

LOCALIZAÇÃO AUTOMÁTICA DE PLACAS DE VEÍCULOS EM IMAGENS BASEADA NO DETECTOR DE VIOLA-JONES

FRANCISCO ADRIANO NOBRE FREIRE*; JOSÉ EVERARDO BESSA MAIA*

**Estatística e Computação
Universidade Estadual do Ceará - UECE
Fortaleza - CE - Brasil*

Emails: adriano.nbfr@gmail.com, jose.maia@uece.br

Abstract— In the context of object detection in images, a topic that has been extensively studied is the automatic location of license plates, which has several potential applications. The objective of this work is to build a license plate detector that achieves good performance of accuracy and speed. Using an implementation of the Viola-Jones detection method as starting point (Viola and Jones, 2001), the detector is developed through some necessary changes to allow its application in the domain of licence plates. The main one is a combination of two cascaded classifiers that detect different kinds of plates and a simple decision classifier, eliminating the need to perform two scans of the image. Improvements are also made in the original detection mechanism, allowing gains in the relationship between accuracy and speed, and a reduction of false detections. The results of tests with the proposed detector are compared with those reported in papers related to this topic.

Keywords— Object detection in images, licence plate location, Viola-Jones detector, cascaded classifier

Resumo— No contexto da detecção de objetos em imagens, um tópico muito estudado é a localização automática de placas de veículos, com várias aplicações em potencial. O objetivo deste trabalho é construir um detector de placas de veículos que alcance bons desempenhos de acurácia e velocidade. Partindo de uma implementação do método de detecção de Viola-Jones (Viola and Jones, 2001), o detector é desenvolvido através de adaptações necessárias para viabilizar sua aplicação no domínio de placas de veículos. A principal delas é a combinação de dois classificadores em cascata que detectam tipos diferentes de placas e um classificador de decisão simples, eliminando a necessidade de fazer duas varreduras na imagem. São feitos ainda aprimoramentos no mecanismo de detecção original que permitem ganhos na relação entre acurácia e velocidade, além de uma redução de falsas detecções. Os resultados de testes com o detector proposto são comparados com os relatados em trabalhos relacionados ao tema.

Keywords— Detecção de objetos em imagens, localização de placas de veículos, detector de Viola-Jones, classificador em cascata

1 Introdução

Localização e reconhecimento de placas de veículos em imagens tem extensa gama de aplicações, incluindo emissão de multas de trânsito, controle de acesso a estacionamentos, rastreamento de veículos roubados, entre outras.

Nesse contexto, uma tarefa fundamental é determinar a região dentro da imagem onde está localizada a placa de veículo, caso esta exista. Diversas abordagens são adotadas para essa tarefa, sendo comum aquelas baseadas em detecção de bordas, usadas em (Hongliang and Changping, 2004), (Duan et al., 2005), (Mahini et al., 2006), (Jiao et al., 2009) e (Abolghasemi and Ahmadyfard, 2009). Em (Anagnostopoulos et al., 2006) foram usadas medições estatísticas para detectar variações abruptas das características locais nas regiões da imagem contendo placas. Já em (Wen et al., 2011), uma binarização aprimorada é seguida por uma análise de componentes conexas para destacar os caracteres contidos na placa.

A abordagem adotada neste trabalho é uma adaptação do método de detecção desenvolvido em (Viola and Jones, 2001), bastante popular por seu ótimo desempenho na detecção de faces. O detector de Viola-Jones, como é chamado, consiste numa cascata de classificadores que avaliam características baseadas nas *wavelets* de Haar, todos treinados pelo algoritmo de aprendizagem supervisionada *AdaBoost* (Freund

and Schapire, 1995) sobre um conjunto de imagens contendo exemplos positivos e negativos. A estrutura de cascata permite descartar rapidamente as regiões de fundo da imagem, focando processamento em áreas da com maior chance de conter o objeto. Este trabalho não descreve os detalhes do funcionamento do detector de Viola-Jones. O leitor interessado pode encontrá-lo em (Viola and Jones, 2001).

A Seção 2 descreve a construção do detector e a Seção 3 os resultados de avaliação de desempenho. Na Seção 4 o artigo é concluído.

2 Construção do Detector de Placas de Veículos

2.1 Treinamento do classificador

O detector de placas é construído a partir da implementação do detector de Viola-Jones disponível na biblioteca *OpenCV*. Para viabilizar o treinamento, as placas de veículos foram separadas em dois tipos: as placas cujo fundo é mais claro que os caracteres compõem o “tipo 1”, enquanto o “tipo 2” é formado pelas placas cujo fundo é mais escuro que os caracteres. Tal divisão é necessária devido à natureza das características usadas pelo classificador, pois os resultados da avaliação de uma mesma característica sobre placas de tipos diferentes tendem a ter sinais opostos. De fato, numa tentativa de treinar um classificador com ambos os tipos, o algoritmo parou de convergir ainda no quarto estágio, cujo classificador já usava mais de

15.000 características sem obter melhorias nas taxas de detecção e falso positivo.

Foram treinados portanto dois classificadores em cascata, cada um responsável por um tipo de placa. Para o treino de cada classificador, foram usadas 10.000 imagens positivas, às quais foram aplicadas rotações aleatórias dentro das seguintes faixas: -15° a $+15^\circ$ no eixo x , -30° a $+30^\circ$ no eixo y e -5° a $+5^\circ$ no eixo z . A restrição a estes valores foi definida de forma a cobrir a faixa de ângulos comumente encontrada nas imagens observadas. As imagens usadas no treinamento do classificador foram redimensionadas para uma resolução de 46×18 pixels. A Figura 1 exibe amostras de imagens positivas usadas no treinamento dos classificadores.



Figura 1: Duas amostras de imagens positivas usadas no treinamento.

O treinamento dos classificadores foi realizado com o auxílio de uma ferramenta que acompanha a biblioteca *OpenCV*. Seus parâmetros¹ foram configurados da seguinte forma: resolução base = 46×18 ; n° de exemplos positivos = 10.000; n° de exemplos negativos = 10.000; taxa de detecção mínima por estágio = 0,999; taxa de falso positivo máxima por estágio = 0,5; n° de estágios = 20; conjunto de características = estendido; n° de características por classificador fraco = 2; variante de Boosting = Gentle AdaBoost; limiar de peso relativo dos exemplos = 0,9; simetria vertical = não. Em ambos os treinamentos, as subimagens usadas como exemplos negativos em cada estágio foram extraídas de um mesmo conjunto contendo 5.000 imagens de cenas variadas.

Os parâmetros de taxas e número de estágios foram escolhidos para alcançar no treinamento taxas de detecção final de 0,98 ($\approx 0,999^{20}$) e falso positivo final de $9,5 \times 10^{-7}$ ($\approx 0,5^{20}$). O classificador de placas “tipo 1” resultante é constituído de 9 estágios e um total de 66 características (uma amostra destas é vista na Figura 2). Já o classificador de placas “tipo 2” obtido contém 7 estágios e 46 características no total.

2.2 Adaptação do detector ao domínio de placas

A abordagem mais óbvia para o uso de dois classificadores é simplesmente varrer a imagem duas vezes,

¹A descrição dos parâmetros usados pela ferramenta de treinamento está disponível na documentação da biblioteca *OpenCV*.



Figura 2: Algumas das características usadas no primeiro estágio do classificador de placas “tipo 1”.

um classificador de cada vez, e combinar os resultados, o que tende a duplicar o custo de detecção.

A solução encontrada foi treinar um classificador auxiliar simples, cuja meta é diferenciar um tipo de placa do outro. O número de estágios foi limitado a apenas 1, visando a eficiência. O resultado desse treinamento foi um classificador composto de apenas uma característica. A Figura 3 ilustra o funcionamento do classificador de placas final que combina os três classificadores treinados.

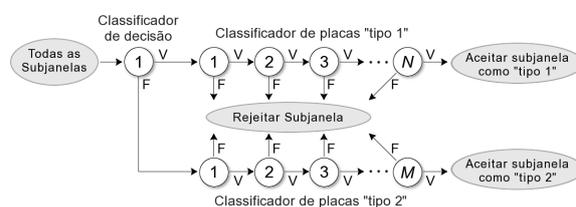


Figura 3: Esquema do classificador final combinado.

2.3 Aprimoramentos no mecanismo de detecção

O detector de Viola-Jones especifica dois parâmetros que controlam a varredura da imagem: o tamanho do passo e o fator de escala. Durante a varredura, a janela do detector é deslocada por uma quantidade de pixels definida pelo produto do passo pela escala atual. Para melhorar a acurácia do detector, pode-se usar fatores de escala cada vez menores, aumentando porém rapidamente o número de subjanelas testadas. Outra forma de realizar uma varredura mais precisa é diminuir o tamanho do passo. No detector original a mudança no passo afeta igualmente a varredura em ambas as dimensões, porém em alguns casos isso não é interessante.

No caso de uma imagem de placa de veículo, se comparados os histogramas horizontal e vertical da imagem binarizada, vê-se que o perfil vertical apresenta uma maior frequência de variação (Figura 4). Dessa forma, é mais adequado usar dois parâmetros de tamanho do passo, um para cada direção. Tal independência torna possível a obtenção de um ajuste mais “fino” no compromisso acurácia \times velocidade. Mesmo com um fator de escala não muito pequeno, pode-se conseguir boa acurácia sem grande prejuízo de velocidade ajustando os tamanhos dos passos horizontal e vertical adequadamente com valores menores que 1.

Uma consequência de se fazer uma varredura mais minuciosa são ocorrências de múltiplas de-

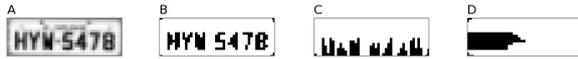


Figura 4: Projeções vertical (C) e horizontal (D) a partir da binarização (B) de uma imagem de placa (A).

tecções ligeiramente deslocadas para uma mesma instância (positiva ou não). O algoritmo do detector de Viola-Jones trata essa questão agrupando os retângulos vizinhos e retornando uma única detecção para cada grupo, cujas coordenadas são determinadas pela média das coordenadas dos retângulos no grupo. Durante essa etapa de agrupamento, uma importante informação pode ser guardada para posterior utilização: o número de retângulos vizinhos que são combinados para cada detecção retornada, ou peso da detecção.

Esse valor é usado para filtrar algumas falsas detecções, estabelecendo-se um peso mínimo para que o retângulo combinado seja retornado. Como falsas detecções tendem a ter pesos menores do que detecções corretas, um valor adequado para o peso mínimo consegue descartar a maior parte das falsas detecções enquanto conserva detecções verdadeiras.

Mesmo após a filtragem pelo peso, eventualmente pode haver interseções entre algumas das detecções remanescentes. Quando duas ou mais detecções de placas se interceptam, no máximo uma delas pode ser correta. Como detecções com maior peso têm mais chance de serem corretas, deve-se manter apenas as detecções cujo peso é o maior dentre as que se interceptam.

O detector de placas de veículos final é flexível, podendo alcançar um desempenho satisfatório em diversas aplicações através de ajustes adequados nos parâmetros listados a seguir:

- Tamanhos mínimo e máximo de uma detecção (se forem conhecidos para a aplicação, ajuda a reduzir o tempo de varredura da imagem);
- Fator de escala para crescimento da janela de detecção (geralmente entre 1, 1 e 1, 2);
- Tamanho dos passos horizontal e vertical (geralmente 1, podendo ser um pouco menor ou maior);
- Deslocamento mínimo da janela de detecção para cada um dos eixos x e y (geralmente entre 1 e 2);
- Peso mínimo de uma detecção para esta ser retornada (são comuns valores entre 2 e 4);
- Razão mínima entre o peso da detecção e o maior peso (numa interseção) para esta ser mantida (valores entre 0, 75 e 0, 85 são boas escolhas).

3 Resultados experimentais e discussão

3.1 Descrição do ambiente e conjuntos de teste

A implementação e testes do detector utilizou um computador pessoal com processador Core2 Duo de

2.8GHz e 2GB de memória RAM executando sistema operacional Windows 7. O código-fonte foi compilado usando o *Eclipse IDE para C++* (versão Helios SR2) e a biblioteca de código aberto *OpenCV* (versão 2.3). O detector foi treinado apenas com imagens de placas que obedecem o padrão atual (da resolução do CONTRAN), foram coletadas somente imagens de placas dentro do padrão ou próximas deste.

O primeiro conjunto de imagens de teste (chamado de A) foi obtido coletando-se principalmente imagens de veículos parados em estacionamentos, buscando semelhança de distâncias e ângulos com imagens obtidas de câmeras instaladas em cancelas. Algumas dessas imagens foram tiradas enquadrando mais de uma placa, visando testar múltiplas detecções. A fim de enriquecer mais o conjunto, foram incluídas imagens de veículos em vias públicas, a distâncias e ângulos similares aos das imagens obtidas no estacionamento.

Este conjunto apresenta boa variedade de iluminação (incluindo imagens noturnas e placas com sombreamento), ângulos e escalas, além de cenários de fundo complexos. As distâncias entre a câmera e a placa variam de 3 a 8 metros aproximadamente e os ângulos das placas estão dentro dos limites das imagens usadas no treinamento.

Todas as imagens foram obtidas na resolução de 800×600 pixels, com o auxílio de uma câmera digital *Canon PowerShot A590IS* com os ajustes no modo automático. O conjunto é formado por 150 imagens de veículos, contendo ao todo 155 placas com tamanhos que variam de 98×34 pixels a 236×78 pixels. A Figura 5 mostra algumas imagens desse conjunto.



Figura 5: Imagens do conjunto de teste A.

O segundo conjunto de teste (conjunto B) é composto de 200 imagens de veículos em movimento, cada uma contendo exatamente uma placa. Tais imagens foram cedidas pela empresa *Atlantis Tecnologia* (www.atlantistec.com.br). Todas as imagens deste conjunto foram obtidas por um equipamento instalado na margem de uma pista (em uma barreira de redução de velocidade). As imagens têm todas a resolução de 752×476 pixels, contendo veículos em dois ângulos, sendo um praticamente frontal e o outro mais inclinado lateralmente. São encontradas placas com

tamanhos entre 112×38 pixels e 152×54 pixels.

Boa parte das imagens desse conjunto contém dificuldades tanto para a detecção quanto para o reconhecimento. Muitas delas foram capturadas com superexposição à luz, fazendo com que o fundo da placa se confunda com a lataria dos veículos mais claros, além de provocar a erosão dos caracteres escuros enquanto dilata os brancos. Em algumas imagens são encontradas placas desgastadas ou amassadas, cujas superfícies apresentam sombreamentos irregulares. A Figura 6 exibe uma amostra desse conjunto.



Figura 6: Algumas imagens do conjunto de teste *B*.

3.2 Resultados: testes I

Além de avaliar o desempenho do detector desenvolvido para a tarefa de localização de placas de veículos, os testes realizados visam também avaliar os efeitos das melhorias deste frente ao detector original.

O primeiro teste realizado visa mensurar o efeito das melhorias propostas (melhor controle da varredura e pré-classificação das placas) com o detector na configuração original. Para este último, foram testadas cinco configurações para os parâmetros ajustáveis, com os parâmetros internos (fixos no código da implementação) inalterados. Já o detector proposto foi testado com apenas uma configuração. Tais configurações são listadas a seguir:

- Original #1: FE=1, 1; PM=2; TP=1; DM=2;
- Original #2: FE=1, 1; PM=3; TP=1; DM=2;
- Original #3: FE=1, 05; PM=2; TP=1; DM=2;
- Original #4: FE=1, 05; PM=3; TP=1; DM=2;
- Original #5: FE=1, 025; PM=3; TP=1; DM=2;
- Alteração Proposta: FE=1, 2; PM=3; TPH=0, 25; TPV=0, 75; DMH=1, 0; DMV=1, 5; RMP=0, 8;

onde FE é o fator de escala, PM é o peso mínimo, TP é o tamanho do passo (com suas variantes horizontal TPH e vertical TPV), DM é o deslocamento mínimo (com as variantes horizontal DMH e vertical DMV) e RMP é a razão mínima de peso para interseções. Para este teste foi utilizado apenas o conjunto de imagens A. Os resultados do teste são vistos na Tabela 1.

Tabela 1: Comparação entre o detector na configuração original e o mesmo com as melhorias propostas.

Config. do detector	Placas Det.	%	Falsas	Tempo (ms)
Original #1	131 / 155	84,5	14	64
Original #2	93 / 155	60,0	2	64
Original #3	149 / 155	96,1	66	117
Original #4	143 / 155	92,3	19	117
Original #5	154 / 155	99,4	41	248
Modificação proposta	154 / 155	99,4	19	120

Analisando os resultados, percebe-se que embora o detector original com fator de escala de 1,1 (menor que o usado normalmente para detectar faces) seja rápido, as taxas de detecção atingidas são muito baixas, obtendo 84,5% mesmo quando o parâmetro do peso mínimo é apenas 2. Quando ajustado para um fator de escala de 1,05 e peso mínimo 3, a taxa de detecção sobe para 92,3% com 19 falsas detecções, gastando um tempo médio de 117ms. Relaxando o peso mínimo para 2 melhora-se a taxa de detecção para 96,1%, aumentando porém o número de falsas detecções para 66. Baixando ainda mais o fator de escala para 1,025 e usando um peso mínimo de 3, obtém-se uma ótima taxa de detecção de 99,4%. Contudo, o número de falsas detecções de 41 ainda é alto, além do tempo gasto subir para 248ms, não sendo adequado para aplicações de tempo real. Esses resultados mostram o compromisso clássico entre verdadeiro positivo versus falso negativo. Um estudo da curva ROC será apresentado em trabalho mais extenso.

O detector proposto, por sua vez, atinge também a taxa de detecção de 99,4% com apenas 19 falsas detecções, mas desta vez gasta um tempo médio de 120ms (aceitável, considerando a resolução das imagens).

Comparando os valores para Original #1, Original #3 e o Detector Proposto (última linha), os resultados mostram claramente que as modificações propostas foram benéficas tanto do ponto de vista da acurácia quanto da redução de falsas detecções, fornecendo um ganho significativo na relação acurácia \times velocidade.

3.3 Resultados: testes II

Para o segundo teste, os dois conjuntos de imagens A e B são usados. O objetivo deste teste é avaliar melhor o desempenho do detector proposto sobre o conjunto completo de imagens. O teste ainda faz um novo comparativo, desta vez entre o detector proposto usando o classificador de decisão e uma variação do mesmo detector que usa a abordagem de duas varreduras independentes.

Visando ressaltar a importância da padronização das placas na busca por maior acurácia na detecção, o teste é realizado também com os subconjuntos B1 e B2 separadamente. O primeiro contém apenas as imagens de B com placas no padrão exato do treinamento, enquanto o segundo contém as demais imagens. Os

resultados do teste são mostrados na Tabela 2.

Tabela 2: Comparação entre versões do detector proposto: com classificador de decisão \times duas varreduras.

Conj. de Teste	Classificador de Decisão				Varred. Independentes			
	PD	%	FD	TM (ms)	PD	%	FD	TM (ms)
A	154/155	99,4	19	120	154/155	99,4	23	154
B1	56/56	100,0	9	69	56/56	100,0	14	90
B2	143/144	99,3	12	68	143/144	99,3	20	89
B1+B2	199/200	99,5	21	68	199/200	99,5	34	89
GERAL	353/355	99,4	40	91	353/355	99,4	57	117

Legenda: PD = placas detectadas; FD = falsas detecções
TM = tempo médio

Os resultados do detector proposto sobre o conjunto *A* já são conhecidos do primeiro teste. Para o conjunto *B1*, o detector localizou corretamente 100% das placas, retornando 9 falsas detecções e gastando tempo médio de 69ms. Já sobre o conjunto *B2* a taxa de detecção foi de 99,3%, com 12 falsas detecções e tempo médio de 68ms. Tal comportamento já era esperado, visto que o subconjunto *B1* contém apenas placas no mesmo padrão usado para treinar os classificadores. Para o conjunto *B* como um todo, a taxa de detecção alcançada foi de 99,5% e o tempo médio gasto ficou em 68ms.

Considerando toda a base de imagens de teste que contém no total 355 placas de veículos, foram corretamente localizadas 353, atingindo a taxa de detecção de 99,4%. Apesar de ter pouco significado (uma vez que os conjuntos possuem imagens de resoluções diferentes), o tempo médio gasto por imagem ficou em 91ms.

Da Tabela 2, os dois detectores apresentam mesma acurácia média com maior falso positivo para o detector de duas varreduras. Uma possível explicação para isso é que nas proximidades de uma placa, às vezes os dois classificadores retornam detecções vizinhas ligeiramente deslocadas, pois as partes claras de uma placa do tipo 1 podem ser confundidas com os caracteres da placa do tipo 2 e vice-versa. Assim, quando é usada uma única varredura, cada subjanela só pode ser associada a um único tipo, ajudando a evitar alguns casos de detecções sobrepostas de tipos diferentes.

Com relação ao tempo de processamento, para o conjunto *A* foram gastos em média 154ms por imagem, um tempo cerca de 28% maior que o gasto pelo detector proposto. Já para o conjunto *B* o tempo médio foi de 89ms, aproximadamente 31% maior que o do outro detector. No geral, o tempo médio foi de 117ms, cerca de 29% maior que o tempo médio geral do detector proposto.

Estes resultados mostram a validade da abordagem proposta de usar um classificador auxiliar de decisão. Obtem-se a mesma acurácia média, mas com ganhos expressivos no tempo de processamento e na redução do número de falsas detecções.

O detector desenvolvido teve um bom desempenho nos testes, deixando de detectar apenas duas placas num total de 355 e conseguindo localizar corretamente placas mesmo em imagens que apresentam dificuldades para a tarefa de detecção. Além disso, em todas as imagens com mais de uma placa o detector as localizou corretamente, mesmo em escalas diferentes. A Figura 7 mostra os dois casos em que não foram detectadas as placas, enquanto a Figura 8 ilustra exemplos de detecções corretas, algumas delas consideradas difíceis.

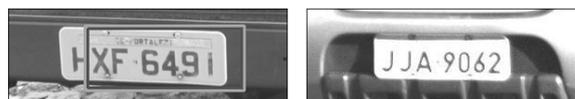


Figura 7: Os casos em que não houve detecção correta.



Figura 8: Exemplos de detecções corretas nos testes.

Na Figura 7, a imagem pertencente ao conjunto *A* (esquerda), não apresenta detecção correta porque esta foi descartada por apresentar um peso abaixo do mínimo especificado. Um teste com peso mínimo igual a 2 a teria detectado. Já na imagem da direita, a falta da detecção pode ter sido causada por uma combinação de fatores, como o padrão diferente do correto e a superexposição na captura da imagem.

Dentre as detecções mostradas na Figura 8, em algumas a placa apresenta dificuldades para a detecção, como sombreamento complexo causado por deformações na superfície da placa ou mesmo pelo ângulo de incidência da luz, onde os próprios caracteres fazem sombra na placa. Há também casos em que a imagem está completamente superexposta, onde a placa fica misturada ao fundo claro da lataria do veículo. A figura também ilustra um caso de múltiplas detecções na mesma imagem em diferentes escalas.

Embora não sejam plenamente comparáveis, a Tabela 3 mostra as taxas de detecção e os tempos de processamento de cada um dos trabalhos relacionados, juntamente com os registrados nos testes desta seção.

A tabela mostra que o detector de placas desenvolvido apresenta uma taxa de detecção de 99,4% que é apenas ligeiramente menor que a maior taxa relatada dentre os trabalhos relacionados ao tema (99,6%). O trabalho que apresenta a maior taxa também relata o segundo menor tempo médio de processamento (100ms), superado apenas pelo detector proposto, cujo tempo médio de 91ms se mostra adequado a aplicações de tempo real.

Cabe observar que o teste com o conjunto *A*

Tabela 3: Comparativo entre os resultados dos testes com o detector proposto e os relatados em trabalhos relacionados ao tema.

Método de Detecção	Imagens de Teste	Taxa Det.	Tempo Méd. (ms)
Hongliang & Changping, 2004	9825	99,6%	~ 100
Duan et al., 2005	805	98,8%	~ 650
Mahini et al., 2006	269	96,5%	~ 300
Anagnostopoulos et al., 2006	1334	96,5%	~ 111
Jiao et al., 2009	5026	95,9%	~ 125
Abolghasemi & Ahmadyfard, 2009	~700	96,7%	~ 1100
Wen et al., 2011	9026	97,2%	~ 158
Detector Proposto	350	99,4%	~ 91

(composto de imagens com resolução de 800×600 pixels), no qual tentava-se localizar placas numa ampla faixa de tamanhos, acabou por elevar o tempo médio. Em imagens de situações práticas, como as contidas no conjunto B , a faixa de tamanhos das placas é razoavelmente estreita. Nesses casos, ajustes adequados no detector podem fazer o tempo médio de processamento girar em torno de 50ms.

4 Conclusão

Com relação ao problema de reconhecimento de placas de licença em veículos, esta pesquisa constatou (junto a uma empresa detentora e compradora de software especializado) que a localização da placa em imagens confusas é a etapa geradora do maior número de erros. Uma vez localizada a placa, sendo os caracteres de forma padronizados, a leitura dos dígitos e letras apresenta alta precisão.

A partir da implementação do detector de Viola-Jones disponível na biblioteca *OpenCV*, um eficiente e eficaz detector de placas de licença de veículos foi desenvolvido. O detector final é flexível, podendo ser sintonizado para obter bons desempenhos de acurácia e velocidade em diversas aplicações. Atende requisitos de tempo real para a aplicação em foco, com taxa de detecção (99,4%) e taxas de falso positivo e falso negativo da ordem de 0,5%.

O projeto completo deste trabalho (em andamento) inclui permitir a localização de placas que apresentem ângulos de inclinação maiores do que os usados aqui, a integração com um método eficaz de segmentação da placa do veículo, seguido do reconhecimento dos dígitos da placa, chegando a um sistema completo de reconhecimento automático de placas de veículos que apresente um bom desempenho global.

Referências

Abolghasemi, V. and Ahmadyfard, A. (2009). An edge-based color-aided method for license plate detection, *Image and Vision Computing* **27**(8): 1134–1142.

Anagnostopoulos, C. N. E., Anagnostopoulos, I. E., Loumos, V. and Kayafas, E. (2006). A license plate-recognition algorithm for intelligent transportation system applications, *IEEE Transactions on Intelligent Transportation Systems* **7**(3): 377–392.

Duan, T. D., Du, T. L. H., Phuoc, T. V. and Hoang, N. V. (2005). Building an automatic vehicle license plate recognition system, *Proceedings of International Conference in Computer Science - RIVF'05*, Can Tho, Vietnam, pp. 59–63.

Freund, Y. and Schapire, R. E. (1995). A decision-theoretic generalization of on-line learning and an application to boosting, *Computational Learning Theory: Eurocolt 95*, Vol. 904, Springer-Verlag, pp. 23–37.

Hongliang, B. and Changping, L. (2004). A hybrid license plate extraction method based on edge statistics and morphology, *Proceedings of the 17th International Conference on Pattern Recognition*, Vol. 2, pp. 831–834.

Jiao, J., Ye, Q. and Huang, Q. (2009). A configurable method for multi-style license plate recognition, *Pattern Recognition* **42**(3): 358 – 369.

Mahini, H., Kasaei, S., Dorri, F. and Dorri, F. (2006). An efficient features - based license plate localization method, *Proceedings of 18th International Conference on Pattern Recognition*, Vol. 2, Hong Kong, pp. 841–844.

Viola, P. and Jones, M. (2001). Rapid object detection using a boosted cascade of simple features, *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition*, Vol. 1, IEEE Computer Society, Kauai, Hawaii, pp. 511–518.

Wen, Y., Lu, Y., Yan, J., Zhou, Z., von Deneen, K. M. and Shi, P. (2011). An algorithm for license plate recognition applied to intelligent transportation system, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 12, pp. 830–845.