate layer and an output layer, which are trained with the *Bayesian Regularization* (BR), *Resilient Backpropagation* (RP) and *Scaled Conjugate Gradient* (SCG) algorithms. A total amount of 420 blinks produced by individuals randomly selected are used in the tests here performed, 210 of them corresponding to eye-blinks produced by the right eye and 210 of them corresponding to eye-blinks produced by the left eye. Besides this, 210 software-generated Gaussian random noise signals are adopted. For the system validation, a simulator of the mobile robot Pioneer 2-DX is used, for which the path to be followed is determined by combining commands generated by eye-blinks. The conclusion is that the algorithms adopted are able to detect the signal peaks and intervals of duration, regarding the eye-blink signals, while the different Artificial Neural Networks tested showed to be able to detect and to satisfactorily distinguish the eye-blinks.

Keywords— Digital signal processing, eletromiogram, neural networks.

Resumo— O presente trabalho tem como objetivo a criação de um sistema de reconhecimento automático de piscadas de olhos, utilizando para isso técnicas de processamento de sinais e redes neurais artificiais. Algoritmos para detecção dos picos e dos intervalos de duração das piscadas são aqui utilizados. Utilizaram-se redes neurais do tipo *feedforward*, com uma camada de entrada, uma intermediária e uma de saída, treinadas com os algoritmos *Bayesian Regularization* (BR), *Resilient Backpropagation* (RP) e *Scaled Conjugate Gradient* (SCG). Foram utilizadas 420 piscadas de indivíduos selecionados aleatoriamente, sendo 210 amostras relativas às piscadas do olho direito e 210 relativas ao olho esquerdo, além de 210 ruídos aleatórios gaussianos gerados por software. Para a validação do sistema, utilizou-se um simulador do robô móvel Pioneer 2-DX, em que o caminho a percorrer é determinado a partir da combinação de comandos gerados pelas piscadas dos olhos. A conclusão é que os algoritmos utilizados foram capazes de detectar os picos e os respectivos intervalos de duração das piscadas, enquanto as Redes Neurais Artificiais criadas foram capazes de detectar e distinguir, satisfatoriamente, as piscadas dos olhos.

Palavras-chave— Processamento digital de sinais, eletromiograma, redes neurais artificiais.

1 Introdução

As disfunções de origem neuromotoras constituem uma das principais causas de problemas associados à fala e à comunicação de indivíduos com deficiência e o ambiente que os cerca. No entanto, normalmente estas pessoas mantêm um perfeito estado de consciência, o que permite que algumas técnicas sejam desenvolvidas para provê-las de meios pelos quais possam se comunicar de maneira eficaz (Toniolo, 2005). Uma solução largamente estudada atualmente é a utilização de sinais biológicos associados a recursos computacionais específicos que possibilitem, por exemplo, que pessoas com deficiência motora utilizem interfaces, tais como tabuleiros pictográficos, os quais são utilizados como instrumento de ajuda na comunicação e aprendizagem de crianças com capacidade de fala limitada. Dentro deste contexto, são utilizados os sinais mioelétricos (SME). A idéia consiste em reconhecer as piscadas de olhos, contidas em SMEs adquiridos da face, para possível seleção dos símbolos pictográficos em um tabuleiro pictográfico.

Existem várias técnicas de reconhecimento de padrões associadas ao sinal mioelétrico, seja utilizando métodos estatísticos para detecção de

piscadas de olhos (Toniolo, 2005) ou intenção de movimento de membros amputados (Hudgins, 1994), seja através de sistemas baseados em redes neurais para detectar a intenção de movimento de membros amputados (Englehart, 1999; Gallant, 1998; Cunha, 2000).

O presente trabalho explora um método simples de detecção e distinção automática de piscadas de olhos, a partir de amostras de SME facial. A detecção e classificação das piscadas é feita utilizando-se redes neurais artificiais (RNA) do tipo *feedforward*, treinadas com os algoritmos *Bayesian Regularization* (BR), *Resilient Backpropagation* (RP) e *Scaled Conjugate Gradient* (SCG). Estas deverão ser capazes de detectar piscadas relativas ao olho direito (SME com pico positivo) e ao olho esquerdo (SME com pico negativo), além de serem capazes de rejeitar as piscadas naturais provenientes, por exemplo, da lubrificação dos olhos.

2 O Sinal Mioelétrico (SME)

O SME é proveniente da soma do potencial de ação gerado em cada fibra muscular, medido sobre a superfície do corpo humano, sendo relacionado às contrações musculares (Biederman, 1898). A soma

algébrica destes potenciais é comumente conhecida como Potencial de Ação da Unidade Motora (do inglês MUAP - *Motor Unit Action Potential*). Este potencial é caracterizado por ser de curta duração temporal, geralmente na faixa de 2 a 10 ms, com amplitudes que variam entre 10 μ V e 50 mV, e larga banda de frequência, de 5 Hz a 10 kHz (Almeida, 1997).

Sabe-se que o sinal mioelétrico é descrito como sendo um processo estocástico, ou seja, suas características (média e variância) variam com o passar do tempo (Kreifeldt, 1974). Dentro deste contexto, é necessário utilizar sistemas mais robustos, que sejam capazes de levar em consideração as características estocásticas do SME. Em (Hudgins, 1993) foi mostrado que tal sinal apresenta uma característica determinística nos primeiros 200 ms após a realização da contração muscular. Porém, normalmente o sinal proveniente da piscada possui um intervalo de duração superior a 200 ms, o que impossibilita um tratamento determinístico do sinal e valida a utilização de redes neurais artificiais.

A captura da piscada dos olhos é feita de forma diferencial, utilizando-se eletrodos de superfície, posicionados estrategicamente na face (Fig. 1), e uma placa de aquisição de sinais biológicos desenvolvida no Laboratório de Automação Inteligente (LAI) do Departamento de Engenharia Elétrica da Universidade Federal do Espírito Santo (UFES). No caso específico da contração muscular associada às piscadas de olhos, os sinais capturados apresentam amplitudes na faixa de 0.1 a 1 mV, variando de acordo com a posição dos eletrodos. Além disso, eles apresentam componentes de frequência desde 0 até 500 Hz, com energia concentrada principalmente em frequências menores que 100 Hz. A Fig. 2 apresenta sinais típicos da piscada de olhos.

Neste trabalho, foram utilizados sinais de piscadas de olhos capturados de voluntários selecionados aleatoriamente. Foram adquiridas aproximadamente 210 piscadas do olho direito e 210 do olho esquerdo, de indivíduos do sexo masculino



Fig. 1 - Posicionamento dos eletrodos de superfície para captura da piscada dos olhos.

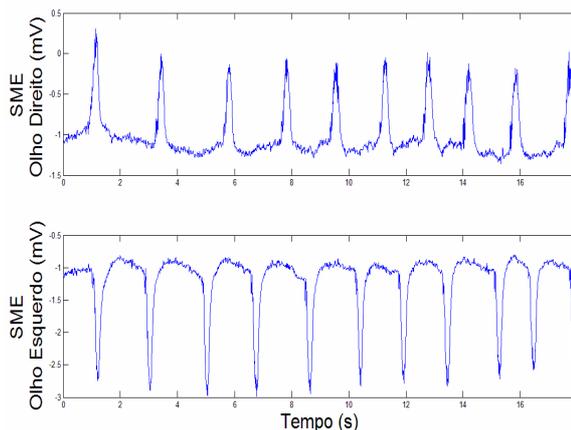


Fig. 2 - Sinais provenientes da piscada dos olhos.

com idade entre 20 e 30 anos, sendo que a aquisição foi feita com taxa de 140 amostras por segundo. Além disso, foram geradas 210 amostras ruídos aleatórios gaussianos, com média zero e variância de 0,1. Tais sinais são utilizados exclusivamente para o treinamento das redes neurais.

Posteriormente, foram utilizadas outras amostras de piscadas para testar o sistema de reconhecimento automático de piscadas (RAP), formado pelas RNA treinadas com os sinais supracitados. Neste caso, foram utilizados os sinais correspondentes a 84 piscadas do olho direito, 84 piscadas do olho esquerdo, além de 84 ruídos Gaussianos (média zero e variância 0,1).

Inicialmente o sinal de piscada adquirido é filtrado usando um filtro digital passa-altas (Butterworth, segunda ordem, frequência de corte em 1 Hz), para remoção do ruído da linha de base e, posteriormente, utiliza-se um filtro digital passa-baixas (Butterworth de quarta ordem, com frequência de corte em 35 Hz), para remoção do ruído muscular.

Após a etapa de filtragem faz-se a normalização dos SME utilizando a equação

$$y_0(n) = \frac{y(n)}{\max|y(n)|}, \quad (1)$$

onde y_n representa o sinal amostrado de entrada.

Posteriormente, utiliza-se um algoritmo baseado no método de Pan-Tompkins (Rangaraj, 2002) para facilitar a detecção do intervalo das piscadas de olhos. Este algoritmo inclui uma série de métodos que realizam a derivada, quadratura e integral do sinal. A operação de derivada aqui utilizada é

$$y_1(n) = \frac{1}{8} [2y_0(n) - y_0(n-1) - y_0(n-3) + 2y_0(n-4)]. \quad (2)$$

A operação de se elevar ao quadrado a derivada torna o resultado positivo e enfatiza grandes diferenças no sinal de piscadas, enquanto sinais de pequena amplitude presentes no SME filtrado são suprimidos. Em outras palavras, calcula-se

$$y_2(n) = y_1^2(n). \quad (3)$$

O algoritmo aqui implementado ainda realiza uma suavização do sinal, utilizando um filtro integral de janela-móvel, ou seja, calcula-se

$$y_3(n) = \frac{1}{N} [y_2(n - (N - 1)) + y_2(n - (N - 2)) + \dots + y_2(n)] \quad (4)$$

A escolha do tamanho da janela (N) é feita considerando-se que caso o valor seja elevado irá ocorrer uma provável união de piscadas que estejam muito próximas e que caso ele seja muito pequeno a piscada ainda poderá apresentar vários picos. Uma janela de tamanho $N = 10$ foi escolhida empiricamente, e mostrou-se satisfatória.

A Fig. 3 ilustra todas as etapas acima descritas.

3 Detecção do Pico da Piscada

Para a marcação do pico da piscada foi desenvolvido um algoritmo que busca o ponto máximo e sua respectiva posição no vetor de amostras de SME pré-processado.

Determinado este máximo, o algoritmo zera os dados próximos ao ponto encontrado, evitando, na próxima marcação, encontrar um ponto de descida da onda referente à piscada, ao invés de seu topo. A busca prossegue até que um limiar seja ultrapassado. Testes mostraram que um valor de 0,35 (ou seja, 35% do valor máximo) torna o algoritmo eficiente. Esse processo é realizado até que o SME possua somente picos cujos valores estão abaixo da faixa delimitada anteriormente.

Apesar de eficiente, alguns cuidados devem ser tomados com o algoritmo. O principal deles é o tamanho da região que deverá ser zerada após a determinação de um pico da piscada. Usando uma região de busca muito pequena, pode-se marcar a subida da onda referente à piscada. Usando uma região muito grande, pode-se zerar um possível pico próximo ao pico marcado. O valor apropriado para essa região de busca deve ser aproximadamente a duração de uma piscada. Baseando-se nisso, optou-se

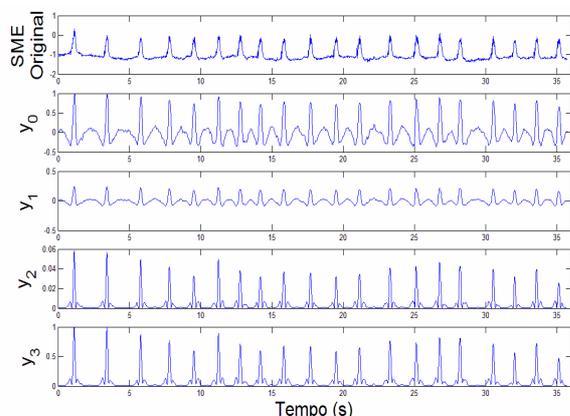


Fig. 3 - Resultados encontrados utilizando-se o algoritmo baseado no método de Pan-Tompkins, onde y_0 é o sinal normalizado; y_1 é o sinal após a aplicação da derivada de Pan-Tompkins; y_2 representa o quadrado do sinal de entrada e y_3 o sinal após a aplicação de um filtro integral de janela-móvel.

por usar uma região de 60 amostras, ou seja, zerar 30 amostras depois e 30 amostras antes do ponto marcado como pico da piscada, o que se mostrou eficiente.

Apesar da marcação dos picos ser precisa em quase todos os SMEs faciais (Fig. 4), o algoritmo marcou alguns picos erroneamente. Porém, dado que algumas piscadas estão relacionadas à lubrificação dos olhos (baixa amplitude e intervalo de pequena duração), o limiar estabelecido considera como válidos apenas sinais com valores de pico acima de 35% do maior valor detectado, e serviu, portanto, para evitar a marcação incorreta destas piscadas.

4 Detecção do Intervalo de Duração da Piscada

Após a marcação dos picos é necessário determinar os respectivos intervalos de duração da piscada. Dentro deste contexto, foi desenvolvido um algoritmo baseado na variação angular de cada ponto. Ele consiste em calcular a tangente dos pontos à direita e à esquerda do pico, a partir da derivada do SME pré-processado.

Caso o valor da tangente no ponto atinja um valor menor que um limiar determinado empiricamente (0,0025 mostrou-se satisfatório), este é considerado como início ou fim do intervalo referente à piscada do olho.

O algoritmo aqui implementado se mostrou bastante eficiente, encontrando corretamente quase todos os intervalos relativos às piscadas do olho direito e esquerdo (Fig.5).

5 RNAs Aplicadas na Detecção de Piscadas

Após a etapa do processamento do SME é suposto que o mesmo apresente apenas o que é relevante para o reconhecimento de padrões. Porém, o novo vetor de dados gerado contém muitos elementos, sendo, portanto, inviável criar uma estrutura neural com esta quantidade de entradas. Neste contexto, foi realizada uma sub-amostragem do intervalo de duração da piscada, para representar os muitos elementos do vetor de dados em algumas unidades, ou dezenas, pré-determinadas. Após a realização da sub-

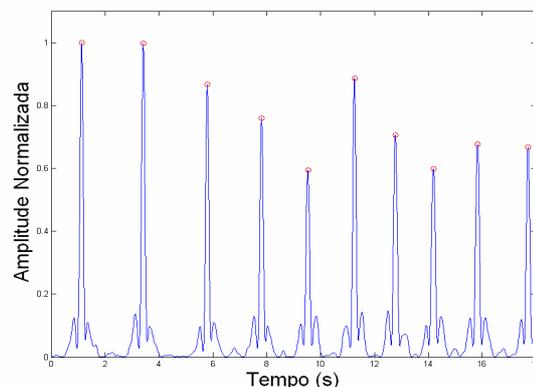


Fig. 4 - Detecção dos picos das piscadas de olhos.

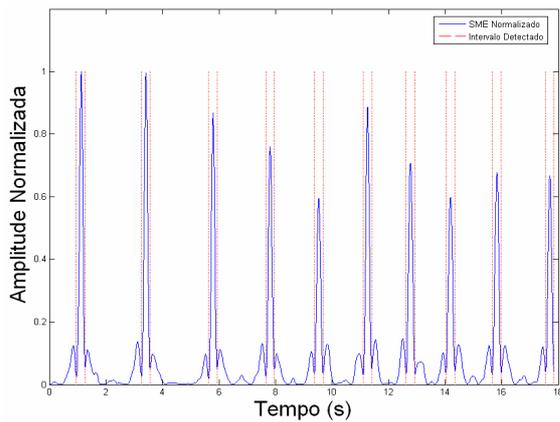


Fig. 5 - Detecção dos intervalos de duração da piscada.

amostragem do sinal correspondente a cada intervalo de uma piscada, estes foram normalizados na faixa de -1 e 1, com o objetivo de proporcionar uma convergência mais rápida na etapa de treinamento das RNAs.

Com isso, a camada de entrada da rede estará definida. Na camada oculta, o número de neurônios foi pré-estabelecido em 4, 6, 8 ou 10, com o objetivo de se determinar a melhor escolha. Redes neurais com o número de neurônios na camada oculta superior ou inferior ao utilizado aqui não apresentaram melhoria nas respostas das mesmas. A camada de saída apresenta três neurônios, para determinar se a piscada é proveniente do olho direito, do olho esquerdo ou se não houve piscada.

Para a etapa de treinamento da rede neural foram utilizados os algoritmos *Bayesian Regularization* (BR), *Resilient Backpropagation* (RP) e *Scaled Conjugate Gradient* (SCG) (MathWorks, 2000). É difícil determinar qual algoritmo de treinamento será mais rápido para solucionar um dado problema. Isto depende de muitos fatores, incluindo a complexidade do problema, o número de entradas, o número de pesos na rede e o erro global.

Foram utilizadas 210 amostras de SME facial para cada sinal conhecido. Neste caso, isso corresponde às piscadas do olho direito e do olho esquerdo, além de 210 ruídos aleatórios gerados, totalizando 630 amostras para treinamento e validação. Em cada sinal realizou-se uma subamostragem e utilizou-se metade das amostras para treinamento e a outra metade para a validação. A Tabela 1 ilustra esta etapa do trabalho.

É importante destacar que o erro apresentado na Tabela 1 é referente à soma dos erros cometidos pelas RNAs nas etapas de treinamento e de validação.

6 Sistema de Reconhecimento Automático de Piscadas (RAP)

Nesta etapa testaram-se todas as RNAs criadas (Tabela 1), escolhendo-se a que apresentou melhores

resultados em cada caso (Tabela 2). Ao todo, utilizaram-se 252 sinais de teste, ou seja, 84 piscadas referentes ao olho esquerdo, 84 referentes ao olho direito e 84 ruídos gerados aleatoriamente, todos não utilizados na etapa de validação ou treinamento.

Observa-se na tabela 2 que, com o sistema desenvolvido, consegue-se um acerto de 99,6% na detecção de piscadas de olhos, o que é uma melhoria em relação a trabalhos anteriores (Frizzera et. al., 2006) que obteve um acerto máximo de 94,7% na detecção de piscadas.

O diagrama da Fig. 6 esboça o processo completo do sistema de reconhecimento automático de piscadas, desde a aquisição do sinal, até a detecção feita pela RNA.

Para ilustrar a aplicabilidade do sistema proposto, utilizou-se um simulador do robô móvel Pioneer 2-DX (Fig. 7), desenvolvido na UFES. Neste simulador, desenvolvido em MATLAB®, o usuário pode escolher entre ambientes com ou sem obstáculos, e determinar a posição destes no mesmo. Além disso, é possível variar as velocidades linear e angular do robô móvel, optando-se por valores que melhor se ajustem à velocidade de processamento do computador e facilitem a visualização do simulador. O usuário pode, ainda, determinar o ponto de chegada do robô móvel, e plotar as velocidades angular e linear obtidas ao longo do caminho percorrido.

Com o intuito de testar o sistema RAP desenvolvido, um caminho pré-definido foi estabelecido, a partir do conjunto de dois comandos formados pelas piscadas provenientes do olho esquerdo e do olho direito. A Tabela 3 apresenta os comandos que o robô móvel deverá realizar para percorrer o caminho determinado. Os comandos são gerados a partir da associação de duas piscadas, por exemplo, o comando “Frente” é gerado a partir de uma piscada com o olho direito e outra com o olho esquerdo, respectivamente. Por sua vez, o comando “Pára” é gerado a partir de uma piscada com o olho esquerdo e outra com o olho direito, respectivamente. De maneira semelhante são gerados os comandos

Tabela 1 – Redes neurais artificiais criadas para cada tipo de algoritmo de treinamento.

Algoritmo Treinamento	Camada Entrada	Camada Oculta	Camada Saída	Erro Total (%)
BR	20	4	3	0.6349
	20	6	3	0.4762
	20	8	3	0.6349
	20	10	3	0.6349
RP	20	4	3	0.3175
	20	6	3	0.6349
	20	8	3	0.3175
	20	10	3	0.4762
SCG	20	4	3	0.7937
	20	6	3	0.4762
	20	8	3	0.3175
	20	10	3	0.3175

Tabela 3 – Resultados apresentados pelas diferentes RNAs criadas.

Algoritmo de Treinamento	Neurônios Camada Oculta	Acerto (%)
BR	6	98.4127
RP	4	99.6032
SCG	10	98.4127

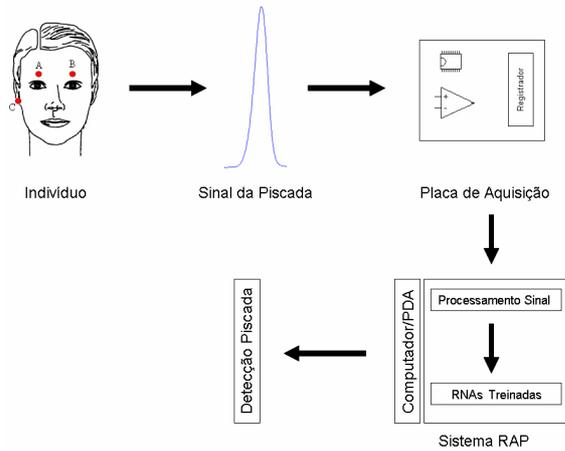


Fig. 6 - Diagrama do processo de reconhecimento automático de piscadas.

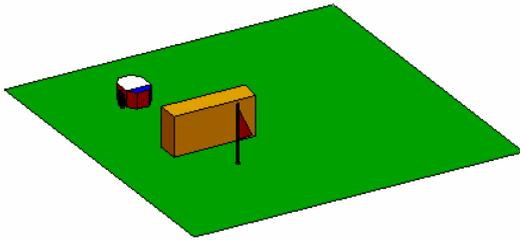


Fig. 7 – Ambiente de simulação do robô móvel Pioneer 2-DX.

Tabela 3 - Comandos determinados pelo sistema RAP para percorrer o caminho pré-estabelecido.

Comandos	Comandos determinados pelo Sistema RAP
Frente	Frente
Direita	Direita
Frente	Frente
Esquerda	Esquerda
Frente	Frente
Esquerda	Esquerda
Frente	Frente
Frente	Frente
Pára	Pára

“Esquerda” e “Direita”. Vale mencionar que cada um dos referidos comandos tem uma temporização associada a ele, que não é mostrada na Tabela 3. Finalmente, a Tabela 3 também apresenta os comandos identificados pela RNA escolhida. Por fim, as piscadas de olhos utilizadas para gerar os comandos enviados ao robô foram selecionadas aleatoriamente do banco de dados utilizado para teste.

A Fig. 8 ilustra o caminho que o robô móvel deveria seguir, e o caminho efetivamente percorrido

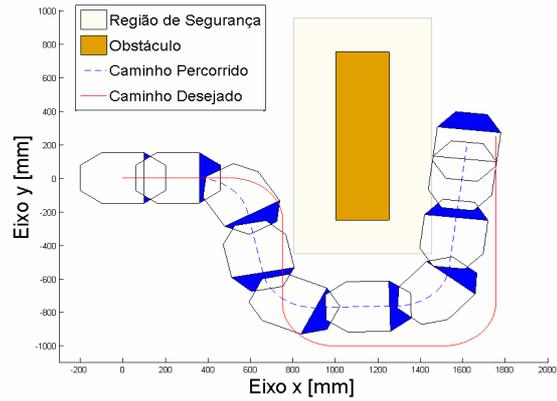


Fig. 8 - Caminho percorrido pelo robô móvel Pioneer 2-DX durante a simulação.

pele mesmo a partir dos comandos gerados pelo sistema RAP. Nota-se que existe um erro cometido pelo robô móvel durante o percurso, o que pode ser associado à estimação errada da velocidade angular e linear durante a simulação. O erro de posicionamento final, dado por

$$\tilde{\rho} = \sqrt{(x_d - x_r)^2 + (y_d - y_r)^2}, \quad (5)$$

onde, x_d e y_d são as posições desejadas nos eixos x e y , respectivamente, e x_r e y_r são as posições reais nos eixos x e y , atingidas pelo robô móvel durante a simulação, foi de 181 mm. Outros fatores como o tempo de processamento do sinal proveniente da piscada e o computador utilizado para simulação, influem de maneira decisiva no erro observado.

7 Trabalhos Futuros

Encontra-se em desenvolvimento na UFES uma cadeira de rodas robótica (Fig. 9) destinada a pessoas com deficiência motora severa, as quais podem comandar a cadeira por piscadas de olhos ou sinais cerebrais. O projeto em questão assume duas grandes frentes de trabalho: uma envolvendo diretamente a cadeira de rodas, e outra responsável por desenvolver sistemas, baseados em sinais biológicos, que permitam a uma pessoa com este tipo de dificuldade motora comandar o veículo autônomo de forma simples e eficiente.

Por meio de símbolos pictográficos, que representam os distintos ambientes de navegação, o usuário pode escolher seu próximo destino dentro do ambiente de navegação. Informações sensoriais são passadas à unidade de processamento de alto nível por meio de uma comunicação serial existente entre um computador embarcado (Mini-ITX) e um microcontrolador (MSP430). Tais informações servem como realimentação necessária ao controlador de alto nível. Do controle de alto nível saem as velocidades linear e angular de referência, as quais são passadas ao controle de baixo nível via comunicação serial.

Dentro deste contexto, a interface aqui desenvolvida poderá ser utilizada para a seleção dos

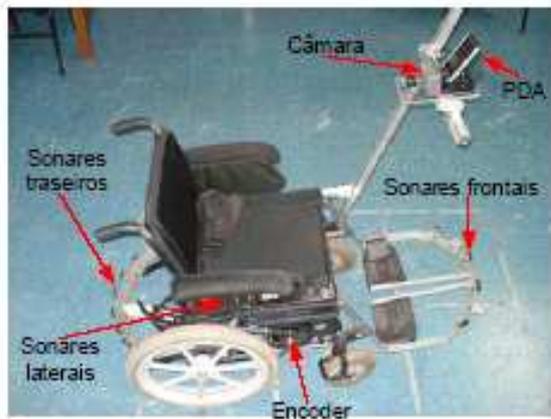


Fig. 9 – Cadeira de rodas desenvolvida no LAI/UFES com os dispositivos embarcados.

ícones no PDA inserido na cadeira de rodas móvel, através dos quais o usuário elege seu próximo destino (por exemplo, ele pode desejar ir à cozinha).

Além do presente trabalho, existem outras interfaces em desenvolvimento no LAI/UFES que utilizam RNAs. Neste caso, trata-se da classificação de sinais eletroencefalográficos (EEG) utilizando a energia e a entropia dos coeficientes da transformada *wavelet* como entrada da RNA.

8 Conclusão

O presente trabalho não utilizou parâmetros clássicos empregados na maioria dos métodos de reconhecimento de padrões em sinais de eletromiograma facial, tais como o método estatístico utilizado em (Toniolo, 2005; Frizzera et al., 2006). A metodologia adotada é semelhante à adotada em (Cunha et al., 2000).

Os algoritmos implementados e utilizados neste trabalho se mostraram bastante satisfatórios, sendo possível a detecção do pico e dos intervalos de duração das piscadas de olho. A redução da quantidade e a melhoria na qualidade dos sinais de entrada possibilitaram a criação de redes neurais que satisfizeram o objetivo principal do trabalho.

As RNAs demonstraram, de maneira geral, capacidade de encontrar padrões nos sinais estudados. A topologia *feedforward* com algoritmo *backpropagation*, de duas camadas ativas e uma intermediária, permitiu uma classificação satisfatória dos sinais.

Os resultados globais apresentaram-se superiores a 98% para os algoritmos de treinamento BR e SCG, e superior a 99% para o algoritmo RP. Estes resultados mostraram-se bastante satisfatórios, demonstrando a aplicabilidade do trabalho apresentado.

Neste sentido, uma proposta de trabalho futuro, e que já está em andamento, consiste em utilizar o sistema proposto para controlar a cadeira de rodas da UFES através da seleção, por piscadas de olhos, de símbolos em um tabuleiro pictográfico disponível em um PDA.

Agradecimentos

Os autores agradecem à CAPES, FAPES (Processo 30897440/2005) e FACITEC pelo suporte financeiro dado a esta pesquisa.

Referências Bibliográficas

- Almeida, M. A. F. (1997). Filtragem Digital de Sinais Biomédicos. *Dissertação de Mestrado, Universidade Federal de Santa Catarina*, 116.
- Biederman, W. (1898). *Electrophysiology*. Londres.
- Cunha, F. L., Franca, J. E. M., Ortolan, R. L., Cliquet, A. (2000). Uso de Redes Neurais Artificiais Para o Reconhecimento de Padrões em uma Prótese Mioelétrica de Mão. *I Congresso Iberoamericano de Tecnologias de Apoio à Deficiência (Iberdiscap)*, 339-342.
- Englehart, K., Hudgins, B., Parker, P., Stevenson, M. (1999). Classification of the Myoelectric Signal using Time-Frequency Based Representation. *Medical Engineering and Physics, Special Issue: Intelligent Data Analysis in Electromyography and Electroneurography*, **21**, 431-438.
- Gallant, P. J., Morin, E. L. and Peppard, L. E. (1998). Feature-based classification of myoelectric signals using artificial neural networks. *Medical & Biological Engineering & Computing*, **36**, 485-489.
- Hudgins, B., Parker, P. and Scott, R. N. (1993). A New Strategy for Multifunction Myoelectric Control. *IEEE Trans. Biomed. Eng.*, **40**, 82-94.
- Hudgins, B., Parker, P. and Scott, R. N. (1994). Control of Artificial Limbs Using Myoelectric Pattern Recognition. *Medical & Life Sciences Engineering*, **13**, 21-38.
- Kreifeldt, J. G. (1974). A Signal-to-Noise Investigation of Nonlinear Electromyography Processors. *IEEE Transactions on Biomedical Engineering*, **21**, 298-308.
- Frizzera, A. N., Celeste, W. C., Martins V. R., Bastos-Filho, T. F., Sarcinelli-Filho, M. (2006). "Human-Machine Interface Based on Electro-Biological Signals for Mobile Vehicles". *International Symposium on Industrial Electronics (ISIE)*, 2954-2959.
- Rangaraj, M. Rangayyan (2002). *Biomedical Signal Analysis*. Wiley Interscience.
- Toniolo, C. C. (2005). Seleção de Símbolos Pictográficos em Tabuleiro Eletrônico Através de Sinais Mioelétricos. *Projeto de Graduação, Universidade Federal do Espírito Santo*, 53.
- The MathWorks Inc. (2000). *Neural Network Toolbox User's Guide*.