

SEGMENTAÇÃO, CLASSIFICAÇÃO E DETECÇÃO DE MOTOCICLISTAS SEM CAPACETE

ROMUERE SILVA, KELSON AIRES, THIAGO SANTOS, KALYF ABDALLA, RODRIGO VERAS*

**Universidade Federal do Piauí
Departamento de Computação
Teresina, Piauí, Brasil*

Email: {romuere, kelson, thiagossantos, kalyfabdalla, rveras}@ufpi.edu.br

Abstract— Motorcycle accidents have been rapidly growing throughout the years in many countries. Due to various social and economic factors, this type of vehicle is becoming increasingly popular. The helmet is the main safety equipment of motorcyclists, but many drivers do not use it. If an motorcyclist is without helmet an accident can be fatal. This paper aims to explain and illustrate an automatic method for motorcycles detection and classification on public roads and a system for automatic detection of motorcyclists without helmet. For this, a hybrid descriptor for features extraction is proposed based in Local Binary Pattern, Histograms of Oriented Gradients and the Circular Hough Transform descriptors. Traffic images captured by cameras were used.

Keywords— Computer vision and and pattern recognize, motorcycle detection, helmet detection, hybrid descriptor, vehicle classification.

Resumo— O número de acidentes envolvendo motocicletas tem aumentado rapidamente ao longo dos anos em muitos países. Impulsionados por vários fatores econômicos e sociais, esse tipo de veículo está se tornando cada vez mais popular. O capacete é o principal equipamento de segurança dos motociclistas, mas muitos motociclistas não o utilizam. Em caso de acidente com motociclista sem capacete, este pode ser fatal. Esse trabalho tem como objetivo explicar e esclarecer um método automático para detecção e classificação de motocicletas em vias públicas e um sistema para detecção automática de motociclistas sem capacete. Para isso, é proposto um descritor híbrido para extração de atributos com base nos descritores *Local Binary Pattern*, *Histograms of Oriented Gradients* e Transformada Circular de Hough. Foram utilizadas imagens de tráfego capturadas por câmeras em vias públicas.

Keywords— Visão computacional e reconhecimento de padrões, detecção de motocicletas, detecção de capacete, descritor híbrido, classificação de veículos.

1 Introdução

Motocicletas são amplamente utilizadas como um meio de transporte em muitos países. As principais vantagens são o preço baixo e o baixo custo de operação em relação a outros veículos. De acordo com o Departamento Nacional de Trânsito no Brasil (DENATRAN), em março de 2013, o Brasil possuía uma frota de 20.281.986 motocicletas e motonetas. Na última década, verificou-se um aumento no número de acidentes envolvendo motocicletas. Em 2011, de acordo com o Departamento Nacional de Infraestrutura de Transportes (DNIT), o Brasil teve um total de 34.635 motocicletas envolvidas em acidentes (*Número de Veículos Envolvidos por Finalidade Do Veículo*, 2011), de acordo ainda com o DNIT, desse total, em 1.011 acidentes o motociclista estava sem capacete.

O principal equipamento de segurança dos motociclistas é o capacete. Embora o uso do capacete seja obrigatório, muitos motociclistas não usam ou usam incorretamente. Segundo o Departamento de Transportes nos EUA, em 2011, apenas 66% dos motociclistas usaram o capacete de acordo com a lei (*Traffic Safety Facts: Research Note Motorcycle Helmet Use in 2011 - Overall Results*, 2011). O Centro de Controle e Prevenção de Doenças nos EUA apresentou um relatório em 2012 onde os resultados indicaram que, em média, 12% dos motociclistas fatalmente feridos não estavam usando capacetes em estados com leis universais de uso de capacete. Nos estados que adotam lei do capacete parcial (o uso de capacetes somente é obrigatório para grupos

específicos, geralmente jovens), o número aumentou para 64%. Finalmente, o número é de 79% em estados sem lei de uso do capacete (*Helmet use among motorcyclists who died in crashes and economic cost savings associated with state motorcycle helmet laws - United States, 2008-2010.*, 2012).

Devido ao grande número de veículos existentes, pesquisas em sistemas de tráfego inteligente tornaram-se populares, incluindo detecção, reconhecimento, rastreamento e contagem de veículos, e estimação de parâmetros do tráfego.

1.1 Contribuições

Esse trabalho apresenta duas contribuições principais: apresentação de um novo método para detecção automática de motociclistas sem capacete; e um novo descritor híbrido baseado em características geométricas, borda e textura. O objetivo deste estudo é desenvolver um sistema de detecção automática de motociclistas sem capacete, criando uma estratégia dividida em dois passos: detecção de motocicleta e detecção do uso do capacete.

1.2 Trabalhos relacionados

Nos últimos anos, muitos trabalhos foram realizados em análise de tráfego em vias públicas, incluindo a detecção, classificação e contagem de veículos e detecção de capacete. No desenvolvimento desses trabalhos são necessários algoritmos para calcular o plano de fundo e imagens de primeiro plano com o objetivo de segmentar os objetos em movimento para,

em seguida, classificá-los. A seguir são mostrados alguns trabalhos relacionados à detecção de capacete.

Wen et al (Wen et al., 2003). Propôs um sistema de um método de detecção de arco de círculo com base na modificação transformada de Hough, tal método foi aplicada para a detecção de capacete em sistemas de vigilância de Terminais de Auto Atendimento. Para verificar a existência de algum capacete na imagem foram utilizados somente recursos geométricos, este pode ser considerado um ponto fraco deste trabalho. O que se observou foi que características geométricas não são suficientes para encontrar o capacete, já que cabeça dos motociclistas muitas vezes é confundida com um capacete, por possuírem formas semelhantes.

Em (Chiu et al., 2007), foi proposto um sistema de visão computacional com o objetivo de detectar e segmentar motocicletas parcialmente obstruída por outro veículo. Um sistema de detecção de capacete é utilizado, e a presença do capacete determina que existe uma motocicleta. Para isso as bordas são calculadas sobre a possível região do capacete, os pontos da borda que são semelhantes a um círculo definem se a região corresponde a um capacete. O sistema necessita de vários parâmetros a serem informados pelo usuário como: raio do capacete, ângulo da câmera e altura da câmera, o que torna o sistema pouco robusto e muito dependente do usuário e da calibração da câmera.

Chiverton (Chiverton, 2012) descreveu e testou um sistema de classificação automática e rastreamento de motociclistas com e sem capacetes. O sistema utiliza o classificador Máquina de Vetor de Suporte (*Support Vector Machine - SVM*) treinadas com histogramas derivados dos dados de imagem da região da cabeça dos motociclistas que utilizam fotografias estáticas e quadros de imagem individuais a partir dos dados de vídeo. O método obteve uma alta taxa de acerto nos seus resultados, mas o número de imagens na fase de testes é pouco.

Segmentação de motocicletas em vias públicas pode ser visto como o primeiro passo para desenvolver qualquer pesquisa em estimativa de tráfego, por esse motivo aqui são mostrados alguns trabalhos relevantes na segmentação de veículos.

Leelasantham et al. (Leelasantham and Wongseree, 2008) propôs uma técnica que consiste na detecção de veículos em movimento, utilizando métodos engenharia de tráfego. Os veículos são divididos em cinco grupos. A fraqueza deste trabalho consiste na extração de atributos, o procedimento utiliza apenas três informações: posição do veículo, comprimento e largura.

Takahashi et al. (Takahashi et al., 2010) introduziu um sistema de visão computacional para detecção de bicicletas, pedestres e motocicletas. O sistema detecta objetos em movimento e movimento de pedalar (ciclistas), utilizando o filtro de Gabor. O descritor Histogramas de Orientação dos Gradientes (*Histogram of Oriented Gradients - HOG*) é calculado e o classificador SVM classifica os objetos em

veículos de duas rodas e pedestres. Por fim, o movimento vertical é calculado e os veículos de duas rodas são classificados em motocicleta e bicicleta.

Sonoda et al. (Sonoda et al., 2011) propôs um sistema para detectar objetos em movimento. O sistema tem como objetivo detectar objetos em movimento em um cruzamento e alertar o condutor. Foi utilizado o Modelo de Mistura de Gaussianas (*Gaussian Mixtures Model - GMM*) para detectar os objetos em movimento e o algoritmo Lucas-Kanade *Tracker* para rastreamento de pedestres.

Chen et al. (Chen et al., 2012) apresentou um sistema de detecção, rastreamento e classificação de veículos. O sistema conta os veículos e separa eles em quatro categorias: carro, van, ônibus e motocicletas, o filtro de Kalman é utilizado para rastrear os veículos. O classificador SVM e o descritor HOG foram utilizados. Os resultados não foram semelhantes quando as condições climáticas mudaram.

1.3 Sistema Proposto

Este trabalho aborda o problema de detecção do uso de capacete por motociclistas em vias públicas. Para resolução do problema o mesmo foi dividido em duas etapas. A primeira etapa consiste em segmentar e classificar as imagens de veículos. Esta etapa tem como objetivo determinar os objetos que se movem na cena para depois classificá-los em *motocicletas* e *não-motocicletas*, tal classificação é feita, nesse problema, porque somente é necessário saber se o veículo é uma moto ou não. A Figura 4 mostra como a primeira etapa do problema é resolvida. No segundo passo é realizada a detecção do uso de capacete. Para reduzir o custo computacional e a precisão usamos uma Região de Interesse (*Region of Interest - ROI*), como na Figura 2. A detecção capacete é feito usando um descritor híbrido para extrair atributos da imagem, e o classificador SVM é usado para classificar uma imagem em *com-capacete* ou *sem-capacete*.

2 Segmentação e Classificação de Veículos

2.1 Segmentação de Veículos

Na fase de segmentação dos veículos é necessário duas etapas: detecção do plano fundo da imagem e segmentação de objetos em movimento.

Detecção do Plano de Fundo O principal objetivo desta etapa é a determinação de uma imagem de fundo que vai ser usado para detectar objetos em movimento. Quando um novo frame do vídeo é capturado ele é comparado ao plano de fundo e todo os pixels que não forem iguais são objetos em movimento. Algoritmos para calcular planos fundos adaptativos são necessários em ambientes onde os objetos estáticos mudam durante o tempo, ou seja, esse plano de fundo é sujeito a alterações. Desta

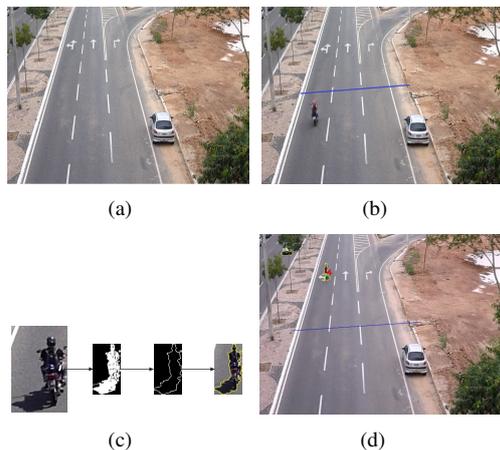


Figura 1: As principais etapas do processo de segmentação de objetos em movimento. As Figuras 1(a), 1(b) e 1(c) mostram os passos da segmentação de veículos e a Figura 1(d) mostra o resultado após a segmentação e classificação de veículos.

forma, nós atualizamos a imagem de fundo usando a adaptativa Mistura de Gaussianas (Zivkovic, 2004).

Segmentação de Objetos em Movimento A segmentação de objetos em movimento na cena permite que apenas os objetos de interesse na imagem sejam avaliados. Isso provoca uma redução do tempo de processamento, devido ao fato de o algoritmo de classificação funcionar apenas em uma pequena área da imagem. O método de subtração de fundo recebe todos os pontos que foram alterados em uma cena.

Em nossa abordagem de segmentação de objetos em movimento é necessário definir uma linha (ver Figura 1(b)) que deve ser marcado pelo usuário. Quando um veículo cruzar esta linha o processo de segmentação de objetos em movimento é iniciado e o quadro da imagem (veículo) é capturado. A subtração entre a imagem do quadro atual e do fundo é feita usando apenas os tons de cinza da informação. Depois disso, é feita uma limiarização utilizando o algoritmo de Otsu (Otsu, 1979) para criar uma imagem binária, em seguida é feita a detecção das bordas da imagem utilizando o algoritmo de Sobel (Sobel, 1970), além de uma abertura morfológica com o objetivo de retirar pequenas regiões e alguns ruídos. O passo seguinte é a detecção da forma utilizando o algoritmo proposto em (Suzuki and Be, 1985).

Um algoritmo de rastreamento é necessário para assegurar que cada veículo seja contado apenas uma vez. Para cada objeto detectado (veículo), o ponto de intersecção entre a diagonal principal do objeto e da linha definida pelo usuário é computado. Este ponto é marcado como o ponto de rastreamento do objeto. Com o objetivo de reduzir o processamento computacional, apenas os objetos detectados anteriormente não marcados são analisados. Este procedimento descrito é mostrado na

Figura 1(c). O próximo passo consiste em calcular o fluxo óptico do objeto detectado usando (Bouguet, 2000) com o objetivo de rastrear o objeto. A Figura 1(d) mostra o resultado desse processamento.

2.2 Classificação de Veículos

Em primeiro lugar, é necessário extrair os atributos dos objetos antes de utilizá-los no classificador. Neste caso, o descritor tem o objetivo de retornar importantes atributos da imagem através de um conjunto de valores. Este conjunto é chamado “vetor de atributos” do objeto. O vetor de atributos é utilizado pelo classificador para separar os objetos do problema em suas respectivas classes.

Extração de Atributos Para o procedimento de extração de atributos, o descritor Padrão Binário Local (*Local Binary Pattern* - LBP) foi utilizado. O LBP tem um bom desempenho em várias aplicações, incluindo classificação de textura, recuperação da imagem e inspeção de superfície. O LBP original (Ojala et al., 1996) rotula os pixels da imagem limiarizando uma vizinhanças 3×3 , cada pixel é comparado com o pixel central e o resultado é o número binário. Após o procedimento de limiarização, um histograma dos rótulos de 256 partições é computado. Este histograma é usado como um descritor de textura. Cada partição do histograma codifica primitivas locais. As primitivas locais incluem diferentes tipos de bordas, curvas, manchas, áreas planas, etc.

Processo de Classificação O principal objetivo de qualquer classificador é usar os atributos do objeto para identificar a qual classe ele pertence. Para classificação de veículos foi utilizado o classificador SVM (Cortes and Vapnik, 1995). A tarefa de classificação dos veículos consiste em diferenciar os objetos segmentados em duas classes *motocicleta* e *não motocicleta* pois é suficiente saber se o objeto corresponde a uma moto ou não.

3 Detecção do Uso do Capacete

Para resolver o problema da detecção do uso de capacete por motociclistas dividimos o problema em três etapas principais: determinação da RoI, extração dos atributos e classificação das imagens.

3.1 Região de Interesse

A determinação da RoI é um importante passo do problema, isso porque é necessário que a região da cabeça do motociclista esteja dentro da RoI. Usando uma RoI é possível diminuir o custo computacional bem como a área onde a busca será feita. Foi utilizada a parte superior da imagem (1/5 da imagem), como mostrado na Figura 2. Na base de dados gerada nesse trabalho, em todas as imagens de motociclistas

a região da cabeça destes estão completamente dentro da RoI.

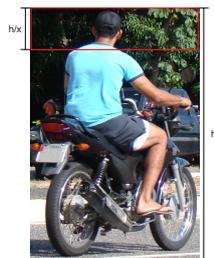


Figura 2: Exemplo de Região de Interesse.

3.2 Extração de Atributos

Para a extração de atributos utilizamos um descritor híbrido combinando a Transformada de Hough Circular (*Circular Transform Hough - CHT*) e os descritores LBP e HOG.

Transformada de Hough Circular Transformada de Hough é uma técnica que pode ser utilizada para encontrar formas geométricas na imagem (círculos, retas, elipses). Para a detecção de círculos em imagens, utiliza-se um processo de votação onde os votos são atribuídos aos pontos de passagem dos possíveis círculos existentes na imagem. Os votos são acumulados em um vetor de acumulação de votos, sendo que a detecção de um possível círculo é obtida quando um valor máximo é obtido no acumulador de votos.

Histogram of Oriented Gradients O algoritmo HOG (Dalal and Triggs, 2005) é um descritor de atributos que calcula o histograma da imagem a partir da orientação dos gradientes. O descritor final é uma matriz unidimensional de histogramas extraídos a partir da imagem. O algoritmo é baseado na forma e aparência do objeto local, que em uma imagem pode ser representado por gradientes de intensidade ou de direções de borda.

Descritor Híbrido Antes de calcular o descritor híbrido um conjunto de pré-processamentos são feitos. Primeiramente, calcula-se a imagem em níveis de cinza usando a distância euclidiana entre as faixas vermelhas e verdes do espaço de cores RGB. Um filtro de média com vizinhança 5×5 é aplicada para reduzir os ruídos. Depois, o limiar de Otsu (Otsu, 1979) é calculado para ser aplicado e obter uma imagem binária. O detector de bordas de Sobel (Sobel, 1970) também é aplicado. O próximo passo é usar o operador morfológico de erosão com objetivo de eliminar pequenas regiões e outros ruídos. Após o pré-processamento usamos o CHT para calcular os 10 melhores círculos na imagem (círculos com mais pontos), após isso é calculado o LBP e o descritor

HOG pelo quadrado circunscrito em cada círculo. Os dois vetores de atributos resultantes (LBP e HOG) são combinadas em um único vetor, gerando o descritor híbrido, tal descritor é uma mescla baseado em forma, textura e orientação de gradientes.

3.3 Classificação das Imagens

No processo de classificação testamos três classificadores. Os classificadores selecionados cobrem as três famílias de diferentes classificadores descritos por (Jain et al., 2000): probabilísticos, geométricas e baseado em árvore. Para a família probabilística testamos o classificador Naive Bayes. Para a família geométrica, foi testado o classificador SVM. Para a família baseada em árvore, o algoritmo *Random Forest* foi escolhido.

4 Resultados e Discussões

Os vídeos usados para os testes foram obtidos a partir de uma câmara de vídeo CCD em vias públicas, durante o dia e à noite. Os vídeos têm uma resolução de 1280×720 pixels com 114 minutos de duração. Todos os algoritmos foram implementados usando a ferramenta MATLAB[®] e a biblioteca OpenCV.

Segmentação de Veículos

A segmentação de objetos em movimento retornou um total de 3245 imagens as quais são utilizadas no processo de classificação. A Figura 3 mostra exemplos de imagens geradas nessa etapa.



Figura 3: Exemplo de imagens geradas no passo segmentação de objetos em movimento. As imagens foram capturadas durante o dia e noite.

Classificação de Veículos

Os resultados da etapa de classificação de veículos são gerados aleatoriamente selecionando 10% do conjunto de dados para treinamento e os outros 90% para testes, repetindo esse processo 10 vezes e calculando a média dos resultados, a fim de avaliar o desempenho dos métodos de classificação.

O LBP foi usado com uma janela 3×3 , isto significa que a imagem é dividida em nove janelas, correspondendo a 9 histogramas e a vizinhança foi de tamanho 3×3 para a computação dos rótulos. O SVM foi executado utilizando uma função de kernel linear com peso igual a 2000.

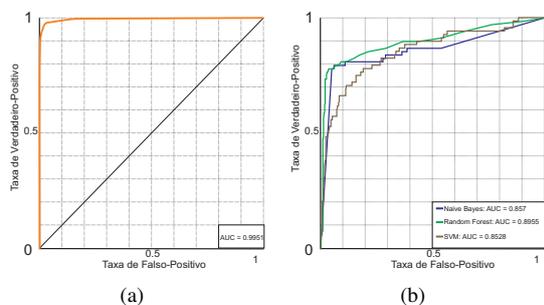


Figura 4: Figura 4(a): curva ROC para o classificador SVM na fase de classificação dos veículos. Figura 4(b): curvas ROC para os classificadores Naive Bayes, Random Forest e SVM na fase de detecção do uso de capacete.

De um total de 3245 imagens, 2576 imagens são *não-motocicletas* e 669 imagens são *motocicletas*. A classificação detectou corretamente 2541 *não-motocicletas* (Verdadeiro Negativo - VN) e 627 *motocicletas* (Verdadeiro Positivo - VP). O classificador errou em 77 ocasiões: 35 imagens de *motocicleta* foram classificados como *não-motocicleta* (Falso Negativo - FN) e 42 imagens de *não-motocicleta* foram classificados como *motocicleta* (Falso Positivo - FP). Para avaliar o desempenho do algoritmo, foram utilizadas as taxas de sensibilidade (S), especificidade (E), o valor preditivo positivo (VPP), o valor preditivo negativo (VPN) e acurácia (A), todos mostrados na Tabela 1.

Tabela 1: Resultado da classificação de veículos.

S	E	PPV	NPV	A
0,9502	0,9836	0,9377	0,9870	0,9767

Com o objetivo de ilustrar a performance da fase de classificação utilizamos as Curvas de Características de Operação do Receptor (*Receiver Operating Characteristic* - ROC), também conhecidas como curvas ROC. A Figura 4(a) mostra a curva ROC para o classificador SVM. Pode-se observar que a Área Sobre a Curva (Area Under Curve - AUC) é igual a 0,9951 sendo próximo de 1 (o resultado ideal).

Detecção de capacete

Na etapa de detecção de capacete usamos 471 imagens de motocicletas, isso foi necessário porque várias imagens tem resolução muito baixa e isso não possibilita a classificação da imagem. Para classificar as imagens utilizamos a mesma estratégia da classificação dos veículos, selecionando 10% do conjunto de dados para treinamento e os outros 90% para testes, repetindo esse processo 10 vezes.

O classificador Naive Bayes foi executado utilizando estimadores de classes. Valores de precisão dos estimadores numéricos são escolhidos com base na análise dos dados de treinamento. No classificador

Random Forest a profundidade máxima das árvores foi ilimitado e o número de árvores a serem gerados foi de 80. O classificador SVM foi executado utilizando uma função de kernel linear, os melhores resultados foram obtidos a partir dessas funções em comparação com funções de base radial e tangente sigmoide. O peso a ser usado para as classes foi de 2000, e o parâmetro de custo foi de 1. A Tabela 2 mostra os resultados da etapa de classificação. O melhor resultado foi obtido com o classificador Floresta Aleatória com uma taxa de acerto de 0,9423. O pior resultado foi obtido usando o classificador SVM (acurácia de 0,8913).

Tabela 2: Resultados para os classificadores Naive Bayes, Floresta Aleatória e SVM.

S	SP	PPV	NPV	A
Naive Bayes				
0.9478	0.7794	0.9603	0.7260	0.9224
Random Forest				
0.9791	0.7353	0.9542	0.8621	0.9423
SVM				
0.9765	0.4117	0.9034	0.7567	0.8913

A Figura 4(b) mostra as curvas ROC para os classificadores Naive Bayes, Random Forest e SVM, pode-se observar que o classificador *Random Forest* obteve uma melhor performance em relação aos demais (AUC = 0,857).

5 Conclusões e Trabalhos Futuros

Os resultados apresentados na Seção 4 se mostraram bastante satisfatórios para o problema de classificação de veículos, obtendo uma acurácia de 0.9767. Os resultados mostram que o descritor LBP prova ser robusto o suficiente para a problema em questão. O descritor LBP descreve o estrutura padrão da textura local, os padrões locais em motocicletas contribuem para a boa performance do classificador SVM. Outros descritores foram testados incluindo o descritores SURF, Haar Wavelet, HOG, Fourier e K-médias como mostrado em (Silva et al., 2012), mas esses descritores não obtiveram as mesmas taxas de sucesso e a performance computacional também não foi melhor.

Na detecção do uso de capacete pode-se observar que o classificador *Random Forest* obteve o melhor resultado, obtendo uma acurácia de 0.9380. Observa-se também que a combinação entre CHT, HOG e LBP retornou um resultado satisfatório na fase de detecção do uso de capacete por motociclistas. Isso se deve ao fato de utilizarmos tanto informações de borda(HOG), de textura(LBP) e informações geométricas da imagem(CHT).

Em relação aos trabalhos citadas na Seção 1.2 relacionados à detecção de capacete pode-se concluir que o trabalho aqui apresentado mostrou-se mais

robusto. Comparando a proposta aqui apresentada com a proposta apresentada por Chiverton (Chiverton, 2012), vemos que muito mais imagens são utilizadas na proposta aqui apresentada, tal quantidade ajuda a validar os testes realizados, bem como obter uma melhor análise dos resultados.

Os resultados apresentados são promissores, mas podem ser melhorados. Um passo importante para que os resultados possam ser melhorados reside na fase de captura de imagens, as quais precisam de uma melhor resolução ao ser capturadas. Muitas imagens não foram utilizadas na fase de detecção do uso de capacete devido a sua baixa resolução. Um dos trabalhos futuros é a detecção e conhecimento da placa do veículo, para isso é necessário uma imagem de alta resolução para reconhecer os caracteres da placa.

Referências

- Bouguet, J.-Y. (2000). Pyramidal implementation of the lucas kanade feature tracker, *Intel Corporation, Microprocessor Research Labs*.
- Chen, Z., Ellis, T. and Velastin, S. (2012). Vehicle detection, tracking and classification in urban traffic, *15th ITSC*, pp. 951–956.
- Chiu, C.-C., Ku, M.-Y. and Chen, H.-T. (2007). Motorcycle detection and tracking system with occlusion segmentation, *WIAMIS '07*, IEEE Computer Society, Washington, DC, USA, pp. 32–.
- Chiverton, J. (2012). Helmet presence classification with motorcycle detection and tracking, *Intelligent Transport Systems, IET* **6**(3): 259–269.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks, *Machine Learning* **20**: 273–297. 10.1007/BF00994018.
- Dalal, N. and Triggs, B. (2005). Histograms of oriented gradients for human detection, *In CVPR*, pp. 886–893.
- Helmet use among motorcyclists who died in crashes and economic cost savings associated with state motorcycle helmet laws - United States, 2008-2010*. (2012). *Technical Report 23*, Centers for Disease Control and Prevention. MMWR. Morbidity and mortality weekly report.
- Jain, A., Duin, R. P. W. and Mao, J. (2000). Statistical pattern recognition: a review, *IEEE Transactions on Pattern Analysis and Machine Intelligence* **22**(1): 4–37.
- Leelasantitham, A. and Wongseree, W. (2008). Detection and classification of moving thai vehicles based on traffic engineering knowledge, *ITST 2008*, pp. 439 –442.
- Número de Veículos Envolvidos por Finalidade Do Veículo* (2011). *Technical report*, Departamento Nacional de Infraestrutura de Transportes, Ministério dos Transportes.
- Ojala, T., Pietikinen, M. and Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions, *Pattern Recognition* **26**(1): 51–59.
- Otsu, N. (1979). A threshold selection method from gray-level histograms, *IEEE Transactions on Systems, Man and Cybernetics* **9**(1): 62–66.
- Silva, R., Aires, K., Veras, R. and Soares, T. S. K. L. A. (2012). Study and implementation of descriptors and classifiers for automatic detection of motorcycle on public roads, *2012 XXXVIII Conferencia Latinoamericana En Informatica (CLEI)*, pp. 1–10.
- Sobel, I. E. (1970). *Camara Models and Machine Perception*, Ph.d dissertation, Stanford University, Palo Alto, Calif.
- Sonoda, S., Tan, J. K., Kim, H., Ishikawa, S. and Morie, T. (2011). Moving objects detection at an intersection by sequential background extraction, *ICCV 2011*, pp. 1752 –1755.
- Suzuki, S. and Be, K. (1985). Topological structural analysis of digitized binary images by border following, *Computer Vision, Graphics, and Image Processing* **30**(1): 32–46.
- Takahashi, K., Kuriya, Y. and Morie, T. (2010). Bicycle detection using pedaling movement by spatiotemporal gabor filtering, *TENCON 2010 IEEE Region 10 Conference*, pp. 918 –922.
- Traffic Safety Facts: Research Note Motorcycle Helmet Use in 2011 - Overall Results* (2011). *Technical Report April 2012*, National Highway Traffic Safety Administration.
- Wen, C.-Y., Chiu, S.-H., Liaw, J.-J. and Lu, C.-P. (2003). The safety helmet detection for atm's surveillance system via the modified hough transform, *International Carnahan Conference on Security Technology*, pp. 364–369.
- Zivkovic, Z. (2004). Improved adaptive gaussian mixture model for background subtraction, *ICPR 2004*, Vol. 2, pp. 28 – 31 Vol.2.