

Extração de Informações de Cor e Forma para Detecção de Placas de Trânsito em Imagens

Ricardo Cezar B. Rodrigues (bolsista CAPES), Sergio Roberto M. Pellegrino (orientador),
Carlos Henrique Q. Forster (orientador)
Instituto Tecnológico de Aeronáutica - ITA
Divisão de Computação
Praça Marechal Eduardo Gomes, 50 - São José dos Campos, Brasil
{rcezar, pell, forster}@ita.br

Resumo

*O reconhecimento automático de sinais de trânsito prova-se útil na concepção de sistemas de apoio à motoristas ou até mesmo de veículos autônomos. No entanto, a capacidade da visão computacional ainda é muito baixa quando comparada ao sistema de visão humana, devido a quantidade de informação que esta pode processar em tempo real e lidar com a complexidade e variação de ambientes. Desta forma, os sistemas de visão computacional reconhecedores de objetos devem utilizar técnicas que evitem processamento desnecessário. Este trabalho propõe um modelo de detecção de regiões candidatas a placas em imagens baseado em informações de cor e forma, onde o objetivo é eliminar regiões da imagem que não têm chances de conter placas de trânsito antes da fase de reconhecimento. O trabalho também apresenta um experimento com os algoritmos supervisionados *k-nn* e *Redes bayesianas* e seus resultados preliminares que atingem até 90% de acertos.*

1. Introdução

As placas de trânsito são projetadas para se destacar em ambientes poluídos visualmente, possuindo características como forma, cor, figuras geométricas em contraste com o ambiente em que se encontram. Em geral podem ser facilmente reconhecidas por seres humanos, pois, através da percepção visual, uma pessoa é capaz de identificar um sinal de trânsito pelo seu contraste, já que sua atenção será muito mais despertada quanto mais contraste existir entre os estímulos.

Trabalhar com imagens digitais de placas para um sistema automático de identificação pode não ser uma tarefa trivial, pois é necessária uma análise minuciosa sobre a va-

riação de cores, iluminação, ambiente entre outros fatores. Devido a exposição das placas a diversas condições climáticas elas sofrem degradação e apresentam variação em sua coloração e até mesmo em suas formas, ver Figura 1, ou seja, um mesmo tipo de placa pode apresentar características diferentes.



Figura 1. Imagem de placa degradada.

Este trabalho propõe um modelo para detecção de placas em imagens baseado na percepção humana. Como as placas geralmente são pintadas com cores vibrantes em contraste com a cor branca ou preta, o modelo utiliza informações de cor para segmentar possíveis regiões de interesse e em seguida extrair características de forma dos objetos segmentados. Algoritmos simples são utilizados para a classificação de regiões como candidatas ou não a placas. A seção seguinte descreve alguns trabalhos correlatos, seguida das seções experimentos e considerações finais.

2. Trabalhos Correlatos

A detecção de placas de trânsito aparece como fase inicial em muitos trabalhos de identificação de sinais de trânsito. O objetivo desta fase é evitar o processamento desnecessário em regiões da imagem que não possuem placas ou objetos de interesse.

Muitos trabalhos recentes apresentam o uso de informações de cores para identificar regiões candidatas a placa,

[1],[4]. Em [5] se apresenta um modelo de detecção de sinais de trânsito baseado na visão humana que extrai informações de cor e atributos de forma. O modelo de cores LCH (Lightness, Chroma, Hue) foi utilizado para segmentar a regiões da imagem por cor. A extração de características dos formatos externos das placas (círculo, retângulo ou triângulo) utilizou histogramas de medidas de orientações de verticalidade e horizontalidade detectadas através de uma máscara com 49 nós sensores. O Trabalho também possui um módulo de reconhecimento e utilizou 98 sinais de trânsito britânicos com taxa de acerto de 95%.

Em [3] é apresentado um módulo para o reconhecimento de sinais de trânsito baseado na detecção de formas. No módulo, retângulos são detectados através de detecção de bordas e círculos são identificados através da transformada Hough. Embora a utilização de métodos robustos como o de Hough pode ser lenta para processar grandes imagens [6], o método foi capaz de obter taxa de acertos de até 90%.

3. Experimento

Os experimentos realizados neste trabalhos consistem basicamente nas etapas de construção do *dataset* e da classificação de imagens através de algoritmos supervisionados e treinados com um conjunto de amostras.

3.1. Conjunto de treinamento (*Dataset*)

O conjunto de amostras (*dataset*) para a base de aprendizagem foi construído a partir de 97 fotos de placas de trânsito com resolução 480X360 *pixels*. Diversas condições de iluminação foram testadas porque as imagens foram obtidas sobre diferentes níveis de incidência da luz solar num mesmo dia.

As imagens deste trabalho possuem amostras de 12 tipos de placas, porém como já dito anteriormente este trabalho não será reconhecer cada tipo de placa e sim regiões candidatas a placas, assim cada amostra será rotulada com uma das seguintes classes: círculo, triângulo, losângulo ou octógono, ver Figura 2.

3.1.1. Segmentação Para este processo o primeiro passo foi eliminar ruídos da imagem, o que foi obtido com a utilização de um filtro de suavização. Após este pré-processamento um filtro de cor foi utilizado com o intuito de identificar regiões de contraste das placas, trabalhando-se com as cores vermelha e amarela, comumente presentes nas na regiões de placas nas imagens.

Neste segmento do trabalho adotou-se os componentes matiz (hue) e saturação (saturation) do modelo de cores HSB, este modelo foi utilizado devido a independência entre seus canais, diferente de outros modelos como RGB [5]. Para criar o filtro de cor foram medidos os intervalos de



Figura 2. Exemplos de placas do banco de amostras.

matiz e saturação das cores vermelho e amarelo, que aparecem nas placas em parte das amostras. Este passo foi realizado com o auxílio da ferramenta IMAGEJ¹. Os intervalos encontrados podem ser visualizados na Tabela 1

	Vermelho	Amarelo
Matiz	0.43 - 0.90	0.37 - 0.98
Saturação	0.00 - 0.05 0.93 - 1.00	0.11 - 0.15

Tabela 1. Intervalo (*threshold*) para as cores amarelo e vermelho nas camadas matiz e saturação do modelo HSB.

A Tabela 1 apresenta dois intervalos de saturação para a cor vermelha, o segundo intervalo teve que ser estabelecido para algumas imagens que foram capturadas com menor incidência de luz solar sobre as placas. Este ocorrido deve-se a simples variações de iluminação causadas por sombras de objetos ou até mesmo de nuvens que obstruíram parte dos raios solares durante alguns minutos na amostragem. Apesar da variação de luminosidade a camada matiz não foi modificada devido a sua independência.

Após obter os intervalos dos valores de matiz e saturação que representam as cores vermelha e amarela. Uma aplicação na linguagem Java foi desenvolvida utilizando o pacote IMAGEJ para obter as camadas do modelo HSB baseado no *plugin color segmentation*² e filtrar apenas as informações nos intervalos encontrados na Tabela 1.

Desta forma, novas imagens foram geradas automaticamente, já segmentadas e binarizadas. Os resultados foram

1 Software de processamento de imagens em Java e código livre, <http://rsb.info.nih.gov/ij/>
 2 *Plugin Color Segmentation* para o software IMAGEJ por Maria E. Barrilla, University of Birmingham, UK

satisfatórios e eliminaram grande parte de regiões nas imagens que não tinham correlação com placas. Exemplos de imagens geradas pelo filtro podem ser visualizadas na Figura 3.



Figura 3. Exemplos de saída após a segmentação por cor.

3.1.2. Extração de Atributos de forma Esta fase do trabalho teve como objetivo utilizar as imagens já segmentadas e binarizadas para extrair características que representem as formas geométricas das regiões de contorno das placas. Antes da extração ainda existe o pré-processamento realizado pelo *plugin* do IMAGEJ *shapedescriptor* [7] para identificar as bordas dos objetos segmentados, e, através dos pontos que compõem a borda de cada objeto, extrair os atributos: área, perímetro, ângulo, fator de forma, circularidade, compacticidade, proporção (*aspect ratio*), maior e menor eixo.

3.1.3. Seleção de atributos Uma análise foi realizada a fim de reduzir a quantidade de atributos que possam comprometer a interpretação dos resultados. Para tornar a caracterização dos objetos invariante à rotação o atributo ângulo que descreve o gradiente não foi utilizado no conjunto de dados, pois as imagens de placas podem ser capturadas de diferentes ângulos ou podem estar fixadas com ângulos diferentes.

O atributo área também não foi utilizado na base de dados, pois objetos que foram segmentados e não são placas podem conter áreas semelhantes à área de placas nas imagens, além disso, se as imagens forem capturadas a uma distância padrão o atributo área torna o modelo variante à escala.

3.1.4. Análise de regressão linear múltipla Uma análise de regressão múltipla com os atributos restantes foi adotada para determinar os atributos mais e menos significantes e assim reduzir o número de atributos e diminuir o tempo de

processamento. A regressão foi realizada no WEKA³ com uma configuração para seleção de parâmetros que retornou uma equação com apenas quatro atributos: Fator de Forma 1, Compacticidade 2, Proporção 3 e o próprio menor eixo.

$$\frac{4\pi area}{\sqrt{perimetro}} \quad (1)$$

$$\frac{\sqrt{\frac{4\pi}{area}}}{maiooreixo} \quad (2)$$

$$\frac{maiooreixo}{menoreixo} \quad (3)$$

3.2. Avaliação dos algoritmos de classificação

Os experimentos foram conduzidos com a intenção de avaliar a eficácia e eficiência de algoritmos simples de classificação utilizando os atributos de forma extraídos das regiões segmentadas por cor para a detecção de regiões candidatas a placas de trânsito durante a fase de geração do *dataset*.

3.2.1. Configurações Foram utilizadas as implementações dos algoritmos supervisionados k-nn e redes bayesianas da versão 3.5.2 do software WEKA com suas configurações padrões, detalhes sobre os algoritmos utilizados podem ser encontrados em [2]. Para cada algoritmo foi utilizada uma validação cruzada com 10 dobras do conjunto de dados para uma estimativa mais confiável da generalização do erro. Os algoritmos tiveram como entrada 147 instâncias de 5 classes que podem ser visualizadas na Tabela 2.

	N. Instâncias
Círculo	33
Octógono	7
Losango	31
Triângulo	11
Não-placa	65
Total	147

Tabela 2. Distribuição das instâncias do *dataset*.

3.2.2. Experimento A validade dos resultados é avaliada através da matriz de confusão e da proporção de falsos positivos e falsos negativos. A Tabela 3 apresenta os resultados de classificação, tempo de treinamento e teste dos algoritmos considerando as 5 classes do *dataset*.

³ Coleção de algoritmos para problemas de mineração de dados implementados em Java e código livre, www.cs.waikato.ac.nz/ml/weka/

	T. Trein.	T. Test.	Inst. Corretas
K-nn	0.0001s	0.0017s	89.79%
R. bayesianas	0.0022s	0.0011s	85.71%

Tabela 3. Tempo de treinamento e teste e percentual de instâncias classificadas corretamente pelos classificadores.

a	b	c	d	e	← classificado como
32	0	1	0	0	a = círculo
1	2	1	0	3	b = octógono
1	1	25	3	1	c = losango
0	0	0	11	0	d = triângulo
0	1	2	0	62	e = não placa

Tabela 4. Matriz de confusão do classificador K-nn.

É possível observar nas Tabelas 4, 5 pelas matrizes de confusão que grande parte das amostras da classe octógono foram classificadas incorretamente. Isto significa que as amostras desta classe não são suficientes para discriminá-la. Já as instâncias de triângulos não apresentam classificações incorretas em ambos classificadores.

Considerando-se que em uma fase posterior serão reconhecidas as regiões detectadas como placas, pode-se então relevar as instâncias que foram confundidas com outras instâncias de uma outra classe de placa, ou seja, reduzir as classes apenas à "placa" ou "não-placa". Desta forma não haveria problema em ter, por exemplo, uma classificação incorreta de uma placa triangular como circular, já que as duas são placas e possivelmente serão identificadas na fase de reconhecimento onde se levará em consideração outras características da região candidata.

a	b	c	d	e	← classificado como
30	0	2	0	1	a = círculo
3	0	1	0	3	b = octógono
0	0	24	5	2	c = losango
0	0	0	11	0	d = triângulo
2	2	0	0	61	e = não placa

Tabela 5. Matriz de confusão do classificador Redes Bayesianas.

4. Conclusões e Trabalhos Futuros

A grande quantidade de instâncias classificadas corretamente pelo algoritmos de classificação, assim como os tempos de treinamento e teste mostram que o modelo proposto permitiu obter resultados satisfatórios. O modelo de cor HSB mostrou-se eficiente e eficaz na fase de segmentação e os atributos selecionados através de regressão mostraram-se capazes e suficientes para discriminar as formas geométricas encontradas nas regiões de bordas das placas.

Como as amostras foram capturadas em um período de algumas horas num mesmo dia, este banco de amostras não caracteriza as diversas situações climáticas em que as placas poderiam estar inseridas. A variação climática pode ser um dos grandes problemas na identificação de placas pois uma imagem de uma placa em um dia ensolarado e uma outra imagem desta mesma placa em um dia chuvoso podem apresentar características como, cor e iluminação muito diferentes.

Em trabalhos futuros, pretende-se aumentar o conjunto de amostras, principalmente nas classes com pouca representatividade. Além disso obter imagens em diferentes condições climáticas para validar o segmentação pelo modelo de cor HSB para diferentes intervalos de cores em um mesmo conjunto de amostras.

Referências

- [1] V. Andrey and K. H. Jo. Automatic detection and recognition of traffic signs using geometric structure analysis. *SICE-ICASE, 2006. International Joint Conference*, pages 1451–1456, Oct. 2006.
- [2] R. Duda, P. Hart, and D. Stork. *Pattern Classification*. Wiley, 2001.
- [3] A. H. Fabien Moutarde, Alexandre Bargeton and L. Chanussot. Modular traffic signs recognition applied to on-vehicle real-time visual detection of american and european speed limit signs. *proceedings of 14th World congress on Intelligent Transportation Systems (ITS)*, pages 9–13, october 2007.
- [4] C.-Y. Fang, S.-W. Chen, and C.-S. Fuh. Road-sign detection and tracking. *Vehicular Technology, IEEE Transactions on*, 52(5):1329–1341, Sept. 2003.
- [5] X. Gao, L. Podladchikova, D. Shaposhnikov, K. Hong, and N. Shevtsova. Recognition of traffic signs based on their colour and shape features extracted using human vision models. 17(4):675–685, August 2006.
- [6] S. Maldonado-Bascon, S. Lafuente-Arroyo, P. Gil-Jimenez, H. Gomez-Moreno, and F. Lopez-Ferrer. Road-sign detection and recognition based on support vector machines. *Intelligent Transportation Systems, IEEE Transactions on*, 8(2):264–278, June 2007.
- [7] J. P. O. L. I. Syverud Kristin, Chinga Gary and W. Knut. Analysis of lint particles from full-scale printing trials. *Ap-pita Journal: Journal of the Technical Association of the Australian and New Zealand Pulp and Paper Industry*, pages 286–290, july 2007.