

A Mobile Application for Driver's Drowsiness Monitoring based on PERCLOS Estimation

G. Soares, D. de Lima, and A. de Miranda

Abstract—Vehicular accidents caused by driver drowsiness involve about 7,000 people/year in Brazil, only on federal highways, and cause psychic damage and traumatic stresses for both the victims involved and their families. Drowsiness is characterized by reduced level of vigilance and concentration, which are essential during driving activity. Due to this adversity, many applications of drowsiness detection had been continuously developed through electrical body signals to alert the driver at the time when sleepiness is identified, such as heart rate variability (HRV) and electroencephalogram (EEG). Although these methods work, the use of electrodes in the driver's body is highly invasive. Therefore, we propose a drowsiness detection system based on driver's real time video capture, by estimating the percentage of eyelid closure over a period, without any contact device. Since the use of smartphones has been growing in the last decade, the system has been implemented in a mobile phone even with memory and processing limitations. Processing reduction procedures were developed to improve the application performance, such as the reduction of the region of interest and the limitation of the search window, which increased by 93.09% the number of frames per second and allowed the application to operate smoothly.

Index Terms—Driver monitoring, Drowsiness detection, Percentage of eyelid closure (PERCLOS).

I. INTRODUÇÃO

A ampliação do uso de veículos pela sociedade moderna desperta uma enorme preocupação sobre o tema da segurança dos condutores. Os acidentes que envolvem veículos são responsáveis por prejuízos diversos e, sobretudo, constituem uma das maiores fontes mundiais de tragédias. As principais causas de acidentes podem ser divididas em dois grupos. O primeiro conjunto consiste de causas evitáveis, como a falta de atenção, o uso de telefone durante a condução e a falta de experiência com a direção. Essas causas podem ser erradicadas com o aprimoramento do sistema de ensino e educação de trânsito. O segundo grupo é composto por fatores incontroláveis, como condições fisiológicas, que são passíveis de monitoramento. Inclui-se, neste grupo, a sonolência que, embora seja de difícil prevenção, é passível de fiscalização [1].

Nos últimos anos, sistemas de detecção de sonolência vêm sendo desenvolvidos por equipes de pesquisa das principais fabricantes de veículos. Entretanto, essas tecnologias estão sendo implementadas em novas frotas fabricadas, sobretudo em veículos com maiores funcionalidades, o que exclui os automóveis antigos e de linha inferior. Logo, isso abre um

universo de possibilidades para novas abordagens de identificação de sonolência baseadas em sistemas de baixo custo, os quais consistem de tecnologias que realizam leituras de comportamentos do motorista, da forma como ele dirige e de seus sinais fisiológicos [2].

Nesse contexto, sistemas baseados em visão computacional se tornaram uma excelente alternativa para monitorar e identificar características da sonolência por parte do condutor. Embora os algoritmos de detecção exijam bastante processamento da unidade central de processamento, sobretudo em imagens com grandes resoluções [3], o que resulta na diminuição do número de quadros por segundo do vídeo, nós propomos métodos de melhoria de performance baseados na redução da região de interesse da busca de características e na limitação do intervalo de expansão dessa região. Dessa forma, conseguimos validar os resultados e aplicar a tecnologia em um dispositivo móvel.

Sendo assim, este trabalho apresenta uma aplicação de monitoramento da sonolência e do adormecimento em uma plataforma de dispositivos móveis, com base no monitoramento contínuo do comportamento das pálpebras e dos olhos do motorista segundo o parâmetro da porcentagem de fechamento da pálpebra (PERCLOS) [4]. Essa aplicação é projetada para operar em qualquer tipo de veículo, uma vez que usa somente recursos do smartphone e não requer nenhum custo adicional relacionado aos hardwares. Dadas as limitações que um smartphone possui, este trabalho aborda e resolve três desafios relacionados à implementação de um algoritmo de identificação de sonolência em dispositivos móveis: otimização de processamento, gerenciamento de oclusão em imagens e análise do estado dos olhos em cada quadro.

Este trabalho está organizado como segue: antes de introduzir nosso sistema de identificação de sonolência, uma breve apresentação do estado da arte é feita na Seção II. A Seção III expõe a metodologia usada na aplicação, onde são feitas descrições dos procedimentos que compõem a análise do comportamento dos olhos do motorista em cada quadro. Na Seção IV são apresentados os resultados quantitativos e qualitativos de cada procedimento, os quais são discutidos e comparados com outros trabalhos da literatura. Por fim, as conclusões gerais do trabalho e as perspectivas de trabalhos futuros são dadas na Seção V.

II. TRABALHOS RELACIONADOS

A detecção de sonolência é um dos grandes desafios dentro da área dos sistemas avançados de assistência ao condutor (ADAS). As principais pesquisas relacionadas são agrupadas e baseadas em três tipos de sinais na caracterização da sonolência: fisiológicos, veiculares e comportamentais [2].

Os autores G. Soares, D. Alves de Lima e A. de Miranda Neto são do Departamento de Engenharia da Universidade Federal de Lavras. Lavras, Minas Gerais, 37200000, Brasil. Os autores podem ser contatados através de gabriel-cambráia@hotmail.com e danilo.delima@deg.ufla.br.

O primeiro grupo é composto por procedimentos que usam sinais elétricos do corpo humano como dados de entrada para o sistema de estimação [5]. Os sinais biomédicos são extremamente úteis para coletar informações da resposta do corpo durante o ciclo da sonolência, como a variabilidade do batimento cardíaco (HRV) [6] e sinais cerebrais provenientes de eletroencefalogramas (EEG) [7], [8], [9]. Os métodos baseados nos sinais elétricos biológicos apresentam índices de precisão elevados, no entanto, são limitados ao ambiente do laboratório de pesquisa, visto que a aquisição dos sinais da atividade elétrica exige a aplicação de eletrodos em regiões do corpo humano [10].

Por conta da invasividade na aquisição de sinais elétricos de motoristas, métodos de identificação de sonolência baseados em informações do veículo foram criados para avaliar o estado do condutor com base em parâmetros como velocidade [11], aceleração e frenagem [12], posição na faixa [13] e angulação do volante [14]. Embora essa abordagem não seja desconfortável, ela é considerada lenta para prever o estado de sonolência [15].

Com a melhoria e a redução do tamanho de câmeras e unidades de processamento, procedimentos fundamentados em comportamentos do motorista se tornaram populares. Geralmente, esses sistemas são compostos por câmeras para aquisição de imagem do ambiente interno do veículo. As imagens são processadas com o objetivo de identificação de atividades praticadas por motoristas, como o bocejo [16] e, especialmente, o piscar dos olhos [17], [18]. Por meio do monitoramento dos estados dos olhos é possível calcular a duração e a frequência das piscadas, como também os seus tempos de abertura e fechamento. A porcentagem de fechamento da pálpebra sobre a pupila ao longo do tempo (PERCLOS) [4], usada neste trabalho, identifica o sintoma de sonolência caracterizado pela lentidão da abertura dos olhos durante o piscar e é considerada uma das medidas mais promissoras de vigilância em tempo real para os sistemas de detecção de sonolência [10], [19], [20]. Essa métrica vem sendo usada em pesquisas recentes, como as de [21] e [22], sobretudo por conta da popularização dos smartphones. Em [23], tem-se a fusão de informações sobre a fisiologia do motorista, por meio de sinais de eletrocardiografia, o indicador PERCLOS [4] e a velocidade do veículo, estimada por meio dos sensores inerciais do telefone, para avaliar o nível de sonolência do motorista.

III. METODOLOGIA

Inicialmente, nesta seção, os principais procedimentos para a criação da aplicação são apresentados. Em seguida, cada método é descrito minuciosamente em tópicos sucessivos na mesma ordem em que as funções são executadas no programa.

A. Visão Geral do Sistema

O sistema desenvolvido neste trabalho, ilustrado na Figura 1 é composto por sete etapas sequenciais. Inicialmente, a imagem é recebida pela câmera e tem sua resolução reduzida para 640x480 pixels, com o intuito de diminuir a quantidade de pontos a serem analisados durante o processo de detecção

da face, de olhos abertos e de olhos fechados. Em seguida a imagem é pré-processada para criar um ambiente em que as características são facilmente identificáveis e um modelo de identificação de face é empregado. A partir da região da face é aplicado o método de extração da área dos olhos, que conta com operações geométricas para reduzir a área da face em uma área ao redor dos olhos, representada por um retângulo. Posteriormente esse retângulo é passado para um sistema preditor (filtro de Kalman) [24] para que a área dos olhos seja rastreada mesmo em situações de oclusão parcial da face, e este é o local onde os modelos propostos de identificação de olhos abertos e de olhos fechados operam. Por fim, as ocorrências de olhos abertos e fechados em cada frame são contabilizadas para a estimação do PERCLOS [4] e os modelos de identificação de sonolência e de adormecimento avaliam o estado do condutor em intervalos específicos de tempo.

B. Aquisição e Pré-processamento da Imagem

A aquisição e o pré-processamento da imagem representam o recebimento e o tratamento dos quadros para criar um ambiente favorável para a detecção de características. A aquisição da imagem é feita pela câmera frontal do smartphone em sua resolução natural e é redimensionada para 640x480 pixels. Em seguida, os canais da imagem são transformados em escala de cinza e seus contrastes são elevados por meio da equalização do histograma. Finalmente, a imagem redimensionada e tratada é enviada para o modelo de identificação de faces.

C. Identificação da Face do Condutor

A busca pela face é feita em toda a imagem para identificar a área que corresponde ao rosto do motorista. É usado o método de detecção do OpenCV [25] que se baseia no conceito de aplicar detectores em uma janela deslizante que percorre toda a imagem. A identificação da face é um processo discreto, que é efetuado em cada quadro do vídeo, e resulta em uma área retangular circundante ao rosto.

D. Extração da Área dos Olhos

A detecção de olhos abertos e fechados é um procedimento que exige uma janela de buscas com tamanho muito pequeno (na faixa de 20x20 *pixels*), visto que os olhos se encontram em uma resolução pequena dentro da área da face. Por esse motivo, o número de operações de busca deve ser relativamente alto, o que reduz substancialmente o valor de quadros por segundo da aplicação [16], [26], [27]. Para reduzir o número de operações de busca, nós propomos a redução da área de interesse da face em uma área próxima aos olhos. Esse procedimento redimensiona a área retangular da face em uma área retangular próxima dos olhos por meio das seguintes equações

$$Eyes_y = Face_y + \frac{Face_H}{5,2}, \quad (1)$$

$$Eyes_x = Face_x + \frac{Face_W}{8}, \quad (2)$$

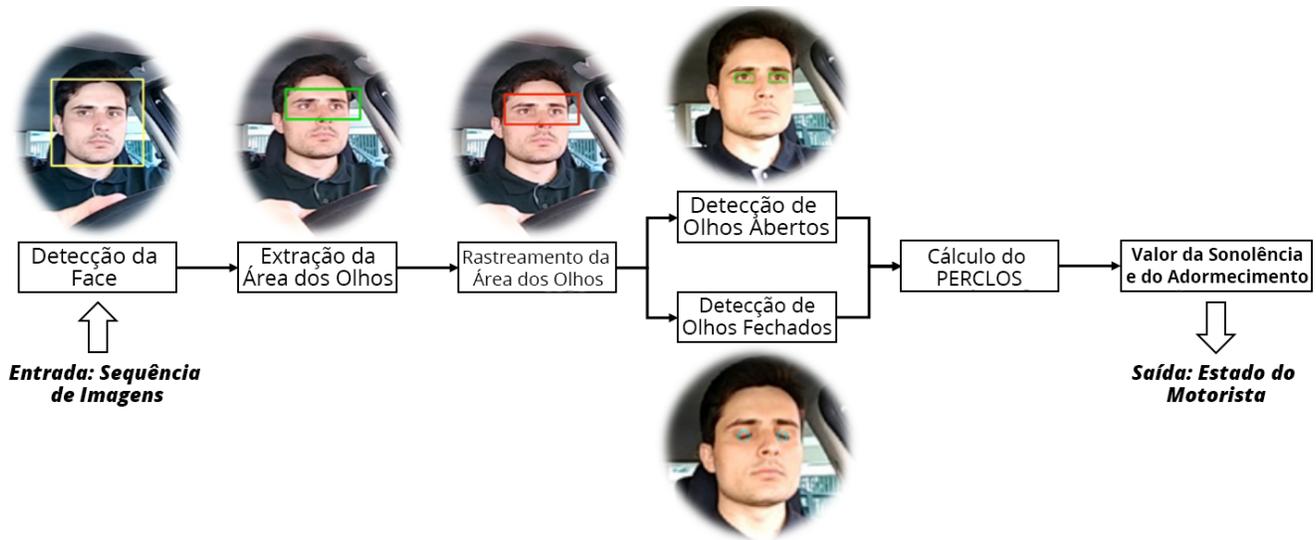


Fig. 1. Estrutura do sistema proposto.

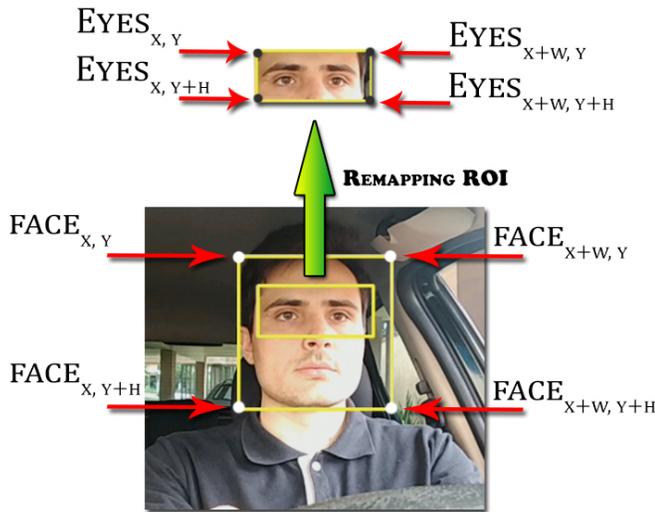


Fig. 2. Extração e mapeamento da região de interesse ao redor dos olhos.

$$Eyes_H = \frac{Face_H}{3}, \quad (3)$$

$$Eyes_W = \frac{Face_W}{1,32}, \quad (4)$$

onde $Eyes_x$ e $Eyes_y$ são os pontos iniciais nas coordenadas x e y , respectivamente, e $Eyes_W$ e $Eyes_H$ são a largura e a altura da área dos olhos. As constantes nas divisões são determinadas conforme a área resultante, a qual deve selecionar corretamente a região dos olhos. O resultado dessa operação é ilustrado na Figura 2, onde a área grande é a face identificada e a área pequena é a região dos olhos resultante das equações 1-4.

E. Rastreamento da Área dos Olhos

Em situações normais de condução, existem muitos fatores que impactam negativamente no processo de identificação da

face, como o excesso ou a falta de iluminação e a movimentação da cabeça do motorista. Nos eventos em que a face não é identificada, a extração da região de interesse e a classificação do estado dos olhos não é possível. Uma vez que a posição do rosto não muda abruptamente em quadros consecutivos [28], é possível estimar a região de interesse. É proposto um modelo de predição da região dos olhos baseado no filtro de Kalman linear [29] para estimar a movimentação da área dos olhos mesmo quando a face do motorista se encontra oculta. Dessa forma, as situações de oclusão são superadas e é possível classificar os estados dos olhos mesmo que parte da face esteja oculta.

1) *Definição do Estágio de Predição:* assim como em [28] e em [30], o modelo do sistema de predição é dado por

$$x_{k+1} = Ax_k + w_k, \quad (5)$$

onde A é a matriz de transição dos estados, w_k é o ruído de processo que é assumido como ruído gaussiano branco aditivo e x_k é o vetor de estado, composto pelos pontos do vértice do retângulo da área de interesse e pelas velocidades no eixo x e y e descrito por

$$x_k = [x_{1,k}, y_{1,k}, x_{2,k}, y_{2,k}, \dot{x}_k, \dot{y}_k]^T, \quad (6)$$

onde $x_{1,k}$ e $y_{1,k}$ formam o ponto inicial da região de interesse, o que é ilustrado na Fig. 2 como $Eyes_{x,y}$. Os parâmetros $x_{2,k}$ e $y_{2,k}$ representam o ponto final $Eyes_{x+w,y+h}$, enquanto \dot{x}_k e \dot{y}_k representam as velocidades de movimentação da área de interesse no eixo x e y , em um quadro k . O vetor de medição z_k é estabelecido como

$$z_k = [x_{1,k}, y_{1,k}, x_{2,k}, y_{2,k}]^T. \quad (7)$$

A etapa de predição começa na estimação dos estados segundo o modelo adotado pela matriz de transição de estados e na obtenção das medições dos pontos da região de interesse como

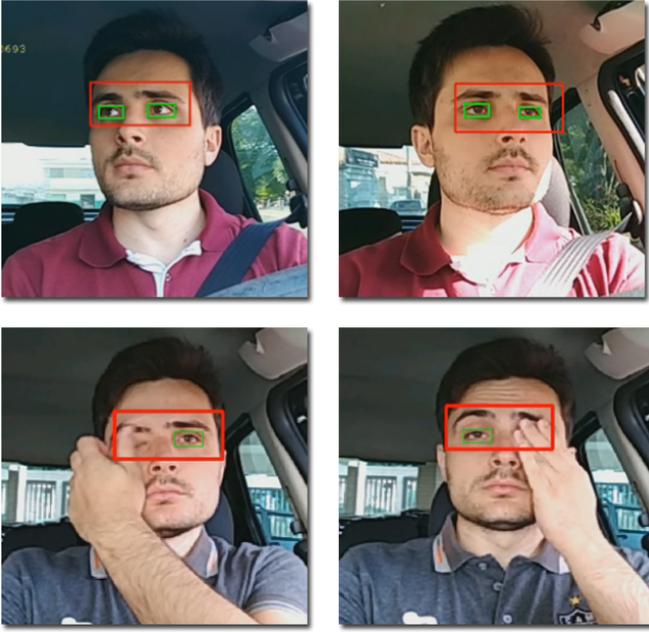


Fig. 3. Exemplos de falhas na detecção da face e operação do modelo de estimação para o rastreamento da área dos olhos.

$$\hat{x}_{k+1|k} = A\hat{x}_{k|k}, \quad (8)$$

$$\hat{z}_{k+1|k} = H\hat{x}_{k|k}, \quad (9)$$

2) *Definição do Estágio de Correção*: o estágio de correção é iniciado com o cálculo do ganho de Kalman, que é usado para ponderar entre os estados previstos e os estados medidos.

$$K_{k+1} = P_{k+1|k}H^T(HP_{k+1|k}H^T + R)^{-1}. \quad (10)$$

A matriz de ruído de medição \tilde{Y} analisa o resíduo entre a medição e a estimação como

$$\tilde{Y}_{k+1} = Z_{k+1} - H\hat{X}_{k+1|k}. \quad (11)$$

A segunda etapa do estágio de estimação consiste na atualização da matriz de estados estimada

$$\hat{X}_{k+1|k+1} = \hat{X}_{k+1|k} + K_{k+1}\tilde{Y}_{k+1}. \quad (12)$$

Por fim, a matriz de covariância P é atualizada como

$$P_{k+1|k+1} = (I - K_{k+1}H)P_{k+1|k}. \quad (13)$$

A Fig. 3 apresenta situações em que o detector de face falha e a área dos olhos é estimada segundo o modelo proposto. As falhas podem acontecer devido à iluminação excessiva, oclusão da face, posicionamento da face com angulação lateral, entre outros. Nessas situações, o detector de olhos opera exclusivamente na área rastreada.

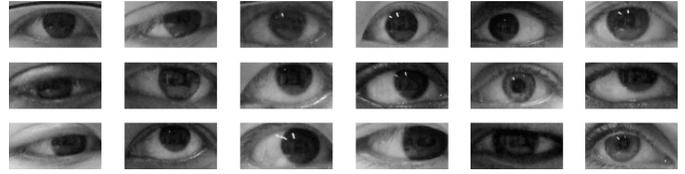


Fig. 4. Imagens usadas para o treinamento do detector de olhos abertos.

F. Identificação de Olhos Abertos

Este trabalho propõe o treinamento específico de detectores baseados em descritores de textura do tipo *local binary pattern* (LBP) [31].

Dois identificadores são aplicados na região rastreada: um de olhos abertos e semiabertos e outro de olhos fechados. Para identificar olhos abertos e semiabertos, nós treinamos um detector com amostras específicas para esse propósito. Ao todo, o conjunto de dados criado contém 5330 imagens de olhos abertos, o que correspondem às amostras positivas e estão ilustradas na Fig. 4. Os olhos são extraídos de imagens provenientes dos conjuntos de dados de [32] e de [33], em posições frontais ou com pequenos graus de angulação, sendo que a resolução de todas as amostras é de 100×50 pixels. A Fig. 4 apresenta uma pequena parte do conjunto de dados. As imagens negativas contêm elementos presentes no cenário de busca que não devem ser classificados como positivos. São usadas 6000 imagens de elementos da face como boca, nariz, queixo, sobrancelha, bochecha, testa e, principalmente, olhos fechados. O treinamento proposto é feito pelo classificador *Gentle Adaboost* com os descritores do tipo LBP, que é caracterizado pela pequena complexidade computacional [34], [35] e é eficaz em identificações com baixa luminosidade [36]. O treinamento é realizado para identificar amostras mínimas de 20×10 pixels em um número total de 8 estágios. Assim como é feito na detecção da face, a janela de busca onde os detectores de olhos abertos são aplicados é limitada inferiormente e superiormente para diminuir a quantidade de operações por parte do algoritmo e elevar a performance do aplicativo.

G. Identificação de Olhos Fechados

O procedimento de identificação dos olhos fechados é semelhante à identificação dos olhos abertos. No total, 918 figuras de olhos fechados, com qualidade adequada, foram adquiridas. As amostras passaram pela operação de ajuste do gamma, que consiste na alteração do brilho original da imagem. O gamma foi ajustado em 0,7 e em 1,1, visto que as imagens originais possuem níveis de brilho elevado. Essa operação, representada pela Fig. 5, tem como objetivo aumentar a generalização do sistema de classificação dos olhos fechados, uma vez que a iluminação natural da imagem varia segundo a posição da câmera e o horário do dia. O conjunto de dados com imagens positivas originais e ajustadas totaliza 2754 amostras, onde uma pequena amostra é ilustrada na Fig. 6. 5330 imagens negativas extraídas de [32], [33], [37] representam imagens de elementos da face, como nariz, boca, queixo, sobrancelha e olhos abertos. As imagens no formato .jpg com resolução de 80×40 pixels são enviadas para o



Fig. 5. Correção do gamma para a variação de luminosidade das amostras de olhos fechados.



Fig. 6. Imagens usadas para o treinamento do detector de olhos fechados.

modelo de classificação baseado no algoritmo *Gentle Adaboost* e são treinadas com descritores visuais LBP.

H. Estimação da Sonolência e do Adormecimento

O indicador PERCLOS [4] é definido como a porcentagem de fechamento da pálpebra sobre a pupila ao longo de um período específico. De forma prática, o PERCLOS calcula a proporção de tempo em que a pálpebra cobre pelo menos 80% da pupila [2], [4] e nota-se que esse valor é superior em indivíduos sonolentos [38]. Esse parâmetro é considerado um dos métodos visuais não-invasivos mais efetivos na estimação de sonolência [39], [15].

Embora existam métodos contínuos para a estimação do PERCLOS [2], [40] que trabalham com a geometria dos olhos, a análise discreta em função da detecção da ocorrência de olhos abertos e fechados é amplamente usada [17], [41], [42] por conta de sua simplicidade e precisão. Nos métodos discretos, a proporção de tempo em que os olhos se encontram fechados em um período específico é calculada por meio da média da ocorrência de olhos fechados sobre a ocorrência total de olhos nesse período como

$$PERCLOS_j = \frac{1}{n} \frac{\sum_{i=1}^n closed_{eye}}{\sum_{i=1}^n closed_{eye} + \sum_{i=1}^n open_{eye}}, \quad (14)$$

onde $closed_{eye}$ e $open_{eye}$ representam a ocorrência de olhos fechados e olhos abertos, respectivamente, em um quadro i dentro de um intervalo n . O grau de sonolência está diretamente relacionado ao valor do PERCLOS [38], uma vez que indivíduos sonolentos apresentam lentidão na abertura e fechamento dos olhos durante as piscadas, o que resulta no aumento do período em que os olhos ficam fechados [42]. Com isso, espera-se que a ocorrência de olhos fechados em condutores sonolentos seja superior à ocorrência de olhos fechados em motoristas vigilantes.

O sistema proposto é separado em duas fases. Na primeira fase, é feita a avaliação da sonolência em um período de tempo longo, de aproximadamente 60 segundos. A segunda fase é proposta para avaliar o adormecimento repentino, evento em



Fig. 7. Estrutura do sistema de monitoramento da sonolência do condutor. O smartphone é fixado com a parte frontal virada para o motorista por meio de um suporte preso ao para brisa.

que o condutor ignora os alertas de sonolência e continua dirigindo até adormecer e perder todos os sentidos relacionados à condução segura. Esta fase é avaliada em um curto intervalo de tempo, aproximadamente a cada 2 segundos.

IV. EXPERIMENTOS E RESULTADOS

A. Descrição do Sistema

O sistema de monitoramento da sonolência e do adormecimento consiste, basicamente, de um smartphone com um suporte de alocação ao para-brisa do veículo, ilustrados na Fig. 7. A versão mínima do Android compatível com a aplicação é a 4.1.x, a qual possui uma API com valor 16. Neste trabalho, especificamente, é usado o telefone Motorola Z-Play, que conta com processador Cortex-A53 octa-core 2,0 Giga-hertz, memória RAM de 3 Gigabytes, câmera frontal de 5 Megapixels com resolução máxima de 1920x1080 *pixels* e taxa de quadros por segundo máxima de 30, uma unidade de processamento gráfico Adreno 506 e uma bateria de 3300 mAh. Todos os testes são operados no sistema operacional Android 7.1.1 (Nougat). A aplicação apresenta consumo médio de 26% do processador e de 48 MB de memória. O consumo de carga elétrica da bateria com a aplicação em operação é de, aproximadamente, 550mAh, com o brilho em 30% e as opções de *wi-fi* e de internet móveis ligadas. Sendo assim, a autonomia da aplicação é de até 6 horas em smartphones com capacidade de bateria elevada. A taxa de quadros por segundo média obtida após os procedimentos de melhoria da performance é de 23,412 *frames* por segundo, ou seja, o algoritmo adquire e processa os quadros, em média, a cada 42,71 milissegundos, o que é muito aceitável para a estimação do PERCLOS [28].

B. Experimentos para Melhoria da Performance

Neste trabalho, nós focamos essencialmente na redução de operações que os procedimentos de detecção da face e dos olhos realizam. É feito um experimento para avaliar a melhora

TABELA I
PERFORMANCE DOS MÉTODOS SEGUNDO AS LIMITAÇÕES DA JANELA DE BUSCA

Limitação Inferior	Limitação Superior	Quadros por segundo
30x30	Nenhuma	15,427 ± 0,412
100x100	140x140	29,789 ± 0,527

de desempenho na limitação da área inferior e superior da janela de buscas da face. Ao aplicar esse método, faces são identificadas somente em um intervalo de *pixels*, mas efetuam um número inferior de operações. O experimento proposto realiza buscas por faces em duas situações: com e sem limitação da janela de buscas. São feitas análises de 20 segundos de vídeo gravados com resolução de 640x480 *pixels*, onde são analisados o número de quadros por segundo para avaliar o desempenho por meio da média e do desvio padrão dos quadros por segundo apresentados em cada uma das situações. Na primeira, é efetuada a busca pela face do condutor com limitação inferior padrão de 30x30 *pixels*, ilustrada pela parte superior da Fig. 8. Na segunda situação, proposta neste trabalho, é aplicada a limitação inferior de 100x100 e a superior de 140x140 *pixels*, na qual permite-se identificar faces em 50 à 100 centímetros da câmera, distância suficiente para monitorar o motorista com o smartphone alocado em um suporte no painel ou no para-brisa do veículo. O resultado visual da limitação está ilustrado na porção inferior da Fig. 8. A implementação desse procedimento aumenta o valor de quadros por segundo da aplicação, os quais são apresentados na Tabela I.

Os resultados apontam que o valor médio da performance do procedimento de limitação da janela de busca é 93,09% superior ao mesmo parâmetro do método com a limitação padrão inferior de 30x30 *pixels*. A importância do número elevado de quadros por segundo está ligado diretamente à taxa de amostragem em que os olhos são buscados na imagem. Uma vez que as piscadas duram poucas centenas de milissegundos, é desejável receber imagens com um período de amostragem pequeno para que as ocorrências de olhos fechados sejam perfeitamente capturadas. Em média, a aplicação deste método reduz o período de amostragem de 64,82 para 33,56 milissegundos, se tornando essencial para que o processamento seja direcionado aos detectores de olhos.

Em complementação ao método de limitação do tamanho da janela de busca da face, é extraída a área dos olhos para diminuir a quantidade de operações que o algoritmo de detecção dos olhos efetua. O procedimento proposto neste trabalho é avaliado por meio de um experimento onde os detectores de face, de olhos abertos e de olhos fechados são aplicados. Esse experimento é dividido em duas fases. Na primeira fase, os detectores de olhos são aplicados na área total da face e a performance da aplicação é avaliada por meio do valor da média e do desvio padrão dos quadros por segundos apresentados. Na segunda fase, o mesmo procedimento é aplicado na região extraída dos olhos, onde a porção inferior e superior da face são descartadas. A análise é praticada em 34 segundos de vídeo para cada fase e os resultados são apresentados na Tabela II.

TABELA II
PERFORMANCE DA APLICAÇÃO SEGUNDO A ROI

Área de Busca	Quadros por Segundo
Face	20,792 ± 0,433
Olhos	23,412 ± 0,345

TABELA III
INDIVÍDUOS PARTICIPANTES DOS EXPERIMENTOS

Sujeito	Idade	Gênero	Cor dos Olhos
A	24	Mulher	Azul Claro
B	48	Mulher	Azul
C	26	Mulher	Castanho
D	21	Homem	Castanho claro

É notável a diminuição do valor de quadros por segundo com os três detectores de olhos em operação. A aplicação dos detectores de olhos na área da face reduz a performance do sistema em aproximadamente 30%, quando comparada somente com a busca pela face. Com esse FPS, o período de aquisição de imagens se expande para 48 milissegundos. Com a diminuição da área da face em 74,25%, a aplicação dos detectores na região dos olhos proporciona melhoria na performance de 12,60%, o que resulta em um período de aquisição de 42 milissegundos. Esse valor é o resultado dos dois métodos propostos para a diminuição do número de operações que o algoritmo de busca realiza: limitação da janela de busca da face e extração da região dos olhos. Em comparação com [28], que obteve 9,5 de fps usando um sistema de processamento completamente dedicado, nossa aplicação possui performance 246,44% superior.

É importante salientar que a aplicação não consegue funcionar com a resolução de 640x480 *pixels* sem esses procedimentos, uma vez que o tempo de processamento se torna demasiadamente elevado.

C. Experimentos para a Avaliação dos Detectores de Olhos

A avaliação da performance dos detectores de olhos do nosso sistema é feita por experimentos com 4 indivíduos, os quais possuem idades diferentes e são compostos por três mulheres e um homem. As descrições dos indivíduos são ilustradas na Tabela III. A importância de analisar diferentes cores de olhos está no fato de que a iluminação do sol causa sensibilidade em olhos mais claros. Com isso, indivíduos com olhos claros tendem a fechar parte da pálpebra continuamente para sofrerem menos com os efeitos, o que pode influenciar no processo de classificação do estado dos olhos. Os experimentos são baseados na análise dos seguintes parâmetros: verdadeiro-positivo (TP), falso-positivo (FP), falso-negativo (FN) e verdadeiro-negativo (TN), os quais são usados para o cálculo da precisão, revocação, *F-measure* e acurácia. A realização dos experimentos é feita em um período diurno, entre 13:00 e 13:30, em um ambiente ensolarado, uma vez que é desejável registrar os efeitos da iluminação excessiva na contração das pálpebras. A descrição específica dos experimentos é feita nas subseções a seguir.

1) *Avaliação do Detector de Olhos Abertos*: a avaliação do detector de olho aberto e semi-aberto é feita em uma sequência

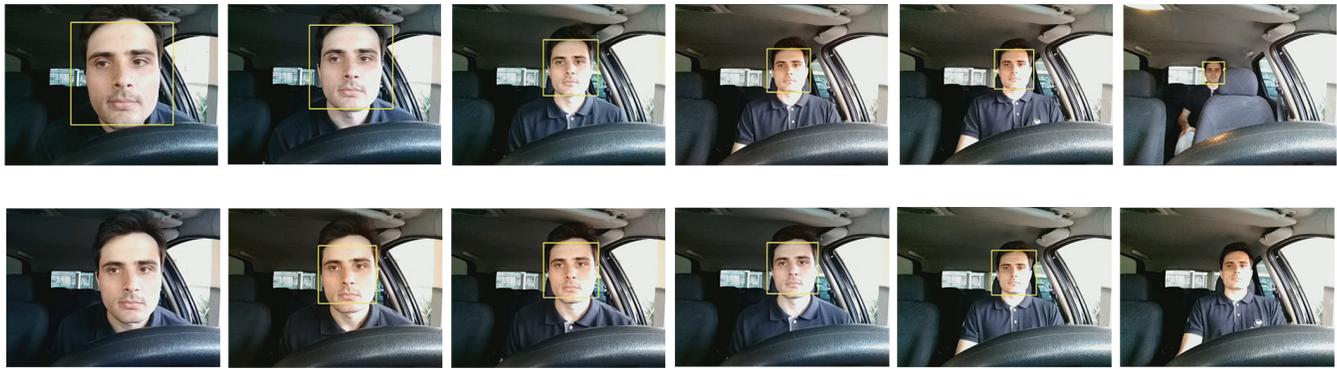


Fig. 8. Identificação da face com limitação inferior da janela de buscas de 30x30 pixels (cima). O mesmo procedimento é realizado com limitações entre 100x100 e 140x140 pixels (baixo).

TABELA IV
RESULTADOS DA DETECÇÃO DE OLHOS ABERTOS

Sujeito	TP	TN	FP	FN
A	409	31	0	60
B	433	20	0	47
C	470	20	0	10
D	474	15	0	11

TABELA V
PERFORMANCE DO DETECTOR DE OLHOS ABERTOS

Sujeito	Precisão	Revocação	F – Measure	Acurácia
A	100,00	87,21	93,16	88,00
B	100,00	90,21	94,85	90,60
C	100,00	97,92	98,95	98,00
D	100,00	97,73	98,85	97,80

de 500 quadros consecutivos de cada indivíduo participante do teste. É pedido para que os indivíduos tenham orientação voltada para a pista em um ambiente onde o veículo se encontra parado por conta da segurança. A Tabela IV apresenta os resultados de detecção por meio da análise dos 500 quadros.

É notável um acréscimo no número de falsos negativos dos indivíduos A e B. Isso acontece por conta da contração dos músculos dos olhos em razão da alta luminosidade solar. Indivíduos com olhos claros possuem dificuldade em permanecer com os olhos amplamente abertos nesse tipo de ambiente. Com isso, é visto que o detector tem dificuldade para classificar corretamente os olhos semi-abertos de sujeitos com sensibilidade. Por outro lado, o número de falsos positivos é apresentado como nulo em todo o experimento, sendo isso justificado pelo treinamento preciso dos detectores, sobretudo para o aspecto negativo do treinamento. Os resultados da avaliação quantitativa são ilustrados na Tabela V.

A precisão perfeita em todos os indivíduos é justificada pela ausência de classificações com falsos positivos. Essa é uma consequência do uso de imagens de elementos do rosto no treinamento negativo do detector, como testa, sobrancelha e olhos fechados.

2) *Avaliação do Detector de Olhos Fechados*: a avaliação do detector de olho fechado é feita em 100 quadros para cada indivíduo da Tabela III. É gravado um vídeo com a aplicação operando com o detector de olho fechado, onde são



Fig. 9. Detecção de olhos abertos (representados pelos retângulos verdes) em quadros consecutivos dos indivíduos B e D.

TABELA VI
RESULTADOS DA DETECÇÃO DE OLHOS FECHADOS

Sujeito	TP	TN	FP	FN
A	62	22	3	13
B	50	15	0	35
C	47	32	0	21
D	60	15	0	25



Fig. 10. Exemplo de fechamento incompleto dos olhos durante uma piscada do indivíduo C.

TABELA VII
PERFORMANCE DO DETECTOR DE OLHOS FECHADOS

Sujeito	Precisão	Revocação	F – Measure	Acurácia
A	95,38	82,67	88,57	84,00
B	100,00	58,82	74,07	65,00
C	100,00	69,12	64,00	79,00
D	100,00	70,59	82,76	75,00

analisadas as ocorrências dos parâmetros de qualidade para a construção do resultado quantitativo. Os resultados de detecção são apresentados na Tabela VII.

O detector de olhos fechados apresenta um número elevado de classificações falsamente negativas, pois os indivíduos possuem dificuldade para fechar os olhos completamente durante as piscadas em ambientes iluminados, o que é ilustrado pela Fig. 10. Os resultados da avaliação quantitativa são exibidos na Tabela VII.

D. Experimentos na Medição do PERCLOS

Para avaliar o indicador PERCLOS e suas alterações em condutores sonolentos, nós propomos um experimento em que

é pedido para o condutor simular uma situação de condução em dois estados diferentes: vigilante e sonolento. Em um primeiro momento são extraídas 10 amostras, as quais possuem 1 minuto cada, de PERCLOS de um condutor vigilante, que se encontra acordado há duas horas após ter dormido por sete horas. Cada amostra consiste de um minuto de vídeo, totalizando dez minutos de análise. A segunda avaliação é composta por um condutor que se encontra acordado há 18 horas. Os resultados são apresentados na Fig. 11.

Os resultados apontam que o PERCLOS do indivíduo sonolento é maior ao do indivíduo vigilante em todas as amostras. Essa discrepância é justificada pela velocidade da pálpebra durante as piscadas. Na simulação do condutor vigilante, é notado que os olhos fechados são identificados em 2 ou 3 quadros no decorrer de cada piscada. Por outro lado, a simulação do condutor sonolento aponta que a aplicação identifica 5 ou 6 quadros de olhos fechados em sequência. Por esse motivo, a média do PERCLOS de um condutor sonolento é 209,78% superior a de um vigilante.

1) *Modelo de Estimação de Sonolência*: o modelo de estimação da sonolência tem como base os resultados do experimento do PERCLOS, ilustrados na Fig. 11. É tomada a média do PERCLOS das amostras em que o indivíduo se encontra sonolento e este valor é definido como o limiar entre o estado de vigiância e o estado de sonolência. A Equação 15 apresenta o modelo proposto.

$$Alerta = \begin{cases} 1, & \text{se } PERCLOS > 0.0493, \\ 0, & \text{senão.} \end{cases} \quad (15)$$

A cada intervalo de 1 minuto é feita a avaliação do PERCLOS no modelo de sonolência. Se o condutor apresentar o nível de PERCLOS superior ao limiar, é enviado um comando para acionar o alerta sonoro por meio do alto falante do smartphone. Esse alerta possui intensidade moderada e exerce a função de orientar o condutor para estacionar o veículo em um local seguro para descansar.

2) *Modelo de Estimação de Adormecimento*: é proposto um modelo de estimação de adormecimento que tem como objetivo monitorar o condutor em intervalos pequenos de tempo para identificar episódios de adormecimento. O modelo idealizado, apresentado na Equação 16, recorre aos valores altos de PERCLOS para identificar o sintoma de fechamento contínuo dos olhos. Nos episódios em que o condutor permanece com seus olhos fechados por um período superior a 80% do intervalo de 1.5 segundo, é emitido um alerta sonoro de alta intensidade que permanece acionado enquanto o motorista continuar com os olhos fechados.

$$Alerta = \begin{cases} 2, & \text{se } PERCLOS > 0.8, \\ 0, & \text{senão.} \end{cases} \quad (16)$$

Um experimento é idealizado para avaliar o período de emissão do alerta sonoro. São simuladas 10 situações de adormecimento das quais é extraído o tempo entre a primeira ocorrência de olhos fechados e o momento em que o alerta sonoro é emitido. Esse experimento é esboçado na Fig. 12. O alerta de adormecimento é efetuado em todas as amostras analisadas, com um tempo médio de, aproximadamente, 2

segundos. Esse alerta sonoro, de alta intensidade, é mantido enquanto o sistema continua a identificar a sonolência do motorista.

V. CONCLUSÃO

Neste trabalho, nós apresentamos um sistema de monitoramento da sonolência e do adormecimento do condutor por meio de uma aplicação que opera usando os recursos dos smartphones. Nossa abordagem inicia na identificação da face com aplicação de limitações no tamanho da janela de buscas para melhorar a performance. Em seguida, a região de interesse é reduzida para a área dos olhos e é rastreada para gerenciar situações de oclusão. A classificação dos estados dos olhos opera na área rastreada para a medição do indicador PERCLOS, que é usado para prever o estado de atenção do motorista, isto é, vigilante, sonolento ou adormecido.

Resultados experimentais mostram que o nosso método de avaliação do condutor baseado no parâmetro PERCLOS é capaz de diferenciar o estado de vigiância do estado de sonolência, o que só é possível graças aos métodos de melhoria da performance que geram um acréscimo considerável de quadros por segundo. Por ser uma aplicação que opera em smartphones, não é necessário a instalação de nenhum componente dedicado no veículo, uma vez que todos os recursos usados são do aparelho. Além disso, por conta da popularidade dos smartphones e pela facilidade de se instalar um aplicativo, nossa aplicação pode atingir um público alvo de diversas camadas sócio-econômicas e em diferentes regiões do planeta.

Nos próximos trabalhos, nós pesquisaremos métodos de ajuste de iluminação em ambientes claros e escuros, com o intuito de melhorar as performances das detecções nesses locais. Outro ponto a ser trabalhado é a integração de informações do veículo, como a velocidade instantânea, para evitar que alertas desnecessários sejam emitidos.

REFERÊNCIAS

- [1] I. A. Akbar, A. M. Rumagit, M. Utsunomiya, T. Morie, and T. Igasaki, "Three drowsiness categories assessment by electroencephalogram in driving simulator environment," in *Engineering in Medicine and Biology Society (EMBC), 2017 39th Annual International Conference of the IEEE*. IEEE, 2017, pp. 2904–2907.
- [2] B. Mandal, L. Li, G. S. Wang, and J. Lin, "Towards detection of bus driver fatigue based on robust visual analysis of eye state," *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, no. 3, pp. 545–557, 2017.
- [3] S. Matuska, R. Hudec, and M. Benco, "The comparison of cpu time consumption for image processing algorithm in matlab and opencv," in *2012 ELEKTRO*. IEEE, 2012, pp. 75–78.
- [4] D. F. Dinges and R. Grace, "Perclous: A valid psychophysiological measure of alertness as assessed by psychomotor vigilance," *US Department of Transportation, Federal Highway Administration, Publication Number FHWA-MCRT-98-006*, 1998.
- [5] K. M. Tabal and J. D. Cruz, "Development of low-cost embedded-based electrooculogram blink pulse classifier for drowsiness detection system," in *Signal Processing & its Applications (CSPA), 2017 IEEE 13th International Colloquium on*. IEEE, 2017, pp. 29–34.
- [6] Z. Piotrowski and M. Szypulska, "Classification of falling asleep states using hrv analysis," *Biocybernetics and Biomedical Engineering*, 2017.
- [7] N. R. Pal, C. Y. Chuang, L. W. Ko, C. F. Chao, T. P. Jung, S. F. Liang, and C. T. Lin, "Eeg-based subject-and session-independent drowsiness detection: an unsupervised approach," *EURASIP Journal on Advances in Signal Processing*, vol. 2008, p. 192, 2008.
- [8] S. Makeig, A. J. Bell, T.-P. Jung, and T. J. Sejnowski, "Independent component analysis of electroencephalographic data," in *Advances in neural information processing systems*, 1996, pp. 145–151.

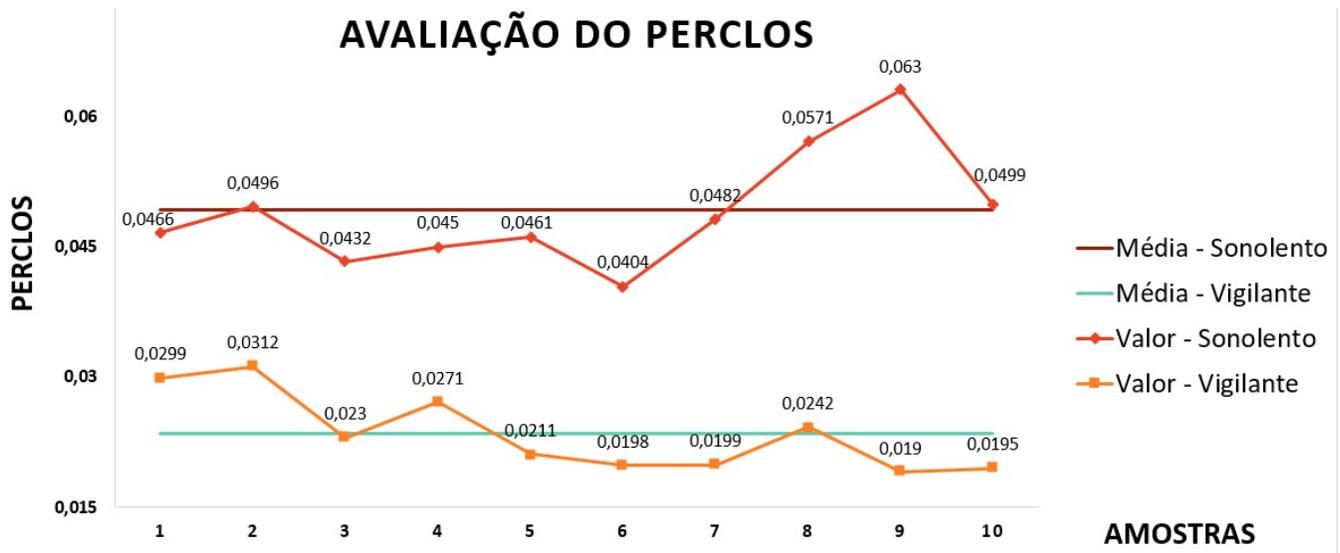


Fig. 11. Resultado do experimento de avaliação do PERCLOS com o indivíduo vigilante e sonolento.

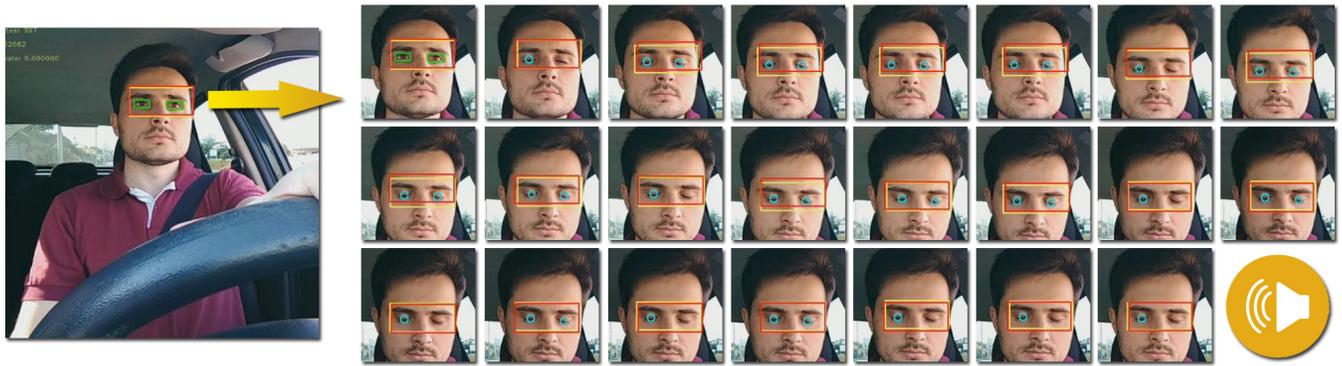


Fig. 12. Ilustração de uma simulação de adormecimento na qual os quadros são apresentados em sequência. A identificação dos olhos fechados eleva o valor do PERCLOS e faz com que o alerta sonoro seja ativado. Treze quadros intermediários dessa sequência foram ocultados para otimizar o espaço da figura.

[9] T.-P. Jung, S. Makeig, M. Stensmo, and T. J. Sejnowski, "Estimating alertness from the eeg power spectrum," *IEEE transactions on biomedical engineering*, vol. 44, no. 1, pp. 60–69, 1997.

[10] X. Wang and C. Xu, "Driver drowsiness detection based on non-intrusive metrics considering individual specifics," *Accident Analysis & Prevention*, vol. 95, pp. 350–357, 2016.

[11] E. De Valck and R. Cluydts, "Slow-release caffeine as a countermeasure to driver sleepiness induced by partial sleep deprivation," *Journal of sleep research*, vol. 10, no. 3, pp. 203–209, 2001.

[12] J. Wang, S. Zhu, and Y. Gong, "Driving safety monitoring using semisupervised learning on time series data," *IEEE Transactions on Intelligent Transportation Systems*, vol. 11, no. 3, pp. 728–737, 2010.

[13] P. Philip, P. Sagaspe, N. Moore, J. Taillard, A. Charles, C. Guilleminault, and B. Bioulac, "Fatigue, sleep restriction and driving performance," *Accident Analysis & Prevention*, vol. 37, no. 3, pp. 473–478, 2005.

[14] Y. Liang, M. L. Reyes, and J. D. Lee, "Real-time detection of driver cognitive distraction using support vector machines," *IEEE transactions on intelligent transportation systems*, vol. 8, no. 2, pp. 340–350, 2007.

[15] A. Sahayadhas, K. Sundaraj, and M. Murugappan, "Detecting driver drowsiness based on sensors: a review," *Sensors*, vol. 12, no. 12, pp. 16 937–16 953, 2012.

[16] B. Reddy, Y.-H. Kim, S. Yun, C. Seo, and J. Jang, "Real-time driver drowsiness detection for embedded system using model compression of deep neural networks," in *Computer Vision and Pattern Recognition Workshops (CVPRW), 2017 IEEE Conference on*. IEEE, 2017, pp. 438–445.

[17] J. J. Yan, H. H. Kuo, Y. F. Lin, and T. L. Liao, "Real-time driver drowsiness detection system based on perclos and grayscale image processing," in *Computer, Consumer and Control (IS3C), 2016 International Symposium on*. IEEE, 2016, pp. 243–246.

[18] D. H. Gong and K. C. Kwak, "Face detection and status analysis algorithms in day and night environments," in *Advanced Informatics, Concepts, Theory, and Applications (ICAICTA), 2017 International Conference on*. IEEE, 2017, pp. 1–4.

[19] R. I. Hammoud, G. Witt, R. Dufour, A. Wilhelm, and T. Newman, "On driver eye closure recognition for commercial vehicles," *SAE International Journal of Commercial Vehicles*, vol. 1, no. 2008-01-2691, pp. 454–463, 2008.

[20] D. S. Bowman, W. A. Schaudt, and R. J. Hanowski, "Advances in drowsy driver assistance systems through data fusion," in *Handbook of intelligent vehicles*. Springer, 2012, pp. 895–912.

[21] E. E. Galarza, F. D. Egas, F. M. Silva, P. M. Velasco, and E. D. Galarza, "Real time driver drowsiness detection based on driver's face image behavior using a system of human computer interaction implemented in a smartphone," in *International Conference on Information Theoretic Security*. Springer, 2018, pp. 563–572.

[22] J. Xu, J. Min, and J. Hu, "Real-time eye tracking for the assessment of driver fatigue," *Healthcare technology letters*, vol. 5, no. 2, pp. 54–58, 2018.

[23] B.-G. Lee and W.-Y. Chung, "A smartphone-based driver safety monitoring system using data fusion," *Sensors*, vol. 12, no. 12, pp. 17 536–17 552, 2012.

[24] R. E. Kalman, "A new approach to linear filtering and prediction problems," *Journal of basic Engineering*, vol. 82, no. 1, pp. 35–45, 1960.

[25] OpenCV, "Open source computer vision," 2016. [Online]. Available:

<http://opencv.org/>

- [26] G. Mohammadi, J. Shanbehzadeh, and H. Sarrafzadeh, "A fast and adaptive video-based method for eye blink rate estimation," 2015.
- [27] N. Neshov and A. Manolova, "Drowsiness monitoring in real-time based on supervised descent method," in *Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS), 2017 9th IEEE International Conference on*, vol. 2. IEEE, 2017, pp. 660–663.
- [28] A. Dasgupta, A. George, S. Happy, A. Routray, and T. Shanker, "An on-board vision based system for drowsiness detection in automotive drivers," *International Journal of Advances in Engineering Sciences and Applied Mathematics*, vol. 5, no. 2-3, pp. 94–103, 2013.
- [29] Y. Chan, A. Hu, and J. Plant, "A kalman filter based tracking scheme with input estimation," *IEEE transactions on Aerospace and Electronic Systems*, no. 2, pp. 237–244, 1979.
- [30] R. Olivera, R. Olivera, O. Vite, H. Gamboa, M. A. Navarrete, and C. A. Rivera, "Application of the three state kalman filtering for moving vehicle tracking," *IEEE Latin America Transactions*, vol. 14, no. 5, pp. 2072–2076, 2016.
- [31] T. Ahonen, A. Hadid, and M. Pietikainen, "Face description with local binary patterns: Application to face recognition," *IEEE Transactions on Pattern Analysis & Machine Intelligence*, no. 12, pp. 2037–2041, 2006.
- [32] B. A. Smith, Q. Yin, S. K. Feiner, and S. K. Nayar, "Gaze locking: passive eye contact detection for human-object interaction," in *Proceedings of the 26th annual ACM symposium on User interface software and technology*. ACM, 2013, pp. 271–280.
- [33] E. Wood, T. Baltrusaitis, X. Zhang, Y. Sugano, P. Robinson, and A. Bulling, "Rendering of eyes for eye-shape registration and gaze estimation," in *Proc. of the IEEE International Conference on Computer Vision (ICCV 2015)*, 2015.
- [34] Y. Zhang and C. Hua, "Driver fatigue recognition based on facial expression analysis using local binary patterns," *Optik-International Journal for Light and Electron Optics*, vol. 126, no. 23, pp. 4501–4505, 2015.
- [35] Q. Wang, J. Liang, Z.-J. Hu, H.-H. Hu, H. Zhao, H.-Q. Hu, X. Gao, and H. Yang, "Spatial texture based automatic classification of dayside aurora in all-sky images," *Journal of Atmospheric and Solar-Terrestrial Physics*, vol. 72, no. 5-6, pp. 498–508, 2010.
- [36] C. Spampinato, S. Palazzo, and I. Kavasidis, "A texton-based kernel density estimation approach for background modeling under extreme conditions," *Computer Vision and Image Understanding*, vol. 122, pp. 74–83, 2014.
- [37] W. Gao, B. Cao, S. Shan, X. Chen, D. Zhou, X. Zhang, and D. Zhao, "The cas-peal large-scale chinese face database and baseline evaluations," *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, vol. 38, no. 1, pp. 149–161, 2008.
- [38] R. Grace and S. Steward, "Drowsy driver monitor and warning system," in *International driving symposium on human factors in driver assessment, training and vehicle design*, vol. 8, 2001, pp. 201–208.
- [39] J. F. May and C. L. Baldwin, "Driver fatigue: The importance of identifying causal factors of fatigue when considering detection and countermeasure technologies," *Transportation research part F: traffic psychology and behaviour*, vol. 12, no. 3, pp. 218–224, 2009.
- [40] J.-F. Xie, M. Xie, and W. Zhu, "Driver fatigue detection based on head gesture and perclos," in *Wavelet Active Media Technology and Information Processing (ICWAMTIP), 2012 International Conference on*. IEEE, 2012, pp. 128–131.
- [41] A. Acioğlu and E. Erçelebi, "Real time eye detection algorithm for perclos calculation," in *Signal Processing and Communication Application Conference (SIU), 2016 24th*. IEEE, 2016, pp. 1641–1644.
- [42] W. Kong, L. Zhou, Y. Wang, J. Zhang, J. Liu, and S. Gao, "A system of driving fatigue detection based on machine vision and its application on smart device," *Journal of Sensors*, vol. 2015, 2015.



Gabriel Cambraia Soares recebeu o título de bacharelado em Engenharia de Controle e Automação e mestre em Engenharia de Sistemas e Automação pela Universidade Federal de Lavras (UFLA), Lavras, Brasil, em 2016 e 2018. É membro do Laboratório de Mobilidade Terrestre (LMT), UFLA, desde 2016. Foi professor substituto no Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG) em 2017. Suas principais áreas de pesquisa envolvem visão computacional e sistemas embarcados.



Danilo Alves de Lima recebeu o título de bacharel em Engenharia de Controle e Automação e mestre em Engenharia Elétrica pela Universidade Federal de Minas Gerais (UFMG), Belo Horizonte, Brasil, em 2008 e 2010, e o título de doutor em Tecnologia de Sistemas e Informação pela Universidade de Compiègne (UTC), Compiègne, França, em 2015. Atualmente, é professor associado no Departamento de Engenharia da Universidade Federal de Lavras, Lavras, Brasil. É membro do Laboratório de Mobilidade Terrestre (LMT), UFLA, desde 2015. Também trabalhou com o Grupo de Pesquisa e Desenvolvimento de Veículos Autônomos (PDVA), UFMG. Suas principais áreas de pesquisa incluem visão computacional, navegação robótica e desenvolvimento de veículos inteligentes.



Arthur de Miranda Neto recebeu o título de bacharel em Ciência da Computação - processamento de dados - (1998), o título de mestre em Engenharia Mecânica (2007) pela Universidade de Campinas (UNICAMP), Campinas, Brasil, e o título de doutor em Tecnologia de Sistemas e Informação pela Universidade de Tecnologia de Compiègne (UTC), Compiègne, França, e em Engenharia Mecânica pela UNICAMP, Brasil. Foi analista de sistemas do Exército Brasileiro entre 1997 e 2005. Foi professor visitante na UNICAMP entre 2012 e 2014. Desde 2014, é Professor Associado no Departamento de Engenharia da Universidade Federal de Lavras (UFLA) e diretor do Laboratório de Mobilidade Terrestre (LMT). Suas principais áreas de pesquisa estão no campo de sistemas robóticos e mecatrônicos, precisamente na área de sistemas de direção autônomos.