

DISPOSITIVO MICROCONTROLADO DE DIREÇÃO ASSISTIDA EMBARCADO PARA AUXILIAR A REDUÇÃO DE ACIDENTES DE TRÂNSITO

Aluno: Denis Ferreira de Lima **Orientador:** Antônio Newton Licciardi Junior

Apoio: PIBIC CNPq

RESUMO

O desenvolvimento e a utilização de um dispositivo de monitoramento de fadiga e sonolência de motoristas é essencial, tendo em vista a alta incidência de acidentes causados por estas condições. O sono e a fadiga é a segunda maior causa de acidentes no Brasil, perdendo apenas para o álcool e drogas. Em situações de condução prolongada, a atenção diminui gradualmente, devido a fadiga ou sonolência, levando a um aumento de tempo de reação, e eventualmente a perda do controle do veículo. O desenvolvimento de um sistema embarcado, microcontrolado para direção assistida, utilizando de visão computacional, a fim de detectar e alertar o motorista de situações críticas, permite uma intervenção precoce e potencialmente salvar vidas. Para desenvolver este projeto, é necessário aplicar técnicas de visão computacional em linguagem Python, bibliotecas pré-treinadas como *OpenCV*, *MédiaPipe*, *dlib*, dedicado ao reconhecimento facial. Além disto, espera-se o uso de sensores embarcados em *Raspberry-PI4* e câmeras para monitorar em tempo real o estado do motorista. A detecção é baseada em métricas como a razão de aspecto do olho (*Eye Aspect Ratio* - EAR) e a razão de aspecto da boca (*Mouth Aspect Ratio* - MAR), que monitoram características faciais indicativas de sonolência, como o fechamento dos olhos ou bocejos frequentes. A partir destes padrões são implementados sensores de alerta ao motorista. Objetiva-se a simplicidade, baixo custo e a confiabilidade.

Palavras-chave: Microcontrolador de direção assistida e embarcada. Visão computacional. Acidentes de trânsito, *EAR*, *MAR*.

ABSTRACT

The development and use of a device to monitor driver fatigue and drowsiness is essential, given the high incidence of accidents caused by these conditions. Sleep and fatigue are the second leading cause of accidents in Brazil, second only to alcohol and drugs. In prolonged driving situations, attention gradually decreases due to fatigue or drowsiness, leading to an increase in reaction time and eventually loss of control of the vehicle. The

development of an embedded, microcontrolled system for assisted driving, using computer vision, in order to detect and alert the driver of critical situations, allows early intervention and potentially saves lives. To develop this project, it is necessary to apply computer vision techniques in Python language, pre-trained libraries such as OpenCV, MédiaPipe, dlib, dedicated to facial recognition. In addition, the use of embedded sensors in Raspberry-PI4 and cameras is expected to monitor the driver's condition in real time. Detection is based on metrics such as Eye Aspect Ratio (EAR) and Mouth Aspect Ratio (MAR), which monitor facial features indicative of drowsiness, such as eye closure or frequent yawning. These patterns are used to implement driver alert sensors. The goal is simplicity, low cost and reliability.

Keywords: Power steering and-board microcontroller. Computer Vision. Traffic accidents, EAR, MAR.

1. INTRODUÇÃO

Acidentes de trânsito são causados constantemente em todo o mundo (ALI, 2021). Desde os primórdios da construção e utilização de automóveis, os acidentes ocorrem e são alvos de pesquisas para que possam ser avaliados e evitados (R7, 2021), (TRÂNSITOIDEAL, 2021), (SOCIALBAURU, 2021). Segundo a Organização Mundial da Saúde (WHO, 2021), acidentes de trânsito são a oitava maior causa de mortes em 2020. Além disso, estes acidentes causam a morte de 1,35 milhões de pessoas por ano e entre 20 e 50 milhões sofrem lesões não fatais, porém resultam em incapacidade (OPAS, 2021).

Por mais diversas que possam ser as causas dos acidentes, eles podem ser relacionados e agrupados em três principais fatores: humano, veicular, ambiental (DO CARMO, 2021). Exemplos que se encaixam em fatores humanos são excessos de velocidade, dirigir sob efeitos de álcool, uso de aparelhos celulares na direção, não manter a distância adequada do veículo a frente e má sinalização. A manutenção regular do automóvel entra como fator veicular. Por último, como fatores ambientais, tem-se o estado de conservação e sinalização da via, falta de acostamentos e passarelas que são deveres do Estado e do governo (DOS SANTOS, 2021). Porém, ao analisar cada tópico, percebe-se que a prudência e responsabilidade do condutor podem prevenir acidentes de todos os fatores, pois um bom condutor mantém a manutenção de seu veículo em dia e dirige de forma cuidadosa e cautelar, independente da situação da via (ONSV, 2021).

De acordo com o ONSV, Observatório Nacional de Segurança Viária (2021), 90% (noventa por cento) dos acidentes fatais são causados por falhas humanas como desatenção




Coordenadoria de Fomento à Pesquisa – CFP 2024

do motorista e desrespeito às leis. Através destes dados é notório perceber, que para haver a redução de acidentes, precisa-se de uma mudança de atitude e ações dos condutores frente à condução de um veículo (DO NASCIMENTO, 2021).

A proposta de um sistema embarcado no veículo que seja capaz de monitorar, classificar e alertar motoristas sobre atitudes incorretas ou desatenções na direção de um automóvel, pode contribuir para a diminuição de parte dos acidentes de trânsito.

A imprudência e falta de atenção ao dirigir são as principais causas de acidentes de trânsito (ONSV, 2021). Observando o gráfico da figura 1, é possível compreender que o uso de celulares, sonolência, alta velocidade e ingestão de álcool são causas importantes de mortes no trânsito brasileiro. Contribuem para a sua ocorrência a falta de fiscalização que pode ser mitigada, através de radares ou lombadas eletrônicas (SANTOS, 2019). É essencial para a segurança do próprio condutor e de outras pessoas ao seu redor, a fiscalização do motorista, se possível num processo contínuo. Por conta deste aspecto, aparelhos que possam monitorar atitudes e a atenção dos condutores são importantes para suportar a redução da quantidade de acidentes.

Figura 1: Gráfico referente a mortes por causa de acidentes segundo dados do Polícia Rodoviária Federal



Fonte: (PRF, 2021)

Por conta dos índices de acidentes de trânsito derivados da sonolência e fadiga, dispositivos eletrônicos embarcados de suporte têm sido propostos e/ou desenvolvidos (PARANHOS, 2019). Como sistema embarcado que abrange outros tipos de sensores e

medições indiretas, pode-se citar o Volkswagen-Bosch (RATHER et al., 2021), que faz a detecção de sonolência do motorista. O sistema utiliza a análise do ângulo de esterçamento do volante e a pressão exercida nos pedais, comparando os dados obtidos no início e durante a viagem, informando quando necessário uma parada para descanso do motorista. A tecnologia é robusta, porém a capacidade de detecção é inferior a 90%.

Em recente revisão sistemática de dispositivos para evitar acidentes de trânsito (HAMDI, 2021), aponta-se que a melhor técnica não invasiva de sistemas de prevenção de acidentes é a de reconhecimento de imagens e monitoração de estados do motorista por sistema de câmeras no veículo. Da mesma forma, tais dispositivos apresentam como principal ponto de melhoria necessário, a confiabilidade de hardware, que requer revisões periódicas.

Considerando as informações apresentadas e a abordagem de sistemas embarcados, é relevante social e cientificamente o estudo e identificação de sistema ótimo possível de monitoração de estados do motorista e alertas, por técnicas de reconhecimento de imagem e de estados de risco. Por ótimo, pode-se entender que o sistema embarcado é de construção viável, de baixo custo, eficiente e confiável.

Neste trabalho, são utilizadas técnicas de processamento digital de imagens do rosto e mão do motorista, geradas para obter parâmetros que demonstram as condições fisiológicas do condutor e se está atento ou não. São integrados alertas sonoros e visuais que comunicam ao condutor quando houver possíveis riscos de sonolência. Para realizar tal tarefa é utilizado o microcontrolador Raspberry-Pi4 e a este acoplado câmera, com capacidade infravermelha e atuadores de alertas.

2. REFERENCIAL TEÓRICO

O Brasil é considerado um país de trânsito violento (ABREU, 2018). Devido a isto, Órgãos governamentais vem tentando conter esta alta de acidentes. Com a implantação do Código de Trânsito Brasileiro (CTB) em 1998, a taxa de mortalidade manteve-se estável, com uma média de 20 mortes por 100 mil habitantes (ABREU, 2018). As leis, fiscalizações, controles municipais de trânsito e melhoria no desenvolvimento dos veículos, não são o suficiente para diminuir significativamente estes números (DE QUEIROZ, 2020).

A velocidade é um dos maiores problemas e está diretamente relacionada à gravidade do acidente, a cada 1% no aumento da velocidade o risco de acidentes fatais aumenta em 4%. O uso de celulares também é um grande risco para o trânsito, pois diminui

o tempo de reação do motorista, tendo 4 vezes mais chances de se envolver em acidentes (OPAS, 2019).

Acidentes de trânsito geram grandes preocupações por conta de vidas perdidas, porém economicamente também são um problema. Pesquisas feitas pelo Instituto de Pesquisa Econômica Aplicada (IPEA) mostram os custos causados pelos acidentes de trânsito no Brasil ocorridos em rodovias e áreas urbanas. Os estudos apresentam uma estimativa conservadora com despesa média de R\$50 bilhões por ano, sem considerar os gastos por danos psicológicos. Este custo representa aproximadamente 3% do PIB brasileiro, em que se estima que cada morte custa cerca de R\$785 mil aos cofres públicos (IPEA, 2021). Com a diminuição dos acidentes e consequentemente dos dispêndios gerados, este valor poderia ser aplicado em educação e saúde.

A distração, sono e desobediência por parte dos motoristas são motivos de grande parte de acidentes de trânsito, nesse sentido uma das soluções criadas para evitá-los é a utilização de radares em centros urbanos (SANTOS, 2019). Com o uso das tecnologias atuais é possível desenvolver dispositivos que sirvam como auxílio ao motorista. O uso de câmeras no automóvel torna tangível transformar informações visuais capturadas pelas câmeras em respostas sonoras enviadas ao motorista, com técnicas de *machine learning* (aprendizado de máquina) (HAMDI, 2021), (RATHER, 2021). Existem também possibilidades de desenvolver algoritmos que consigam discernir certas ações do motorista por seus gestos e assim gerar uma resposta para auxiliá-lo (ANDRADE, 2017).

As câmeras em geral, através das imagens geradas por elas, conseguem engendrar uma relevante quantidade de informações. Os sensores utilizados pelas câmeras possuem sensibilidade a ponto de ser melhor que a do olho humano em determinados aspectos, como sensibilidade a luz infravermelha e luminosidade, o que é essencial para captação de imagens noturnas (LAGO, 2019; SILVA, 2015; RATHER, 2021).

Estudos são feitos a fim de determinar a direção do olhar do condutor, para evitar acidentes por imprudência (LAGO, 2019). Para isto é coletado um conjunto de dados internos do veículo para a análise e conclusão do comportamento do motorista. Velocidade, aceleração, rotação do rosto, características faciais e luminosidade são dados analisados para chegar à resposta se há atenção ou distração por parte do motorista.

De acordo com pesquisas realizadas, aparelhos embarcados de monitoramento do condutor utilizando câmeras, Raspberry, linguagem Python com biblioteca *OpenCV*, podem

ser desenvolvidas com baixo custo e serem eficientes (DE ALMEIDA NORONHA, 2019; HAMDÍ et al., 2021). Neste caso, o processo pode ser dividido em três fases, onde a câmera captura frames de imagens do motorista, estas imagens são processadas de acordo com as expressões faciais, principalmente dos olhos e boca, e caso a análise seja positiva é enviado um alerta para o condutor.

Visão computacional é uma tecnologia muito recorrida para análise de imagens faciais (SOUZA, 2019; DE ALMEIDA NORONHA, 2019; ELEKTRA, 2024; CVONLINE, 2024; ADRIAN, 2023). Pesquisas demonstram que quando utilizadas visão computacional e algoritmos como o de Viola e Jones para detecção, é possível a identificação de expressões faciais, a fim de distinguir momentos que o motorista apresenta comportamentos de risco, como a sonolência. Em relação ao processo de detecção usa-se o formato cascata, que é uma combinação sucessiva de análises, o que resulta na aprovação ou rejeição da situação de sonolência e/ou desatenção.

Com o aumento de dispositivos IoT (*Internet of Things*), a sua utilização como sistemas embarcados em automóveis se torna relevante (STREIFFER, 2017; ABREU, 2021; ANDRADE, 2021; ANDRADE, 2017). Com diversas aplicações e dados a serem analisados, o *deep learning* (aprendizagem profunda) e *big data* (grande conjunto de dados) são tecnologias que podem ser combinados, para que a coleta e análise possam ser cada vez mais precisas e refinadas.

3. PROCEDIMENTOS METODOLÓGICOS

A metodologia do trabalho está dividida em etapas que envolvem o estudo e teste de ferramentas computacionais indispensáveis no desenvolvimento do projeto. O protótipo do sistema de detecção de fadiga e sonolência foi desenvolvido utilizando o Raspberry-Pi 4, que é uma plataforma de hardware compacta e eficiente, para executar tarefas de visão computacional, além de ter um baixo custo em relação a outros microcontroladores. Esta plataforma ainda permite a integração de sensores e outros periféricos possuindo uma boa capacidade de processamento, particularmente de bibliotecas de visão computacional atuais em Python.

3.1 Ferramentas e Bibliotecas Utilizadas

Respeitando as melhores práticas identificadas na seção 2, pode-se descrever as ferramentas habitualmente usadas em dispositivos embarcados, como o que se pretende construir:

OpenCV: biblioteca utilizada para captura, processamento e manipulação de imagens e vídeos. Através dela foi possível a captura de frames da webcam, e convertê-las em uma escala cinza no qual é realizado operações de detecção de contornos, mais eficaz para uso com algoritmos *MAR* e *EAR*.

Dlib: esta biblioteca é usada apenas nos testes. Ela permite a detecção de faces e a predição de marcos faciais. O detector de faces é baseado no algoritmo *HOG* (*histogram of Oriented Gradients – histogramas orientados pelo gradiente*) e o preditor de marcos faciais permite identificar e monitorar a região dos olhos (*EAR*) (SOUZA, 2019; DE ALMEIDA NORONHA, 2019).

MediaPipe: Desenvolvido pelo Google é uma estrutura de aprendizado de máquina no qual permite a construção de *pipelines* (filas) de processamento de mídia em tempo real. Sendo utilizada para identificar através do *FaceMash* os pontos do rosto facial como também a detecção de mãos (HAMDI et al., 2021).

TensorFlow: utilizada para construir e treinar modelos de aprendizado de máquinas em especial a redes neurais, no qual realiza tarefas de visão computacional e processamento de linguagem natural de modo a permitir inferência em tempo real e execução em dispositivos móveis, sendo ideal para projetos de inteligência artificial complexos. Esta ferramenta é considerada como de computação intensa e pode não ser apropriada para microcontroladores embarcados, como o Raspberry (HAMDI et. al, 2021; ABREU, 2021).

Dentre as bibliotecas auxiliares que podem ser utilizadas no desenvolvimento do protótipo, destaca-se (ABREU, 2021; ANDRADE, 2017):

Scipy.spatial.distance: calcula as distâncias euclidianas entre os marcos faciais, permitindo a realização dos cálculos de abertura dos olhos e boca.

Imutils: facilita operações comuns em processamento de imagens, como a manipulação de vídeo e a transformação de coordenadas de marco faciais

Playsound: é uma biblioteca simples para reprodução de áudio, no qual foi necessária para a reprodução do efeito sonoro de alerta.

Matplotlib: permite a criação de gráficos em tempo real de modo a realizar o monitoramento da abertura dos olhos ou boca.

Numpy: manipula dados numéricos das coordenadas adquiridas nos marcos faciais, sendo um suporte de cálculos eficientes para estes parâmetros.

3.2 Levantamento de imagens

Informações sobre conjunto de imagens de motoristas com atitudes corretas e incorretas na direção/condução de veículos serão levantadas, preferencialmente, a partir de bases de dados abertas existentes na internet de trabalhos anteriores, como exemplo em (ELEKTRA, 2024; CVONLINE, 2024). De acordo com Silva (2015), para câmeras de resolução média (640 x 480, 1024 x 768), o interessante é obter imagens de pelo menos 30 pessoas diferentes, identificando atitudes de direção correta ou de risco ao volante. Alternativamente, podem ser obtidas imagens de voluntários, capturadas a partir de um celular ou webcam fixado no veículo, respeitando Lei do uso de imagens devido, Constituição Federal, artigo 5, inciso X. Importante observar que para a captura de imagens noturnas, é relevante que a câmera possua o recurso de iluminação e sensibilidade ao infravermelho.

3.3 Algoritmos Computacionais

Nesta etapa, são levantados e estudados os algoritmos de visão computacional, a partir de referências científicas disponíveis, como por exemplo, em Abreu (2021), em Andrade (2017) e De Mello (2021), utilizando computador e a linguagem de estudo adequada, como Python, C.

A implementação do algoritmo de detecção de sonolência, tendo como referência o artigo do Adrian Rosebrock (ADRIAN, 2023), é desenvolvido em Raspberry-Pi4 utilizando as bibliotecas mais eficientes para processamento em tempo real: *OpenCV*, *Imutils*, *Numpy*, *playsound* e *dlib*.

Em particular, utilizando o FaceMesh no qual é feito um mapeamento do rosto em 3D de modo que é inserido 468 pontos na face que ele consegue identificar no rosto através das coordenadas do rosto por exemplo das pálpebras para verificar o piscar ou fechamento

de olhos como também a abertura da boca demonstrando a fadiga através de bocejos, movimentos de desatenção etc.

3.4 Câmeras

A partir de trabalhos científicos de relevância, como em Rather (2021) ou Ramdi et al. (2021), são consideradas as câmeras habitualmente usadas, de baixa e média resolução (640 x 480 ou 1024 x 768), acopladas a microcontroladores de sistemas embarcados, para a captura e reconhecimento de imagens de motoristas em tempo real. Dentre as câmeras recomendadas, são verificadas as que estão disponíveis no mercado nacional, suas especificações técnicas e melhores custos de aquisição. Deseja-se escolher para o estudo câmera disponível, que possua o menor custo e seja eficaz no reconhecimento das imagens.

Cameras com infravermelho

Câmeras com visão infravermelha são desejáveis, uma vez que o sistema embarcado deve ser capaz de operar tanto de dia como de noite em um veículo. Como exemplo de câmeras disponíveis no mercado nacional, pode-se citar

Raspberry Pi NoIR Camera V2, é uma câmera sensível à luz infravermelha, no qual é ideal para captura de imagens em completa escuridão (ML, 2023).

WebCam Wift que conta com suporte a IR e controle de exposição avançado, compatível com aplicações de Visão Computacional (ML2, 2023).

3.5 Microcontroladores aplicáveis

Nesta etapa são estudados e considerados os microcontroladores usuais e suas capacidades de processamento de imagens em tempo real para aplicação em sistemas embarcados através dos recomendados em materiais científicos, como em Hamdi et al. (2021) ou Rather (2021), e dos técnicos disponíveis nas bases de consulta, estes últimos como em Raspberry (2021). Para que seja possível o processamento em Python e o uso de bibliotecas de visão computacional com modelos pré-treinados modernos, dois controladores podem ser utilizados: a ESP32 e o uso de MicroPython ou o Raspberry. De acordo com recente estudo realizado por Thapa e KC (2023), considerando o processamento de visão computacional, a plataforma mais robusta e de menor custo para o uso de bibliotecas pre-treinadas apresentadas é o Raspberry. Optou-se no projeto, por trabalhar então com o Raspberry-pi4.

4. PROTOTIPAÇÃO E TESTES

Nesta fase, implementa-se o protótipo do sistema embarcado e são efetuados testes de laboratório e de campo para ajustes do hardware e software, de acordo com a seção 3. No protótipo, é utilizado um Raspberry-Pi4 e câmera de Raspberry com baixa resolução, webcam Wift (ML2, 2023) que atende as características citadas na seção 2. Tentou-se utilizar câmera comercializada própria para o Raspberry (barramento próprio) (ML, 2023). Esta não se mostrou viável, apresentando contínuos problemas de hardware (possível fragilidade de materiais).

Inicialmente, foi desenvolvido alguns códigos de testes no google *Colab*, plataforma *on-line* do Python, e em seguida testes em notebook i5, utilizando o *Pycharm*. Dependendo do êxito obtido, cada versão do código foi carregada no Raspberry-pi4. Para viabilizar a utilização do Python no dispositivo, é necessária a instalação do sistema operacional *linux*, além do IDE *Pycharm*. Todos os códigos desenvolvidos e imagens trabalhadas deste projeto, encontram-se organizadas no *Github* (GITHUB, 2024).

Vale lembrar que para os cálculos de detecção de fadiga ocular, especificamente da proporção da abertura e fechamento dos olhos, *EAR*, é baseado em materiais de aprendizagem profunda de Adrian Rosebrock (ADRIAN, 2023). Neste, as distâncias euclidianas entre marcos faciais verticais e horizontais dos olhos são calculados, determinando se estão abertos ou fechados. Em casos de sonolência, o ser humano passa mais tempo com o olho fechado. Utilizou-se de um valor entre 2 e 5 segundos de olho fechado, para gerar um alerta ao motorista no protótipo. No caso de olho fechado, a razão entre a linha vertical e a horizontal dos olhos tende a zero, como ilustrado na figura 3.

O sistema no Raspberry é capaz de monitorar imagens de vídeo em tempo real, a uma razão de pelo menos 10 qps (quadros por segundo), ou velocidade de cálculos de 0,1 s, o suficiente para detectar com precisão estados de sonolência, baseado em *EAR*. Para tal é realizado sequencialmente a capturas de frames e processamento de imagens, utilizando as bibliotecas, *OpenCV*, e *MédiaPipe*. Em cada quadro (imagem) capturado do rosto são utilizadas as funções do preditor de marcos faciais (*Face Mash*). O preditor permite identificar 468 pontos do rosto (ADRIAN, 2023) ou até mesmo as malhas das mãos. A análise de alguns destes pontos que definem a região dos olhos, por exemplo, viabiliza realizar o diagnóstico da situação do motorista e se ele demonstra fadiga, sonolência ou até mesmo distrações

como o uso de um aparelho celular (se o centro dos olhos não estiver na direção do para-brisa (para frente) ou dos espelhos laterais (por curtos intervalos de tempo).

Para o protótipo, após a definição da malha facial de um quadro (imagem capturada pela câmera da face do motorista, é possível monitorar por programação os tempos de movimentos dos olhos e lábios. Os pontos que definem as distâncias horizontais e verticais das pálpebras e dos lábios, permitem verificar se uma pessoa está sonolenta: ou com seus olhos fechados por certo tempo, ou bocejando (considerou-se limite dos lábios na vertical em distância máxima por mais de 2 segundos (HAMDÍ et al., 2021). A Figura 2 ilustra o que ocorre com uma imagem capturada, após ser submetida ao *Face Mesh*. Um conjunto de pontos na forma de um vetor em Python é retornado, viabilizando os cálculos *EAR* e *MAR*.

Figura 2 – Exemplo de cálculos dos 468 pontos realizadas pelo preditor do *Face Mesh*



Fonte: (HOTAKOMA, 2024)

A detecção do estado de sonolência é efetuada observando a razão entre a distância dos pontos verticais e os pontos horizontais que definem a região das pálpebras. No exemplo apresentado na figura 3, esta razão é continuamente calculada ao longo da sequência de quadros e apresentada no gráfico da figura abaixo em que o eixo horizontal corresponde ao tempo e o vertical a razão. Caso o tempo de olhos fechados (razão $< 0,1$) esteja entre 2 a 5 s, considerou-se que o motorista está sonolento e um alerta visual/sonoro deve ser disparado pelo dispositivo.


Desta maneira, a figura 4 ilustra uma situação em que as marcas faciais do *Face Mesh* correspondentes aos olhos definem uma razão pequena ($< 0,1$), por mais de 2 s, indicando que o motorista está sonolento e/ou desatento.



Coordenadoria de Fomento à Pesquisa – CFP 2024

Figura 3: Exemplo de detecção de olhos fechados.

Na imagem superior a esquerda, tem-se os pontos que referenciam o estado de olho aberto e na do canto superior direito o estado de olhos fechados. No gráfico da figura, é apresentado a razão/proporção do olho aberto fechado (distância vertical/horizontal) ao longo do tempo, o que indica se o olho está aberto ou fechado



Fonte: (SOUKUPOVA, CECH, 2016)

Figura 4: Alarme de motorista desatento ao volante por *EAR*.

Na imagem da esquerda, corresponde ao frame que apresenta a análise de olhos fechados por mais de 2s, gerando um alarme ao motorista. Já na imagem da direita, foi estabelecido 8s, de acordo com Hotakoma (2024), para que novo alarme fosse gerado ao motorista, excessivamente sonolento ou dormindo.



Fonte: os autores

Seguindo este princípio, através dos marcos faciais que definem o contorno dos lábios da boca, é possível estimar se o motorista está com a boca aberta ou fechada. Nos bocejos, em geral, a razão entre a distância vertical/horizontal tende a ficar grande por alguns segundos, em média maior que 2 s (ADRIAN, 2024; SOUKUPOVA, CECH, 2016).

Novamente, se esta condição é identificada pela captura contínua dos pontos pelo software, alarme de sinal de bocejo, podendo pressupor fadiga ou sonolência, é enviado pelo protótipo, alertando o motorista. A figura 5 ilustra uma situação em que as marcas faciais do *Face Mesh* correspondentes aos lábios definem uma razão grande ($>0,25$), em geral por mais de 5 s (ADRIAN, 2024), indicado que o motorista está com a boca aberta e bocejando.

Figura 5 - Alarme de motorista desatento ao volante por *MAR*.



Fonte: os autores

São exploradas também outras possibilidades das bibliotecas. No caso ilustrado na figura 6, corresponde a premissa de um motorista desatento, utilizando um telefone celular. Para tal, calcula-se os pontos que definem a mão (esquerda ou direita) e a proximidade desta dos pontos que definem a orelha. No protótipo, trabalha-se com a hipótese de que a proximidade média é inferior a 10 cm, por mais de 10s. Neste caso, ou o motorista está falando com o celular próximo a orelha direita ou esquerda, e, sobretudo, dirigindo com uma mão só, o que é imprudente.

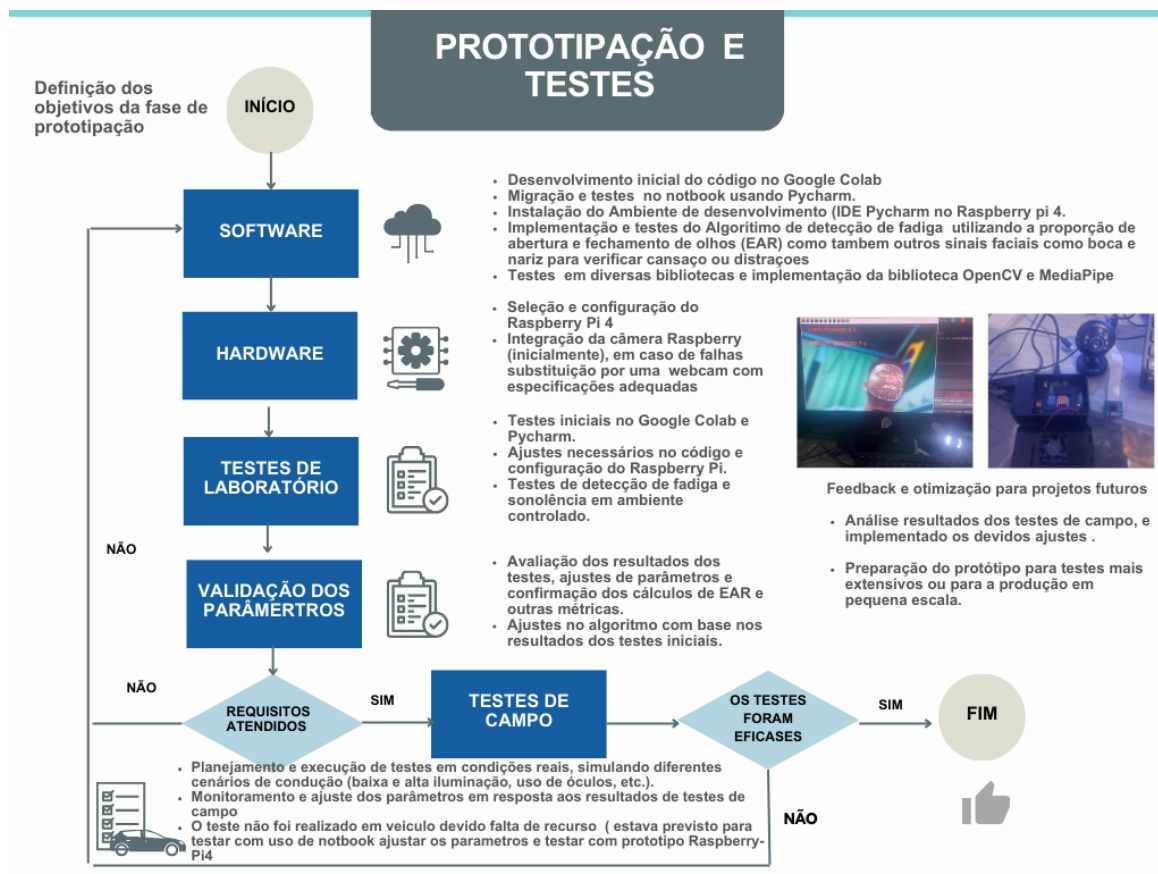
Figura 6 – Motorista falando no celular.



Fonte: os autores

O fluxograma, na figura 7 ilustra o processo de prototipação e testes de desenvolvimento do sistema embarcado para monitoramento de distrações, sonolência e fadiga de motorista. Após a definição do objetivo e pesquisas do projeto foi iniciado o desenvolvimento de software e hardware, avançando para as etapas de testes laboratoriais e validação dos parâmetros culminando para o teste de campo de modo a analisar condições reais (no qual acabou não sendo executado devido à ausência de um veículo para teste). Observando-se da importância de ajustes, testes de redes neurais e otimizações para produção em pequena ou larga escala. O desenvolvimento a partir de Raspberry-Pi4 e bibliotecas como OpenCV e MediaPipe enfatiza uma solução acessível e de alta precisão.

Figura 7 – Fluxograma compondo o processo de desenvolvimento do protótipo



Fonte: os autores

5. RESULTADOS ESPERADOS

O objetivo é desenvolver um protótipo funcional capaz de monitorar e alertar motoristas sobre comportamentos de sonolência e/ou desatenção. O sistema obtido é portátil,

podendo ser embarcado em veículos com a câmera disposta na direção do rosto do motorista. Testes, como os exemplificados na seção 4, demonstram a sua eficiência em algumas condições. Um sistema protótipo Raspberry com webcam e alarmes como *buzzer* e luzes, custa em média no Brasil em torno de R\$ 800,00, sendo de custo relativamente acessível.

Para o desenvolvimento do projeto é relevante o estudo e exploração das bibliotecas e funções atuais de visão computacional, em linguagem de programação Python para o desenvolvimento dos algoritmos computacionais elaborado. Além disto, conhecimentos de Linux, para poder embarcar o software no hardware portátil proposto, o Raspberry.

No decorrer dos treinamentos, foram identificadas situações desafiadoras ao protótipo: a utilização de óculos atrapalha a detecção das marcas faciais dos olhos e seria necessário a utilização de um filtro polaroide na câmera, para otimizar a detecção de olhos fechados. Se ainda os óculos possuírem lentes escuras, a detecção de fadiga por *EAR* torna-se inviável, sendo, porém, possível, a detecção por *MAR* ou ainda a desatenção por uso de telefone celular ao volante. O protótipo foi testado em laboratório, não houve recursos para embarcar o mesmo em veículos, a fim de validar as diversas condições de iluminação ou luzes noturnas de diversos pontos focais sobre o motorista (exemplo, luz de um farol alto de um veículo na mão contrária modificando a iluminação/luminosidade), que podem comprometer a taxa de efetividade de detecção de sonolência ou desatenção. O simples teste de realizar o reconhecimento com a luz apagada foi viável, já que a câmera possui iluminação infravermelha e o algoritmo trabalha com imagens em preto e branco, de acordo com a recomendação de literatura.

6. DISCUSSÃO

Este protótipo desenvolvido demonstra a viabilidade de utilizar técnicas de visão computacional para monitorar a atenção dos motoristas, tornando o projeto de interesse na prevenção de acidentes relacionados a distrações, fadiga ou sonolência. No entanto, o protótipo foi desenvolvido e testado em laboratório, não havendo recursos para testes de campo, que permitiram mais ajustes no protótipo e melhor determinar a sua taxa de eficiência, em condições de luminosidade adversas ou quando o motorista utiliza óculos.

Observou-se, todavia, que a utilização de iluminação infravermelha (IR) pode resultar em uma melhora na captura de imagens faciais em ambientes noturnos ou de pouca luz, sendo um recurso importante, porém não disponível em câmeras que são diretamente conectadas ao barramento do Raspberry.

Apesar dos testes não terem sido aplicados em ambiente embarcado de campo, é possível constatar que este desenvolvimento é eficaz em constatar fadiga, sonolência e distrações, como o uso do celular, em tempo real. O protótipo ainda atendeu os pré-requisitos em um sistema de baixo custo, com alertas eficazes. Entretanto o desempenho do protótipo precisa ser refinado para atingir o estágio de implementação em um veículo.

7. CONSIDERAÇÕES FINAIS

O protótipo desenvolvido mostra a viabilidade do sistema embarcado para monitoramento de fadiga, sonolências e distrações. No desenvolvimento é utilizado o Raspberry-Pi4, um processador que permite a execução de códigos Python e o uso de bibliotecas de visão computacional modernas. No desenvolvimento do protótipo foram realizados inúmeros testes em escala de laboratório, a fim de validar as condições de alarmes de sonolência por *EAR*, por *MAR* e ainda desatenção por uso de celular ou dirigir somente com uma mão ao volante. Ressaltando que todo o desenvolvimento de projeto realizado se encontra a disposição, programas, repositórios, e dados, organizados em Github: https://github.com/Fenixsinedbr/Dispositivo_Microcontrolado_Detec-o_Facial.git (GITHUB, 2024).

REFERENCIAS

ADRIAN, Rosebrock. **Deep Learning for Computer Vision with Python**. Disponível em: <https://pyimagesearch.com/deep-learning-computer-vision-python-book/>. Acesso em: 10 de outubro de 2023.

ABREU, Débora Regina de Oliveira Moura; SOUZA, Eniuce Menezes de; MATHIAS, Thais Aidar de Freitas. **Impacto do Código de Trânsito Brasileiro e da Lei Seca na mortalidade por acidentes de trânsito**. Cadernos de Saúde Pública, v. 34, p. e00122117, 2018.

ABREU, Viviana Rubina Gonçalves. **Reconhecimento Facial-Comparação do Uso de Descritores Geométricos Heurísticos e Aprendizagem Profunda**. 2021. Tese de Doutorado. Universidade de Coimbra.

ALI, Farman et al. **Traffic accident detection and condition analysis based on social networking data**. Accident Analysis & Prevention, v. 151, p. 105973, 2021

ANDRADE, Rodrigo Meira. **Módulo auxiliar de monitoramento veicular através de câmeras e deep learning**. 2017. 37 f. Trabalho de Conclusão de Curso (Especialização em Sistemas Embarcados Para a Indústria Automotiva) - Universidade Tecnológica Federal do Paraná, Curitiba, 2017.

CVONLINE. **Images Database**. Disponível em: https://bit.ly/DB_CV2. Acesso em: 20 de março de 2024.

DE ALMEIDA NORONHA, F.; ALMEIDA, L. L. de; ASSIS DA SILVA, F.; PANDUR ALBUQUERQUE CABRAL, F.; AUGUSTO SISCOOTTO, R. **Detecção de fadiga a partir da análise de imagens faciais**. Colloquium Exactarum. ISSN: 2178-8332, [S. l.], v. 11, n. 2, p. 34–45, 2019. Disponível em: https://bit.ly/dec_fad. Acesso em: 20 abr. 2021.

DE MELLO, Guilherme. **Detecção e classificação facial em tempos de Covid-19**. Universidade Estadual de Londrina, 2021.

DE QUEIROZ, José Carlos Eloi; FERREIRA, LEONARDO BORGES. **Embriguez ao volante: Análise da eficácia da lei seca no Distrito Federal**. Revista Brasileira de Estudos de Segurança Pública, v. 13, n. 1, p. 60-69, 2020.

DO CARMO, Mario Henrique. **Trânsito: uma questão de segurança pública**. Brazilian Journal of Development, v. 7, n. 3, p. 24799-24814, 2021.

DO NASCIMENTO, Beatriz Rigorfi. **Impactos da educação de trânsito na saúde pública**. Revista UniCET, v. 1, n. 3, 2021.

DOS SANTOS, Andreza Patricia Almeida. **A educação como agente de transformação social e prevenção de acidentes e mortes**. Revista UniCET, v. 1, n. 3, 2021.

ELEKTRA. **Driver Dataset**. Disponível em: <http://adas.cvc.uab.es/elektra/enigma-portfolio/cvc11-drivface-dataset/>. Acesso em: 05 de abril de 2024.

GITHUB. **Softwares desenvolvidos durante o corrente projeto do sistema embarcado e dados**. Disponível em: https://github.com/Fenixsinedbr/Dispositivo_Microcontrolado_Detec-o_Facial.git. Acesso em: julho de 2024.

HAMDI, Mustafa Maad et al. **VANET-based traffic monitoring and incident detection system: A review**. International Journal of Electrical and Computer Engineering (IJECE), v. 11, n. 4, p. 3193-3200, 2021.

HOTAKOMA. MediaPipe landmark face/hand/pose sequence number list view. Medium, 2023. Disponível em: <https://medium.com/@hotakoma/mediapipe-landmark-face-hand-pose-sequence-number-list-view-778364d6c414>. Acesso em: 17 ago. 2024.

IPEA. **Custos dos acidentes de trânsito no Brasil: estimativa simplificada com base na atualização das pesquisas do IPEA sobre custos de acidentes nos aglomerados urbanos e rodovias**. Disponível em: https://bit.ly/ip_acd. Acesso em: 14 de abril de 2021.

LAGO, Thiago Koster. **Sistema inteligente para avaliação em tempo real da atenção dos condutores de veículos**. 2019. Tese de Doutorado. Universidade Federal do Rio de Janeiro.

ML. **Câmera para Raspberry com visão infravermelha**. Disponível em: <https://produto.mercadolivre.com.br/MLB-3683274855-cmera-Raspberry-pi-noir-v2-8mb-JM>. Acesso em: set de 2023.

ML2. **Webcam com visão infravermelha**. Disponível em: https://produto.mercadolivre.com.br/MLB-3766013785-webcam-domestica-sem-fio-com-viso-noturna-infravermelha-JM#position%3D49%26search_layout%3Dgrid%26type%3Ditem%26tracking_id%3Dc4d0bca5-b269-45c4-a9f1-f19f21d1716a. Acesso em: ago de 2023.

ONSV. Observatório Nacional de Segurança. **90% dos acidentes são causados por fator humano**. Disponível em https://bit.ly/on_qr. Acesso em: 13 de abril de 2021.

OPAS. **Folha informativa – acidentes de trânsito**. Disponível em: https://bit.ly/op_ac. Acesso em: 13 de abril de 2021.

PARANHOS, Vinícius Kerber. **Sistema de detecção de sonolência**. Trabalho de Conclusão de Curso, UPF, 2019.

PRF. Polícia Rodoviária Federal – **Dados sobre mortes no trânsito**. Disponível em: <https://portal.prf.gov.br/dados-abertos-acidentes>. Acesso em: 21 de março de 2021.



Coordenadoria de Fomento à Pesquisa – CFP 2024

R7. **A história do primeiro acidente fatal de carro, ocorrido há 150 anos.** Disponível em: https://bit.ly/pri_ac. Acesso em: 10 de abril de 2021.

RASPBERRY. **Hardware and Software.** Disponível em: <https://www.Raspberrypi.org/>. Acesso em 24 de março de 2021.

RATHER, Adil Ahmad; SOFI, Tasawor Ahmed; MUKHTAR, Nowreen. **A Survey on Fatigue and Drowsiness Detection Techniques in Driving.** In: 2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS). IEEE, 2021. p. 239-244.

Rosebrock, A. (n.d.). **Eye blink detection with OpenCV, Python, and dlib.** Retrieved from <https://bit.ly/2CYC7Gf>

SANTOS, Elayne Barbosa dos. **Impacto dos controladores eletrônicos de velocidade na redução do número e da gravidade de acidentes de trânsito com vítimas em trechos de rodovias federais.** Dissertação de Mestrado. UNB, 2019.

SILVA, José Ivson Soares da. **Reconhecimento facial em imagens de baixa resolução.** 2015. Dissertação de Mestrado. Universidade Federal de Pernambuco.

SOCIALBAURU. **O primeiro acidente de trânsito.** Disponível em: <https://www.socialbauru.com.br/2015/12/07/o-primeiro-acidente-de-transito/>. Acesso em: 11 de abril de 2021.

SOUKUPOVA, Tereza; CECH, Jan. Eye blink detection using facial landmarks. Em: **21st computer vision winter workshop**, Rimske Toplice, Slovenia. 2016.

SOUZA, Matheus Luiz Anderle de et al. **Um estudo de técnicas de detecção de olhos utilizando Visão Computacional.** 2019.

STREIFFER, Christopher et al. **Darnet: a deep learning solution for distracted driving detection.** In: Proceedings of the 18th acm/ifip/usenix middleware conference: Industrial track. 2017. p. 22-28.

THAPA, Sulav; KC, Subash Chandra. **Raspberry Pi and ESP32-Based Smart Sensor Network for IoT Platform Integration and Real-Time Environmental Data Monitoring.** 2023.



Coordenadoria de Fomento à Pesquisa – CFP 2024

TRANSITOIDEAL. **Breve história do trânsito.** Disponível em: <http://www.transitoideal.com.br/pt/artigo/4/educador/66/breve-historia-dotransito>. Acesso em: 08 de abril de 2021.

WHO. **World Health Organization – Road traffic injuries.** Disponível em: <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>. Acesso em: 30 de março de 2021.

Contatos: 10343757@mackenzista.com e antonio.licciardi@mackenzie.br