

Sistema de Detecção de Fadiga e Desvio de Atenção de Condutores de Veículos

Ricardo C. C. de Meira Santos, Ricardo A. O. Oliveira e Vicente J. P. Amorim
Computing Department (DECOM)
Federal University of Ouro Preto (UFOP)
Ouro Preto, Brazil
Email: ricardocamara03@gmail.com, rrabelo@gmail.com, vjpamorim@gmail.com

Resumo—Neste trabalho propomos um sistema de detecção de fadiga e distração de condutores. Este sistema é baseado em técnicas de processamento de imagens e reconhecimento de padrões para identificar situações de risco criadas por sonolência e distrações. As imagens são obtidas por uma câmera posicionada em frente ao motorista. O estado de sonolência do condutor é detectado utilizando o PERCLOS. Quando o PERCLOS está acima de um limiar pré-determinado o sistema acusa sonolência e quando a face do motorista não está frontal por um certo tempo o sistema acusa distração. Neste trabalho testamos o sistema em ambiente real com motoristas profissionais. O sistema aqui proposto se mostrou apto a detectar as situações de risco, atingindo 90% de precisão na detecção de distrações, além de fadiga e sonolência.

Index Terms—segurança veicular, sistemas embarcados, reconhecimento de padrões, detecção de fadiga

I. INTRODUÇÃO

Com o grande número de veículos nas estradas em qualquer hora do dia e da noite, a fadiga de condutores está entre as principais causas de acidente de trânsito em todo o mundo [1]. Estes acidentes ocorrem principalmente com motoristas profissionais por causa de longas jornadas de expediente e grandes sequências de dias consecutivos de trabalho. As distrações ao volante também aumentam o número de situações de risco e acidentes no trânsito. Outro problema é que grande parte dos motoristas não é capaz de julgar seu próprio estado em relação a sonolência, fadiga e distração. Devido a estes fatos, surge a necessidade de criação de sistemas de detecção de fadiga e distração de condutores.

Um lado pouco explorado pela literatura são os sistemas simultâneos de detecção de fadiga e distrações. Geralmente os trabalhos encontrados tratam somente de um dos dois. Em sua maioria os estudos acontecem em laboratórios com voluntários cientes dos testes que estão sendo realizados, o que pode gerar resultados enviesados. Algumas propostas são testadas até mesmo em vídeos gravados previamente sendo que o ideal para avaliação de sistemas desta natureza são testes em ambientes reais. Neste trabalho propomos um sistema que aumenta a segurança no ambiente veicular monitorando o comportamento dos motoristas e detectando fadiga e desatenção dos mesmos. O sistema aqui proposto foi testado em ambiente real, instalado em um veículo em uso e com motoristas profissionais durante seus períodos de trabalho servindo como casos de teste. O sistema faz uso de métodos

visuais utilizando de uma câmera, faróis infravermelhos e um computador embarcado no veículo. Considerando a posição da face do motorista nas imagens pode-se definir onde está focada a atenção do condutor. Além disso, as imagens dos olhos permitem inferir se o mesmo encontra-se sonolento ou não. Sempre que é detectada uma situação de risco o sistema alerta o motorista através de um sinal sonoro. Sendo assim, cabe ao motorista tomar uma providência.

II. REVISÃO

Os sistemas de detecção de fadiga de condutores se dividem em 3 grandes grupos: baseados em fisiologia, baseados no veículo e baseados em visão computacional.

Os sistemas baseados em fisiologia têm seu foco na fisiologia do motorista. Nesta classe, o nível de alerta do motorista pode ser medido com Eletroencefalografia (EEG), Eletrooculograma (EOG), Eletrocardiograma (ECG), entre outros [2] [3]. Os métodos baseados em fisiologia, em geral, são bem invasivos, pois necessitam da utilização de eletrodos nos condutores, tornando assim pouco viável sua comercialização. Outro problema em relação aos sistemas baseados em fisiologia é a dificuldade na detecção de distrações do motorista. Como exemplo, não ocorrem mudanças significativas na fisiologia do motorista quando operando um telefone celular ou o som do carro.

Os sistemas baseados no veículo possuem como principal característica o uso de sensores onde através de suas medições procura-se inferir o estado de alerta do motorista. Estes sistemas geralmente utilizam medições de sensores no volante e nos pedais, além de monitorar os movimentos que o condutor aplica ao volante como em [4] e [5]. O motorista fadigado tende a ter movimentos mais imprecisos ao volante, além de viradas mais bruscas para alinhar o veículo com a pista. O desempenho desta classe de sistemas é prejudicado em pistas ruins que realmente necessitam de viradas bruscas ao volante. Outro ponto fraco desta classe é que tais sistemas tendem a detectar distrações somente após sua ocorrência.

Os sistemas baseados em visão computacional utilizam uma ou mais câmeras filmando o motorista. Geralmente estes métodos fazem uso de técnicas de reconhecimento de padrões e processamento de imagens para localizar a face do motorista, conseguindo prever sua orientação. Uma vez detectada a face, torna-se possível também a identificação dos olhos e

a classificação se estão abertos ou fechados. O principal problema destes sistemas é a variação de luminosidade do ambiente. Outro problema comum reside na utilização de óculos, que podem tender a diminuir a acurácia do sistema.

III. TRABALHOS RELACIONADOS

Em [6] os autores propõem um sistema com base em características visuais. Utilizam o algoritmo Viola-Jones proposto em [7] para detecção de faces e o filtro de Kalman para rastrear a face. Para detecção de olhos utilizam PCA (*Principal Component Analysis*) [8] durante o dia e um detector baseado em LBP (*Local Binary Patterns*) [9] durante a noite. O descritor LBP descreve a imagem comparando cada pixels com seus vizinhos. Para detecção de sonolência foi utilizado PERCLOS (*Percentage of Eye Closure*) [10]. O PERCLOS é dado pela porcentagem de quanto tempo em que o olho esteve fechado um limite predeterminado de tempo. Este sistema obteve uma taxa processamento de FPS (*Frames Per Second*) de 9,5 FPS. Os resultados foram de 97% de acurácia na classificação dos olhos tanto para dia quanto para noite e 5% de alarmes falsos. Este trabalho não apresentou testes em usuários com óculos.

Em [11] é apresentado um sistema utilizando um algoritmo com fusão de métodos fisiológicos e visuais. São processados sinais de um sensor de fotopletismografia (PPG) instalado no volante do veículo. É utilizado ASM (*Active Shape Model*) [12] para detectar os pontos característicos da face e um *smartphone* Android para receber as informações dos sensores via rede sem-fio e posteriormente processar os dados para identificar se o motorista está habilitado a conduzir o veículo. Tais dados são analisados utilizando uma rede Bayesiana dinâmica para prever se o motorista se encontra apto a dirigir. Este trabalho chegou a uma taxa de acurácia na detecção de fadiga 95% e 10% de detecções falsas.

Em [13] são utilizadas câmeras de infravermelho e AdaBoost [14] para detecção da face. Os olhos são localizados através de extração dos pontos característicos da face com Redes Neurais Convolucionais identificando a abertura e fechamento dos mesmos. Foram realizados testes com óculos e sem óculos, e para a detecção de fadiga foi utilizado o PERCLOS. Este trabalho apresenta um diferencial que são os testes com óculos. Em contrapartida, eles não realizam experimentos em ambiente veicular, tampouco em plataforma de desenvolvimento embarcado. Foi obtida uma acurácia de 95,81% de acertos com usuários sem óculos e 91,45% para usuários com óculos.

Em [15] realizamos a comparação de plataformas de desenvolvimento embarcado quando executam um *software* de detecção de distrações de condutores. Neste trabalho são comparadas 4 plataformas: Texas TI BeagleBone Black, CubieBoard, WandBoard Single e WandBoard Quad. Estas 4 plataformas foram submetidas a execução de um sistema de detecção de face frontal e lateral para análise de desempenho do *hardware* quando da execução de um *software* dessa natureza. A plataforma WandBoard Quad se mostrou melhor que as outras alcançando uma taxa de FPS alta em relação as demais.

IV. METODOLOGIA

A. Visão Geral do Sistema

O sistema é dividido em três componentes básicos: uma câmera, uma unidade de processamento e um computador de bordo. Uma câmera infravermelho é posicionada em frente ao motorista. Dessa forma, este sistema se encaixa na classe de baseados em visão computacional. Para o funcionamento noturno são utilizados faróis de LED infravermelhos. Na Figura 1 podemos ver a instalação da câmera (em vermelho) e dos faróis infravermelhos (em verde).



Figura 1. Posicionamento da câmera e faróis no veículo.

A unidade de processamento é o elemento do sistema responsável pelo tratamento das imagens. Nela são executados os algoritmos de visão computacional responsáveis por prever o estado de sonolência e desatenção do motorista. Em [15] comparamos 4 plataformas diferentes em relação ao seu desempenho quando executam algoritmos de visão computacional relacionados a detecção de face. Desta forma a unidade de processamento foi desenvolvida com o processador Freescale i.MX6 Quad Core e com 1GB de RAM DDR3, configuração semelhante a WandBoard Quad, plataforma a qual obteve o melhor desempenho em [15]. A unidade de processamento envia para o computador de bordo a posição da face do motorista, ou seja, se a posição da face está frontal, lateral ou se não foi detectada. Além da posição da face também é enviado por quanto tempo a mesma se encontra nesta posição. Quando a face está voltada para a frente o sistema analisa a situação dos olhos e, caso estejam fechados, também é enviado o tempo de olho fechado no dado instante. Outra informação enviada é o PERCLOS dos últimos 3 minutos em que a face esteve voltada para frente, além do número de piscadas por minuto no último minuto.

O computador de bordo é o dispositivo responsável pelo cruzamento das informações de velocidade do veículo com aquelas geradas pela unidade de processamento, considerando os dados relativos ao motorista somente quando o veículo se encontra acima de um limiar configurável de velocidade. Esta tática é adotada para que o sistema não alerte o motorista com o veículo parado e durante manobras. O limiar de velocidade escolhido neste trabalho é de 40km/h. Caso o computador de bordo receba a informação que a face não está voltada para

a frente ou os olhos estão fechados por um tempo maior que um limiar predefinido o computador de bordo emite um alerta sonoro para alertar o motorista sobre a situação de risco.

A primeira etapa do algoritmo é a detecção da face. Nela, primeiramente se busca por uma face frontal utilizando o algoritmo proposto em [7] com os incrementos descritos por [16]. A imagem captada pela câmera com resolução de 640x480 é redimensionada para 30% do seu tamanho original. Sempre que uma face é detectada, a região de busca no próximo frame é limitada a uma área menor que contém a posição atual da face, reduzindo assim o espaço de busca da próxima face, como mostrado na Figura 2. Caso, a face frontal não seja encontrada, o algoritmo busca pela face lateral utilizando um detector baseado em LBP. Quando o algoritmo não encontra uma face frontal inicia-se a contabilização de tempo de distração.

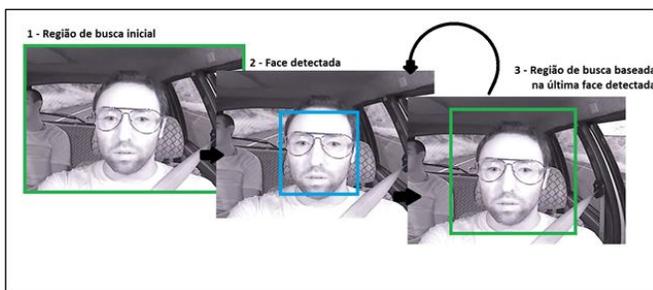


Figura 2. Detecção de face utilizando Viola-Jones.

Sempre que a face frontal é encontrada o algoritmo passa para a segunda etapa, onde ocorre a localização dos olhos. Esta fase recebe como entrada a posição da face, depois define a área de busca de cada olho através da geometria facial. Durante a inicialização do sistema são detectadas imagens dos olhos através do algoritmo Viola-Jones e em seguida selecionada uma imagem de cada olho para servir como *template* para localização dos mesmos. Terminada a inicialização, os olhos passam a ser detectados utilizando casamento de *template*.

Após sua detecção os olhos são classificados como abertos ou fechados. Visando otimizar o sistema, somente um dos olhos é localizado na etapa anterior. Para a classificação de olhos são extraídas as características das imagens utilizando 3 classificadores: LBP, LTP [17] e HOG. A saída destes três descritores são concatenadas e submetidas a uma Rede Neural Artificial (RNA) [18]. Assim, possibilitando a detecção de piscadas do condutor e o cálculo do PERCLOS.

A Figura 3 apresenta o funcionamento do algoritmo de forma geral. O algoritmo foi implementado utilizando a biblioteca OpenCV 2.4.14 em linguagem C++.

V. EXPERIMENTOS

O sistema foi instalado em um caminhão de uma empresa brasileira de fabricação e transporte de gases industriais. Isso livrou o experimentos de possíveis vieses criados em laboratório, como desatenção proposital, simulação de sonolência, entre outros. Todas as situações registradas nos experimentos foram reproduzidas em ambientes reais e não propositalis.



Figura 3. Algoritmo

Foi utilizado um DVR (*Driver Video Recorder*) para gravar as imagens que serviam de entrada para o sistema. Dessa forma, os vídeos gravados no DVR foram utilizados como referência para análise de acurácia do sistema. Os dados gerados foram registrados no computador de bordo. Assim, foi possível cruzar os dados gerados pelo sistema com os vídeos gravados. Isso permitiu mensurar a acurácia na detecção de desatenções. Além disso, permitiu ainda uma análise do estado do motorista em relação a sonolência. Os vídeos gravados tiveram duração de 30 minutos cada.

Em [19] é mostrado a correlação entre bocejos e o estado de vigília das pessoas, explicando que há uma tendência a ocorrer bocejos frequentes quando elas estão fadigadas. Desta maneira, para classificar o estado de vigília dos motoristas dos testes, a característica visual que utilizamos foi o número de bocejos em cada vídeo de 30 minutos. Foram criadas duas classes (A e B) para dividir os resultados obtidos. A classe A consiste nos motoristas que consideramos não apresentarem fadiga ou sonolência, se mostrando aptos a conduzirem os veículos. A classe B engloba os motoristas que apresentaram sinais de fadiga e sonolência durante o período de cada vídeo. A classe A engloba motoristas que bocejaram no máximo 7 vezes em 30 minutos. E a classe B engloba motoristas que bocejaram mais de 14 vezes em 30 minutos. Não houve nenhum vídeo com número de bocejos no intervalo fechado entre 8 e 13. De forma resumida, a classe A está apta a conduzir o veículo, não mostrando sinais visuais de fadiga e a classe B não se mostra apta a exercer tal tarefa, caracterizando uma situação de risco.

Para detectar situações de risco geradas por distração dos condutores, a unidade de processamento envia para o computador de bordo um sinal a cada período de 2 segundos nos quais não é detectada uma face frontal. Tal fato caracteriza uma situação de risco onde a atenção do motorista não está na pista. Estas distrações são classificadas como lateral, quando o motorista olha para os lados, e baixo quando o motorista olha para baixo. O último tipo de distração é olho fechado, caracterizada pela detecção de que o motorista está com olho fechado por mais de 2 segundos. Então, cada vez que o sistema detecta que há alguma distração lateral, baixo ou olho fechado é registrado um evento no computador de bordo.

Nestes experimentos foram analisados um total de 31 vídeos. Destes 31 vídeos, 19 foram utilizados para analisar os valores de PERCLOS, totalizando 9,5 horas. O número de vídeos utilizados para analisar é menor que 31 pois em 12 deles não foram gerados valores de PERCLOS, totalizando 6 horas. Isto ocorre por que neles a velocidade do veículo oscilou entre acima e abaixo de 40 km/h, não sendo suficiente para gerar dados de PERCLOS durante os 30 minutos considerados. Para a análise de faltas foram utilizados os 31 vídeos. No total foram 15,5 horas de experimentos.

VI. RESULTADOS

A. Taxa de FPS

A taxa de FPS do sistema varia entre as situações onde a face da pessoa está voltada para frente e quando não está. Quando a face está voltada para frente, ou seja, quando o sistema está detectando faces frontais, a taxa de FPS do sistema permanece em 20 FPS. Nesta situação o sistema realiza somente a busca da face frontal e o processamento relacionado aos olhos. Uma taxa de 20 FPS é suficiente para detectar as piscadas, sendo maior que 9,5, que é a maior taxa de FPS apresentada nos trabalhos relacionados.

Quando há detecção de faces laterais consecutivas, a taxa de FPS do sistema cai para 6 FPS. Neste caso há, inicialmente, busca de face frontal e somente depois busca-se pela face lateral em cada imagem de forma consecutiva. Quando se detecta uma face lateral o sistema registra para qual lado a face foi detectada, de modo que na próxima imagem, quando for ocorrer a busca de face lateral, execute-se primeiro a busca pela posição, esquerda ou direita, que foi registrada anteriormente.

Quando não há face detectada, o sistema tem uma taxa média de 4 FPS. Como o sistema detecta distração do motorista olhando para baixo através do histórico de movimentação da face, quando não há face detectada, a taxa de FPS também é 4 FPS. Este caso se mostra mais lento, pois em cada imagem há a busca pela face frontal, depois pelas laterais em ambos os lados. A Tabela I resume os valores da taxa de FPS para cada uma das situações.

B. Detecção de Distrações

Em relação as classificações de distrações detectadas pelo sistema, além de distrações de faces laterais e voltadas para baixo, também há as de olhos fechados. Isto ocorre quando

Tabela I
FPS

Taxa de FPS	
Posição da Face	FPS Médio
Frontal	20
Lateral	6
Baixo	4

o motorista fecha seus olhos por um tempo maior ou igual a 2 segundos. Este mesmo tipo de distração é detectado quando o motorista está olhando para baixo e sua atenção perde o foco que deveria ser a estrada. Nos testes realizados, a maioria destas ocorrências foi quando o motorista estava fazendo uso do telefone celular, focando sua atenção por muito tempo no painel ou lendo algum papel enquanto dirigia. Nestas situações, a imagem do olho se assemelha a imagem de um olho fechado pelo fato do motorista estar olhando para baixo, como pode ser observado na Figura 4.

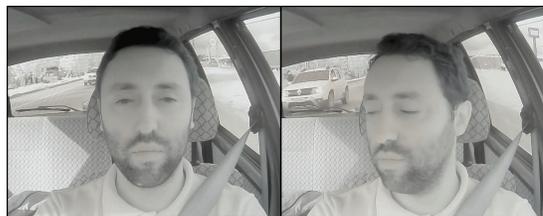


Figura 4. Motorista distraído

A Tabela II exhibe os dados de distrações de cada tipo separadamente. Na Tabela II as siglas VP, FP e FN se referem a verdadeiros positivos, falsos positivos e falsos negativos respectivamente. Podemos notar que a distração que ocorre mais vezes é a lateral, em seguida a de olhos fechados. A maioria das distrações de olhos fechados ocorrem quando os motoristas estão distraídos olhando para baixo sem mudar a posição da face. As distrações de face voltada para baixo são as que ocorrem em menor quantidade. A maior taxa de falsos positivos ocorre na detecção de faltas de olhos fechados e a menor taxa em distrações para baixo.

Tabela II
TABELA DE DISTRAÇÕES

Tabela de Distrações				
Tipo	Reais	VP	FP	FN
Lateral	152	147	11	5
Olhos Fechados	130	130	19	0
Baixo	10	9	1	1
Total	292	286	31	6

A Tabela III é a matriz de confusão resultante das somas de todos os tipos de distrações. O número das situações que não foram distrações e não foram detectadas representam todo o momento que o motorista presta atenção na pista e o sistema não acusa como distração. Este valor foi gerado através da multiplicação do total de vídeos utilizados na análise de distrações (31) com tamanho em minutos (30)

com tamanho em segundos (60) dividindo-o por 2, o que representa o tempo de cada distração. Obteve-se assim o valor 27900, que representa o número total de distrações de dois segundos possíveis. Subtraindo-se deste número todas as distrações detectadas (286), todas as distrações não detectadas (6) e todas detectadas de maneira errada (31) tem-se 27577.

Tabela III
MATRIZ DE CONFUSÃO DAS DISTRAÇÕES

	Distração	Não Distração
Detectadas	286	31
Não Detectadas	6	27577

A Tabela IV apresenta os dados estatísticos em relação a detecção de distrações em geral. A taxa de FPs se mostrou maior que a taxa de FNs, assim observa-se que o sistema tem tendência maior a detectar distrações que não ocorrem em comparação com distrações que ocorrem. Ou seja, se tratando de erros, a probabilidade do sistema errar acusando uma situação que não seja de risco como de risco é um pouco maior que deixar de acusar uma situação de risco. O sistema apresentou uma taxa de acurácia próxima de 99%. Sendo assim tem-se uma probabilidade de 99% a cada dois segundos do sistema classificar a situação como risco ou não corretamente. A probabilidade de uma distração ser classificada corretamente é de 90%, com este valor se referindo à precisão. A revocação foi 97%, indicando que dada uma distração do motorista, esta possui 97% de chance de ser detectada pelo sistema.

Tabela IV
ESTATÍSTICA DA DETECÇÃO DE DISTRAÇÕES

Taxa de Falsos Positivos	0,0011
Taxa de Verdadeiro Positivos	0,9795
Taxa de Falsos Negativos	0,0002
Taxa de Verdadeiros Negativos	0,9989
Acurácia	0,9987
Precisão	0,9022
Revocação	0,9795

C. Análise de fadiga

A detecção de fadiga toma como base o número de PERCLOS, salvo a cada 3 minutos pelo computador de bordo. Como descrito anteriormente, classificou-se o estado de vigília de cada motorista em duas classes: classe A: motoristas aptos a dirigir; e classe B: motoristas inaptos a dirigir, ou seja, fadigados. A classe A engloba todos os motoristas que bocejaram no máximo 7 vezes em 30 minutos e a classe B engloba os motoristas que bocejaram no mínimo 14 vezes. Analisando a classe B, visualmente nota-se que os motoristas não estavam aptos a dirigir de forma segura e isso está correlacionado a sua fadiga ou sonolência. Nos testes foram analisados 4 vídeos de motoristas fadigados da classe B e 10 vídeos de motoristas da classe A. Na Tabela V é exibida a correlação entre PERCLOS e o número de bocejos para a classe A e B. Nota-se que, quando o número de bocejos é alto,

o valor PERCLOS também tende a ser alto, tornando possível a identificação de estado de fadiga através de uma análise dos valores de PERCLOS. Também nota-se uma discrepância nos valores médios de PERCLOS quando comparadas as duas classes.

Tabela V
RELAÇÃO PERCLOS E BOCEJOS

	Classe A		Classe B	
	PERCLOS	Bocejos	PERCLOS	Bocejos
Media	3,48	2,40	10,69	27,25
D. P.	2,06	2,87	5,82	9,58

A Figura 5 mostra o gráfico contendo os valores médios de PERCLOS para as duas classes. Como o valor PERCLOS é gravado no computador de bordo a cada 3 minutos, cada vídeo de 30 minutos gerou 10 medições. Fica claro a diferença entre os valores medidos para cada classe de motoristas, sendo que o valor de PERCLOS para a classe B é sempre maior que aquele da classe A.

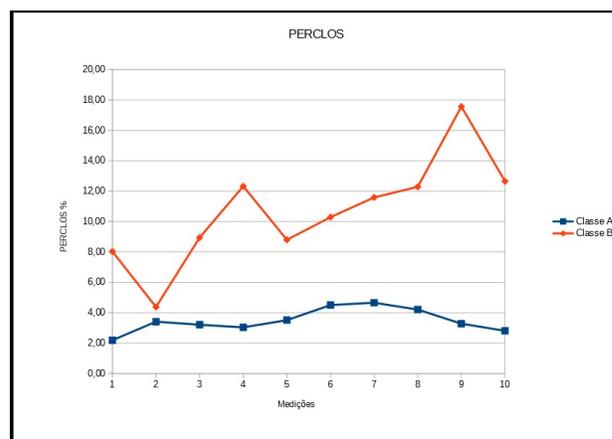


Figura 5. PERCLOS para classes A e B

As classes A e B não incluem os vídeos onde os motoristas estavam distraídos lendo e manipulando objetos dentro do veículo. Para estes casos foi criada a classe C que se trata dos motoristas com alto índice de distração e que continuavam com a face voltada para frente, olhando de fato para baixo. Na maioria dos casos são motoristas que estão utilizando telefones celulares simultaneamente à condução do veículo. Este tipo de situação foi mostrado na Figura 4, gerando um alto índice de PERCLOS e também são situações de risco. Na Figura 6 temos o gráfico de PERCLOS incluindo a classe C. Essa possui uma taxa de PERCLOS médio de 12,58, mas um desvio padrão de 13,95. Este desvio padrão alto deve-se ao fato do valor de PERCLOS variar muito quando se compara os momentos em que o motorista está olhando fixamente para baixo e os momentos que ele foca sua atenção de fato da pista.

Para detectar situações de risco através do PERCLOS foi estabelecido que cada valor maior que 10% recebido pelo computador de bordo se configura em uma situação de risco e um alerta é gerado pelo sistema. Sendo assim, o sistema não

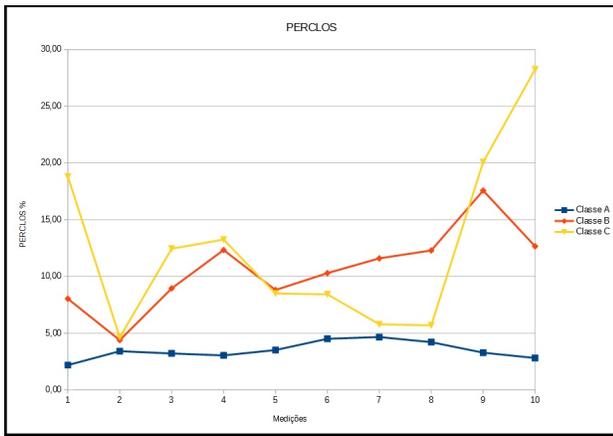


Figura 6. PERCLOS para classes A,B e C

gerou nenhum alerta relacionado ao PERCLOS na classe A, já que os valores de PERCLOS se mantiveram baixos, uma vez que os motoristas estiveram em alerta, não fadigados, e focados na pista de maneira geral. Para a classe B, o sistema gerou uma média de 6 alertas a cada vídeo de 30 minutos, sendo que o valor mínimo foram 4 alertas e o máximo 8. Para a classe C o sistema gerou uma média de 3 alertas por vídeo, sendo que o mínimo de alertas nesta classe foi 2 e o máximo 6. Concluímos que nestes testes o sistema se mostrou apto a detectar todas as situações de risco geradas pela análise de PERCLOS dos vídeos de 30 minutos.

VII. CONCLUSÃO

Neste trabalho propomos um sistema de detecção de fadiga e distração capaz de aumentar a segurança nos ambientes veiculares. O sistema aqui proposto funciona em ambiente diurno e noturno. A taxa de FPS do sistema quando o motorista está com a face voltada para frente é 20 FPS. Esta taxa de FPS supera todos os trabalhos relacionados citados aqui.

Os testes realizados foram feitos em situações reais. Classificamos as situações de risco criadas através de distrações e fadiga dos condutores. Para as distrações em que os motoristas mudam a direção de suas faces ou fecham os olhos por mais de 2 segundos o algoritmo obteve 90% de precisão. Já os trabalhos relacionados não realizam a junção de detecção de fadiga e distração, realizando somente a detecção de fadiga. Apresentamos aqui um método na detecção de ambos, pois assim o sistema monitora não somente a fadiga como também as distrações que possam ocorrer e gerar situações de risco.

Em relação a detecção de fadiga o sistema foi capaz de reconhecer todos os casos em que os motoristas estavam fadigados através do PERCLOS, assim como nos trabalhos relacionados. O sistema obteve uma média de 6 alertas de risco a cada 30 minutos para motoristas sonolentos ou fadigados. Não houve detecção de risco através do PERCLOS com motoristas aptos a dirigir. O sistema também se mostrou capaz de detectar distrações de motoristas que mantém a face em posição frontal, mas o foco de sua atenção em outros objetos.

REFERÊNCIAS

- [1] L. Hartley, T. Horberry, N. Mabbott, and G. P. Krueger, "Review of fatigue detection and prediction technologies," *National Road Transport Commission*, 2000.
- [2] S. K. Lal, A. Craig, P. Boord, L. Kirkup, and H. Nguyen, "Development of an algorithm for an eeg-based driver fatigue countermeasure," *Journal of safety Research*, vol. 34, no. 3, pp. 321–328, 2003.
- [3] A. Kokonozi, E. Michail, I. Chouvarda, and N. Maglaveras, "A study of heart rate and brain system complexity and their interaction in sleep-deprived subjects," in *Computers in Cardiology, 2008*. IEEE, 2008, pp. 969–971.
- [4] R. Sayed and A. Eskandarian, "Unobtrusive drowsiness detection by neural network learning of driver steering," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 215, no. 9, pp. 969–975, 2001.
- [5] A. Eskandarian and A. Mortazavi, "Evaluation of a smart algorithm for commercial vehicle driver drowsiness detection," in *Intelligent Vehicles Symposium, 2007 IEEE*. IEEE, 2007, pp. 553–559.
- [6] A. Dasgupta, A. George, S. Happy, and A. Routray, "A vision-based system for monitoring the loss of attention in automotive drivers," *IEEE Trans. Intelligent Transportation Systems*, vol. 14, no. 4, pp. 1825–1838, 2013.
- [7] P. Viola and M. Jones, "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*, vol. 1. IEEE, 2001, pp. I–I.
- [8] J. Yang, D. Zhang, A. F. Frangi, and J.-y. Yang, "Two-dimensional pca: a new approach to appearance-based face representation and recognition," *IEEE transactions on pattern analysis and machine intelligence*, vol. 26, no. 1, pp. 131–137, 2004.
- [9] M. Topi, O. Timo, P. Matti, and S. Maricor, "Robust texture classification by subsets of local binary patterns," in *Pattern Recognition, 2000. Proceedings. 15th International Conference on*, vol. 3. IEEE, 2000, pp. 935–938.
- [10] W. W. Wierwille, S. Wreggit, C. Kirn, L. Ellsworth, and R. Fairbanks, "Research on vehicle-based driver status/performance monitoring; development, validation, and refinement of algorithms for detection of driver drowsiness. final report," Tech. Rep., 1994.
- [11] B.-G. Lee and W.-Y. Chung, "Driver alertness monitoring using fusion of facial features and bio-signals," *IEEE Sensors Journal*, vol. 12, no. 7, pp. 2416–2422, 2012.
- [12] Z.-L. Zheng and F. Yang, "Enhanced active shape model for facial feature localization," in *Machine Learning and Cybernetics, 2008 International Conference on*, vol. 5. IEEE, 2008, pp. 2841–2845.
- [13] F. Zhang, J. Su, L. Geng, and Z. Xiao, "Driver fatigue detection based on eye state recognition," in *Machine Vision and Information Technology (CMVIT), International Conference on*. IEEE, 2017, pp. 105–110.
- [14] Y. Freund, R. Schapire, and N. Abe, "A short introduction to boosting," *Journal-Japanese Society For Artificial Intelligence*, vol. 14, no. 771–780, p. 1612, 1999.
- [15] R. O. RCCM SANTOS, "Análise de desempenho de um sistema embarcado de deteco de fadiga de condutores," *IV Simpósio Brasileiro de Engenharia de Sistemas Computacionais*, 2014.
- [16] R. Lienhart and J. Maydt, "An extended set of haar-like features for rapid object detection," in *Image Processing. 2002. Proceedings. 2002 International Conference on*, vol. 1. IEEE, 2002, pp. I–I.
- [17] W.-H. Liao, "Region description using extended local ternary patterns," in *Pattern Recognition (ICPR), 2010 20th International Conference on*. IEEE, 2010, pp. 1003–1006.
- [18] S. A. Ahmed, S. Dey, and K. K. Sarma, "Image texture classification using artificial neural network (ann)," in *Emerging Trends and Applications in Computer Science (NCETACS), 2011 2nd National Conference on*. IEEE, 2011, pp. 1–4.
- [19] A. G. Guggisberg, J. Mathis, U. S. Herrmann, and C. W. Hess, "The functional relationship between yawning and vigilance," *Behavioural brain research*, vol. 179, no. 1, pp. 159–166, 2007.