

CLASSIFICADOR EM CASCATA APLICADO AO COMANDO DE UMA CADEIRA DE RODAS

RESUMO

Marcos Batista Figueredo, Dr.

A precisa detecção do estado dos olhos representa uma etapa fundamental para diversas atividades que requerem a Interação Homem-Máquina (IHM). Este artigo apresenta uma análise da implementação de parte de um sistema para navegação de uma Cadeira de Rodas com Automação (CRA), baseado em expressões faciais, notadamente os olhos fechados usando um Classificador em Cascata de Haar (*Haar Cascade Classifier* – HCC). Voltado a pessoas com incapacidade de locomoção dos membros superiores e inferiores, a detecção do estado baseou-se em duas etapas: a captura da imagem, que concentra as ações de detecção e otimização da imagem; ações da cadeira, que interpreta os dados da captura e envia as ações para a cadeira. Os resultados revelaram que o modelo tem excelente precisão na identificação com desempenho robusto no reconhecimento dos olhos fechados, contornando muito bem questões de oclusão e iluminação com cerca de 98% de acerto. A aplicação do modelo nas simulações abre a oportunidade de implementação e casamento com o universo de sensores da cadeira objetivando uma navegação segura e eficiente ao usuário.

PALAVRAS-CHAVE: cadeira de rodas. classificador em cascata. detector de olhos fechados



INTRODUÇÃO

Diversas doenças ou acidentes podem levar um paciente a graves danos na medula espinhal ocasionando a perda de movimento nas partes inferiores e superiores. Segundo IBGE, (2011), 14% população brasileira possui algum tipo de deficiência, seja ela visual, motora, auditiva entre outras, representando um crescimento da ordem de 7% nos últimos anos.

Dentre esse grupo cerca de 4% não possuem qualquer tipo de movimento nos membros inferiores e superiores. Isto devido a problemas motores muito graves, como plegia dos quatro membros e necessidade de assistência ventilatória. Também se aplicando a portadores de doenças degenerativas do sistema neuromuscular, como, por exemplo, a Esclerose Lateral Amiotrófica (ELA), em que de uma maneira progressiva a pessoa perde seus movimentos, até ficar completamente paralisada, e vir a óbito por insuficiência respiratória.

Entre os diversos tipos de deficiências físicas motoras que podem acometer uma pessoa, a tetraplegia (incapacidade motora dos quatro membros) e as doenças do sistema neuromotor, como a ELA, constituem graves anomalias, que levam o indivíduo a um estado quase vegetativo, com dificuldades de integração na sociedade como pessoa útil e capaz. Entretanto, na maioria dos casos, tais indivíduos apresentam plena capacidade cerebral. E com os meios físicos necessários podem participar da sociedade de modo produtivo. Assim, faz-se necessário encontrar meios que permitam desenvolver suas aptidões pessoais e profissionais, até mesmo, ter alguma atividade profissional, com dignidade humana.

Normalmente, este paciente, recorre a uma cadeira de rodas para realização de tarefas como ir e vir, sempre com o auxílio de algum cuidador ou parente. Algumas destas utilizam acoplamentos que permitem ao usuário sua locomoção no seu ambiente e em geral são muito invasivas.

Os trabalhos de (BRAGA,2012), (HALAWANI, 2012), (SONG, 2011) e (ZHAO, 2012) indicam a preocupação da comunidade acadêmica em realizar ações tecnológicas, de baixo custo, que tornem a vida cotidiana dessas pessoas mais independente, e estes estudos indicam ainda que essas ações prolongam a vida dos pacientes e melhoram sua qualidade de vida (RUMÃO DE MELO, 2009), (CEZAR DA CRUZ, 2011).

Diversos trabalhos têm sido realizados por diferentes grupos de pesquisa no sentido de desenvolver cadeiras de rodas com algum tipo de inteligência, ou que sejam capazes simplesmente de entender comandos de voz, locomoção autônoma, desvio de obstáculos entre outras funções e como destacado em (BRAGA, 2012), estes modelos possuem um custo elevado de aquisição e manutenção, dispendo de pouco ou nenhum tipo de tecnologia embarcada.

Motivado por esta realidade iniciou-se um projeto de cunho interdisciplinar que visa dotar uma cadeira de rodas comum com elementos que tornem tanto possível como viável economicamente a mobilidade de um paciente sem movimentos dos membros superiores e inferiores. Este trabalho tem como objetivo apresentar os resultados iniciais do modelo de detecção e comando do protótipo (Figura 1) e apresentar suas principais características.



Figure 1: CRA utilizada como protótipo



Fonte: autor

Esta navegação é limitada em alguns aspectos, pois alguns movimentos das expressões faciais revelaram-se extremamente cansativos, como abrir e fechar a boca e outros se mostraram demasiadamente difíceis de serem captados ou requerem equipamentos ainda em desenvolvimento, como o movimento da retina dos olhos. Assim duas expressões se revelaram menos susceptíveis a falha, baixa intrusividade (equipamentos ligados ao indivíduo) e baixa curva de aprendizado (capacidade do indivíduo de aprender a usar a cadeira), são elas o abrir e fechar dos olhos e o movimento de girar a cabeça para direita e esquerda. Essas expressões foram avaliadas por 20 indivíduos que simularam o estado de um tetraplégico e geraram uma avaliação descrita na Tabela 1.

Tabela 1: Percentual de acerto e falha da detecção das expressões faciais e média de pontuação da dificuldade em aprender a usar as expressões faciais e o quanto desta aplicação era ou não intrusiva. Analisada em 20 indivíduos.

Expressão Facial	Falha (%)	Acerto (%)	Intrusividade (0-10)	Aprendizado (0-10)
Fechar e Abrir os Olhos	2%	98%	2	2
Girar Cabeça	3%	97%	2	3

Fonte: autor

Daí o modelo para navegação de uma Cadeira de Rodas com Automação - CRA baseia-se em duas expressões:

- Abrir e fechar os olhos (Move a cadeira para frente ou para)
- Girar a cabeça para esquerda ou direita (Move a cadeira em 90° em torno do eixo da mesma)

Tem-se neste trabalho como objetivo apresentar a arquitetura para detecção da ação de abrir e fechar dos olhos baseado em *Haar Cascade Classifier* - HCC e avaliar o desempenho do detector em relação a eficiência e eficácia

A eficácia do detector foi testada no protótipo, avaliando sua resposta aos comandos, já a sua eficiência foi avaliada a partir da:




- Construção de banco de dados de imagens alvo considerando regionalidades e diversidade cultural brasileira;
- Manipulação das diversas variáveis de treinamento;
- Manipulação e controle do número ideal de vizinhos mínimos do detector, reduzindo o número de falsos positivos;
- Resposta maior ou igual a 98% de acerto.

Segundo JOLIFFE,(2002) o modelo de VIOLA, (2001) que utiliza um classificador em cascata e as características de HCC. Funciona muito bem na detecção facial e já se tornou padrão por sua alta taxa de acerto e baixa taxa de falsos positivos.

O modelo VIOLA, (2001) é adaptativo e amplamente utilizado pelo seu grau de robustez e rapidez. Em nossa implementação a detecção é baseada em HCC, com parâmetros avaliados e um banco de positivos com cerca de 10000 imagens frontais de olhos fechados Figura 2.

Figura 2: Amostra do conjunto de positivas



Fonte: Autor

Este artigo foi organizado da seguinte forma: A seção 2 descreve os materiais e o método utilizado para a realização e implementação da arquitetura A seção 3 apresentam os testes e resultados. Seção 4 por sua vez traz as conclusões e trabalhos futuros.

METODOLOGIA

O modelo para detecção do estado dos olhos utiliza um a ideia simples. Se um detector consegue detectar um olho humano numa face frontal então ele deverá reconhecer também um olho fechado. Para este fim, treinou-se um classificador em cascata que identifique este objeto na imagem de entrada. A escolha do modelo de VIOLA, (2001), se dá principalmente pela sua simplicidade, rapidez de execução e do desempenho notável, (BRADSKI,2000), (BRADSKI,2008). O método combina basicamente quatro conceitos-chave:

- Características retangulares, chamadas de recursos de Haar;
- Imagem Integral;
- Algoritmo de aprendizagem – AdaBoost;
- Um classificador em cascata.

O conjunto dessas ideias, permite uma seleção simultânea das principais características e a formação do classificador em cascata, a seguir será descrito as referidas etapas.

Características de Haar




Os recursos de Haar codificam a existência de contrastes entre as regiões orientadas da imagem. E estes são utilizados para extrair as informações necessárias para correta interpretação do rosto humano ou outra característica. Neste trabalho utilizamos para extrair características que definem tanto os olhos fechados como aberto e sua relação espacial. Esse conceito é semelhante aos coeficientes da wavelet de Haar, definida em uma janela de detecção com $W \times H$ pixels conforme a formula:

$$caracteristica = \sum_{i=1}^N \omega_i RecSum(r_i) \quad (1)$$

Em que ω_i e arbitrariamente escolhendo como fator de peso e $RecSum(r_i)$ é a soma das intensidades dos pixels, que foi descrito por [12] como imagem integral. O retângulo r_i e descrito como uma função com cinco parâmetros: $r = (x, y, w, h, \phi)$, na qual x, y são as coordenadas da posição superior do conjunto de pixels, w e h definem as dimensões do retângulo e $\phi = \{0^\circ, 45^\circ\}$ representa o grau de rotação.

Figura 3: Algumas das características de Haar




Fonte: Adaptado de BRADSKI (2008)

A presença de uma característica de Haar, Figura 3, é determinada pela subtração do valor do pixel médio da região pelo valor médio do pixel da região clara. Se a diferença for acima de um limiar (definido durante a aprendizagem), a característica está presente.

No caso da detecção de olhos fechados este fato é utilizado para a representação das informações aproximadas e também, relacionadas a planos de fundo da imagem de teste. Este conhecimento torna-se bastante fino com relação ao olho aberto e fechado, a utiliza entre os dois dificilmente é encontrada em outros modelos com abordagem baseada em aparência.

De modo geral, portanto, as características nada mais são do que avaliações para um conjunto de informações da intensidade de luz em um pixel. Esse processo consiste na soma da intensidade dos pixels de regiões brancas das características, subtraído a soma da intensidade do restante cinza da imagem. Os resultados são usados como valor da característica de uma determinada localização e podem ser combinados para a formação de hipóteses fracas nas imagens (HJELMÅS,2001).




Tipicamente o modelo adota os retângulos vistos na Figura 3 e para determinar a presença, ou ausência de centenas de características de Haar em cada posição de imagem e com escalas diferentes, toma-se uma técnica chamada de imagem integral.

Image Integral

As imagens integrais criam, a partir da imagem original, uma nova representação da imagem, simplesmente, soma-se os valores de cada pixel a esquerda e acima, inclusive. A ideia em usar essa representação é aumentar a velocidade na extração de características, pois qualquer retângulo de uma imagem pode ser calculado por meio desta ideia. Necessário apenas quatro índices para calcular qualquer retângulo e como consequência imediata, precisa-se de apenas uma passagem para obter dados desejados em sub-regiões de uma imagem, vide Figuras 5 e 6.

A ideia em usar essa representação é aumentar a velocidade na extração de características, pois qualquer retângulo de uma imagem pode ser calculado por meio da imagem integral.

Figure 4: Representações da Imagem Integral, (a) região de cálculo, (b) Soma das áreas A-B-C+D, (c) região racionada de cálculo, (d) Soma rápida A-B-C+D



Fonte: Autor

Figure 5: Representação do cálculo da imagem Integral, observamos que a soma da região em (a) é igual a sete em (b) representamos como $108-73-80+52$

8	3	9	7	1
1	8	5	2	3
6	7	5	2	3
5	2	9	3	1
4	0	8	1	2

(a) Imagem de Entrada A

0	0	0	0	0	0
0	8	11	20	27	28
0	9	20	34	43	47
0	15	33	52	63	73
0	20	40	68	82	93
0	24	44	80	95	108

(b) Imagem Integral de A

Fonte: Autor

Adaboost

O problema Boosting de origem na área computacional, conhecida como machine learning que informalmente pode ser exposto da seguinte forma:



Suponha que existe um método de classificação que é ligeiramente melhor do que uma escolha aleatória, para qualquer distribuição em X . Chamado de weak learner ou classificador fraco. A existência de um classificador fraco implica na existência de um classificador forte (strong learner), com erro pequeno sobre todo o espaço X .

Em estatística consiste em perguntar se dado um método razoável de estimação, é possível obter um método próximo de ótimo. Este problema foi resolvido por SCHAPIRE,(1990), que apresentou um algoritmo que transforma um classificador fraco em um classificador forte.

A partir de então, foram desenvolvidos vários algoritmos dentro do contexto boosting. Um dos mais recentes e bem-sucedido algoritmo é conhecido como AdaBoost que é oriundo do fato de que o boosting gera em cada passo uma distribuição sobre as observações da amostra, atribui maior peso (maior probabilidade de estar na amostra perturbada) às observações classificadas incorretamente no passo anterior.

Nesse sentido o AdaBoost está focado nas classificações ruins, ou então, nos dados de difícil classificação, e esta é a característica principal deste algoritmo: minimizar o erro sobre um conjunto de treinamento. Uma das vantagens do adaboost é a existência de outros parâmetros, além dos turnos T , para que melhore o aprendizado.

O resultado, após sucessivas iterações do algoritmo, de um conjunto de hipóteses com pesos, em que aqueles que possuírem menores erros de classificação ganham maior importância e, é chamado de hipótese forte ou classificador forte.


Classificador em cascata

Aumentar a velocidade de uma tarefa de classificação, em geral, resulta em um aumento dos erros associados. Porém, para surtir este efeito teríamos que reduzir o número de avaliação dos classificadores fracos, o que resultaria numa perda na acurácia do sistema. Assim se propõe uma árvore degenerativa de decisão, *decision stump*, cuja estrutura que contém o encadeamento de classificadores do mais genérico ao mais específico, segundo o qual os primeiros níveis da cascata não são muito precisos, apesar de conseguir classificar uma grande quantidade de amostras com uma pequena quantidade de características.

O uso da cascata caracteriza-se pelo fato de que, em uma imagem durante uma tarefa de detecção, a maioria das sub janelas analisadas pelo classificador são rejeitadas. Por essa razão, uma generalização nos primeiros estágios deve ser suficientemente alta para que evite a passagem para estágios subsequentes de sub janelas classificadas como falso positivo, conforme, Figura 6:



Figure 6: Estrutura do classificador



Fonte: Autor

DESENVOLVIMENTO (RESULTADOS E DISCUSSÕES)

A performance do sistema de detecção de olhos fechados foi construída baseado num conjunto de 10.000 imagens de diversas pessoas. As imagens foram adquiridas em um ambiente com iluminação controlada, com 2048x1536 pixels no formato JPG. Para obter uma detecção precisa o classificador vários parâmetros podem ser modificados durante o processo de treinamento. A influência desses parâmetros altera a complexidade dos classificadores fracos e consequentemente aspectos como falsos positivos e positivos são influenciados.

O tamanho padrão de entrada foi ajustado para 24x24 pixels. Todas as imagens na nossa base foram tomadas no mesmo, fundo uniforme. De imediato quisemos verificar se o conjunto negativo construído a partir das mesmas imagens com rostos oclusos é suficiente para distinguir entre olhos abertos e fechados, que utiliza o classificador com parâmetros padrões.

Esta análise servil para diminuir o custo tanto de busca de imagens como otimização da programação, mas não se revelou satisfatório para imagens tão pequenas. Então o outro conjunto de treinamento negativo foi criado, se reuniu aleatoriamente cerca de 9000 imagens diversas que não contenham quaisquer referências a olhos humanos. A versão do *AdaBoost* que proporcionou melhores resultados para a detecção facial foi *Gentle AdaBoost*, com uma proporção de falsos positivos requerida das cascatas ajustado para $10e^{-6}$.

Devido a dimensões reduzidas da imagem de treinamento limitamos os retângulos de Haar que utilizamos. Apesar do número de maneira pelas quais os retângulos podem ser dispostos ser vasto, mas por razões práticas e de tempo limitamos as seguintes medidas:

1. Consideramos apenas *Haar-like* com dois, três e quatro retângulos
2. O tamanho do modelo das características de Haar foi definido em no máximo 5x5 e no mínimo 3x3 pixels
3. Todos os retângulos que contribuem para o único recurso de Haar tinham o mesmo tamanho.

Um total de 408.564 características de Haar foram obtidas por imagem nas condições acima, com um número satisfatório de recursos Para este problema de detecção foi utilizado quatro detectores que foram construídos e diferem entre si



basicamente pelo tipo de *boost* utilizado e variação de parâmetros conforme descrito na Tabela 2 e 3 e na Figura 7, em que: MinHitRate representa a taxa de acerto mínimo desejado para cada fase do classificador; MaxFalseAlarm é a taxa de alarme falso máximo desejado para cada fase do classificador; Nstages é o número de estágios da cascata; Btype representa o tipo de boost utilizado (Type of boosted classifiers: DAB - Discrete AdaBoost, RAB - Real AdaBoost, LB - LogitBoost, GAB - Gentle AdaBoost.); WTRate é a linha de corte e o peso utilizado no boost; Wcount – contagem máxima de arvores falsas para todas as fases da cascata.

Tabela 2: Apresentação dos parâmetros e dos classificadores

Parâmetros	Classificador 1	Classificador 2	Classificador 3	Classificador 4
MinHitRate	0.9 - 0.999	0.9 - 0.999	0.9 - 0.999	0.9 - 0.999
MaxFalseAlarm	0.1 - 0.5	0.1 - 0.5	0.1 - 0.5	0.1 - 0.5
Nstages	20	25	20	25
Btype	GAB	RAB	LB	DAB
WTRate	0.95 - 0.98	0.95 - 0.98	0.95 - 0.98	0.95 - 0.98
Wcount	100	100	100	100

Fonte: Autor

Tabela 3:Apresentação dos melhores resultados e seu tempo de processamento

Parâmetros	Classificador 1	Classificador 2	Classificador 3	Classificador 4
MinHitRate	0.999	0.987	0.985	0.999
MaxFalseAlarm	0.5	0.5	0.4	0.5
Nstages	20	25	20	25
Btype	GAB	RAB	LB	DAB
WTRate	0.97	0.98	0.95	0.95
Wcount	100	100	100	100
Tempo de processamento	4 dias	5 dias	4 dias	7 dias

Fonte: Autor


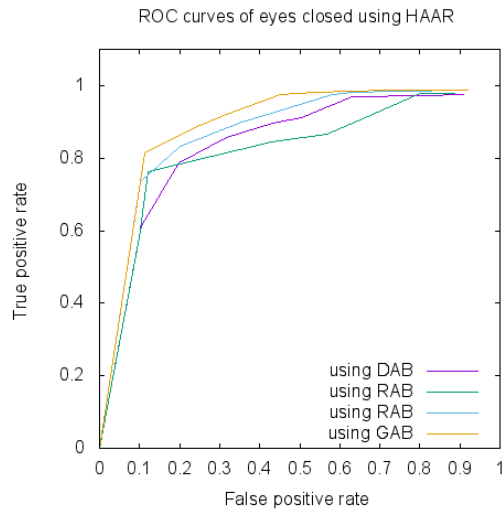
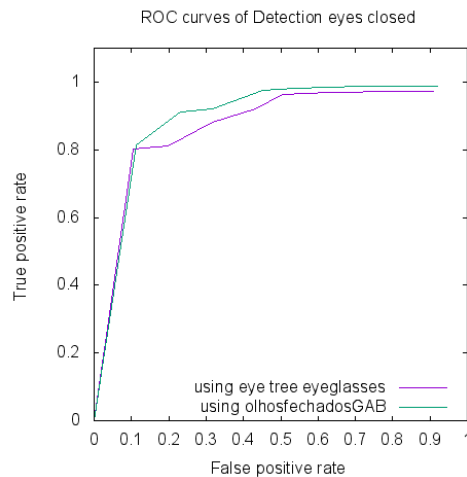


Figura 7: Gráfico ROC com os melhores parâmetros e com análise para diferentes versões do adaboost



Fonte: Autor

Figura 8: Comparação entre nosso classificador e o de distribuição pública



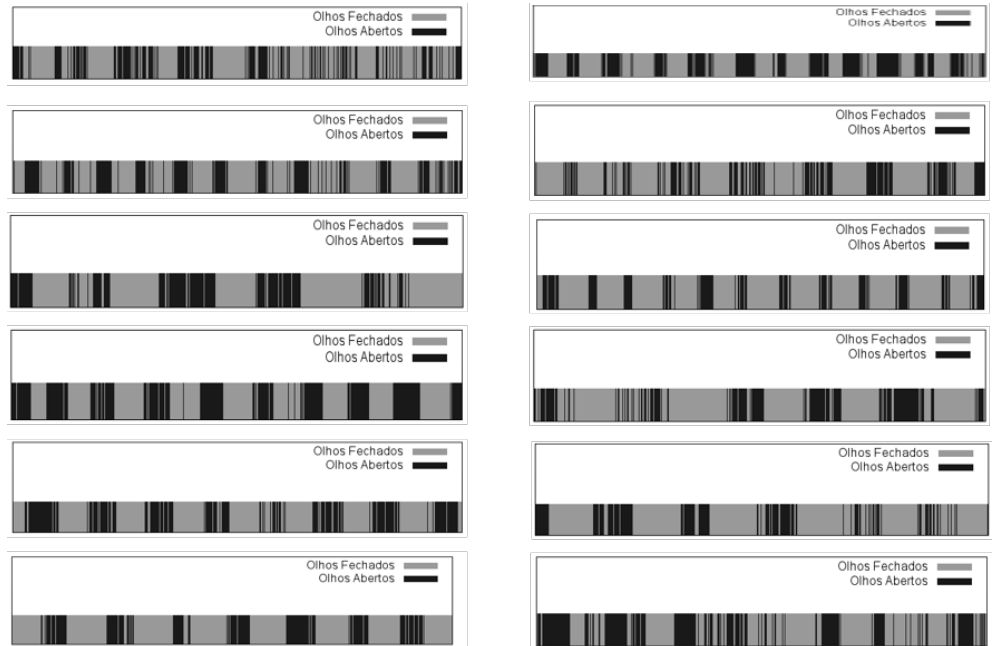
Fonte: Autor

A Figura 8 apresenta a diferença entre o resultado do detector público e o detector com melhor resposta. A ambos apresentam uma boa taxa de reconhecimento, porem taxas maiores de positivos em relação a falsos positivos deixa o classificador “olhosfechadosGAB” com melhor performance.

Simular o que acontecerá diretamente na cadeira é fundamental assim foram realizados dois testes: o primeiro com 12 voluntários, realizaram durante o mesmo período de tempo (2 minutos) a gravação de um vídeo com sua imagem da face frontal a qual realizam em momentos determinados a abertura e o fechamento dos olhos, com os seguintes resultados descritos na Figura 9.




Figure 9: Resultados da detecção dos olhos abertos e fechados



Fonte: Autor

No segundo teste, o mesmo grupo de voluntários realizou a navegação da CRA de um ponto A até um ponto B, e que utilizassem uma região de 1 metro quadrado com local de parada, conforme Figura 10.

Figure 10: Navegação da cadeira do ponto A (start) ao ponto B(stop)




Fonte: Autor

CONSIDERAÇÕES FINAIS

Os testes demonstraram claramente de HCC pode ser utilizado com sucesso num sistema de detecção de olhos fechados e a combinação entre o classificador criado para olhos fechados e de face resultou num sistema rápido e eficiente.

O detector treinado (classificador 1) com os parâmetros descritos na Tabela 2 superou o detector proposto pelo framework do OpenCV tanto na proporção de



detecção como na eficiência computacional. Neste trabalho, foi capaz de detectar aproximadamente de 98% dos resultados cerca de 9% de falsos positivos.

Os resultados mostram que a utilização de dados regionalizados permite uma detecção mais eficiente, observamos que o detector não falha a ser submetido a pessoas com as quais ele foi treinado. O que define que para um sistema robusto o paciente deve ter sua imagem da face treinada no classificador com um número significativo de posses.

O valor médio do erro foi de 0.058, ao aplicar o mínimo de vizinhos o detector retornou um número de 90% de positivos enquanto para a um número máximo de vizinhos obtivemos 98% como as janelas de detecção varrem toda a imagem com o máximo de vizinhos a interseção entre as janelas é única e, portanto, não existe a possibilidade de falso verdadeiro.

Outro ponto crucial é a oscilação do detector enquanto o indivíduo fecha e abre os olhos. Esse conjunto de erros se estabiliza em poucos milissegundos (não seria um problema caso esse momento não tivesse resultado em “trancos” na cadeira). A solução para este problema foi dada usando um tempo de espera para a estabilização da detecção (cerca de 1 segundo) e a partir daí a cadeira teve sua partida e parada realizada suavemente.

Foi possível obter taxas de em média 280 milissegundos de resposta do detector e a arquitetura demonstrou-se bastante estável, sem travamentos ou respostas demoradas ao usuário. Indivíduos envolvidos no trabalho relataram que não necessitariam de longo treinamento para utilização da cadeira e que, (após 30 minutos de teste) não sentiram desconforto ao utilizar o sistema.

REFERÊNCIAS

ARAI, Kohei; MARDIYANTO, Ronny. Eyes based eletric wheel chair control system. IJACSA) International Journal of Advanced Computer Science and Applications, v. 2, n. 12, 2011.


BRADSKI, Gary; KAEHLER, Adrian. **Learning OpenCV: Computer vision with the OpenCV library.** " O'Reilly Media, Inc.", 2008.

BRADSKI, Gary; KAEHLER, Adrian. OpenCV. **Dr. Dobb's journal of software tools**, 2000.

BRAGA, Rodrigo António Marques et al. Concept and design of the intellWheels platform for developing intelligent wheelchairs. Informatics in control, automation and robotics, p. 191-203, 2009.

BRAGA, Rodrigo António Marques et al. Plataforma de desenvolvimento de cadeiras de rodas inteligentes. PhD (Dissertação), Faculdade de Engenharia da Universidade de Porto, Programa de Doutoramento em Engenharia Informática, Porto, Portugal, set 2012.

CEZAR DA CRUZ, Daniel Marinho; AUGUSTO IOSHIMOTO, Maria Teresa. Tecnologia assistiva para as atividades de vida diária na tetraplegia completa c6 pós-lesão medular. Revista Triângulo, v. 3, n. 2, 2011.



ERIKSSON, Martin; PAPANIKOLOPOULOS, Nikolaos P. Driver fatigue: a vision-based approach to automatic diagnosis. *Transportation Research Part C: Emerging Technologies*, v. 9, n. 6, p. 399-413, 2001.

ERIKSSON, Martin; PAPANIKOTOPOULOS, Nikolaos P. Eye-tracking for detection of driver fatigue. In: *Intelligent Transportation System, 1997. ITSC'97.*, IEEE Conference on. IEEE, 1997. p. 314-319.

HALAWANI, Alaa et al. Active vision for controlling an electric wheelchair. *Intelligent Service Robotics*, v. 5, n. 2, p. 89-98, 2012.

HJELMÅS, Erik; LOW, Boon Kee. **Face Detection: Asurvey. Computer Vision and Image Understanding**, v. 83, n. 3, p. 236-274, 2001.

IBGE - Instituto Brasileiro de Geografia e Estatística. Características da população e dos domicílios resultados do universo, Censo Demográfico 2010, vol. 1, p. 161, 2011.

JI, Qiang; YANG, Xiaojie. Real-time eye, gaze, and face pose tracking for monitoring driver vigilance. *Real-Time Imaging*, v. 8, n. 5, p. 357-377, 2002.

JIAN-ZHENG, Liu; ZHENG, Zhao. Head movement recognition based on lk algorithm and gentleboost. In: *Networked Computing and Advanced Information Management (NCM), 2011 7th International Conference on. IEEE, 2011.* p. 232-236.

JOLLIFFE, Ian. Principal component analysis. John Wiley & Sons, Ltd, 2002.


KIRULUTA, Andrew; EIZENMAN, Moshe; PASUPATHY, Subbarayan. Predictive Head Movement Tracking Using a Kalman Filter *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART B: CYBERNETICS*, v. 27, n. 2, p. 326-331, 1997

LEE, Chan-Su; SAMARAS, Dimitris. Analysis and synthesis of facial expressions using decomposable nonlinear generative models. In: *Automatic Face & Gesture Recognition and Workshops (FG 2011), 2011 IEEE International Conference on. IEEE, 2011.* p. 847-852.

LIAO, Wei-Kai; COHEN, Isaac. Classifying Facial Gestures in Presence of Head Motion *Computer Vision and Pattern Recognition - Workshops. CVPR Workshops. IEEE Computer Society Conference on, 2005,* 77

LIN, Chern-Sheng; CHANG, Kai-Chieh; JAIN, Young-Jou. A new data processing and calibration method for an eye-tracking device pronunciation system. *Optics & Laser Technology*, v. 34, n. 5, p. 405-413, 2002.

MANOGNA, S.; VAISHNAVI, Sree; GEETHANJALI, B. Head Movement Based Assist System for Physically Challenged Bioinformatics and Biomedical Engineering (iCBBE), 4th International Conference on, 2010, 1-4



NGUYEN, H. T.; KING, L. M.; KNIGHT, G. Real-time head movement system and embedded linux implementation for the control of power wheelchairs. In: Engineering in Medicine and Biology Society, 2004. IEMBS'04. 26th Annual International Conference of the IEEE. IEEE, 2004. p. 4892-4895.

OPENCV, Learning. Computer vision with the OpenCV library. Gary Bradski & Adrian Kaebler-O'Reilly, 2008.

RUMÃO DE MELO, Valdenice. Avaliação da qualidade de vida de pacientes com lesão medular acompanhados em regime ambulatorial. 2009.

SCHAPIRE, Robert E. The strength of weak learnability. Machine learning, v. 5, n. 2, p. 197-227, 1990.

SONG, You; LUO, Yunfeng; LIN, Jun. Detection of movements of head and mouth to provide computer access for disabled. In: Technologies and Applications of Artificial Intelligence (TAAI), 2011 International Conference on. IEEE, 2011. p. 223-226.

TAYLOR, P. B.; NGUYEN, H. T. Performance of a Head-Movement Interface for Wheelchair Control Proceedings of the 25th Annual International Conference of the IEEE EMBS, 2003, 17-21

VIOLA, Paul; JONES, Michael. Rapid object detection using a boosted cascade of simple features. In: Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on. IEEE, 2001. p. I-511-I-518 vol. 1.

ZHAO, Zheng; WANG, Yuchuan; FU, Shengbo. Head Movement Recognition Based on Lucas-Kanade Algorithm. In: Computer Science & Service System (CSSS), 2012 International Conference on. IEEE, 2012. p. 2303-2306.