

Inventário Automático de Sinais de Trânsito: um Sistema de Mapeamento Móvel *

Luís Paulo Santos João Luís Sobral
Departamento de Informática
Universidade do Minho
Campus de Gualtar, 4710-057 Braga, Portugal
psantos@di.uminho.pt, jls@di.uminho.pt

Resumo

A inventariação e georeferenciação do mobiliário urbano é um processo fundamental para entidades responsáveis pela gestão destas infra-estruturas, fornecendo informação indispensável para o apoio à tomada de decisões. No entanto, o levantamento e processamento da informação necessária para esta inventariação são processos morosos devido à extensão da malha urbana. A utilização de Sistemas de Mapeamento Móveis (SMM) permite acelerar este levantamento, mas a informação deve ainda ser processada para localizar e identificar os objectos de interesse. Este artigo apresenta uma abordagem baseada em técnicas de Visão por Computador, que permite automatizar a localização e identificação de mobiliário urbano numa sequência de imagens obtida com um SMM. Esta abordagem restringe-se, nesta fase de estudo de viabilidade e prototipagem, à sinalização vertical de trânsito. A principal contribuição deste artigo consiste na introdução de um novo método de localização e identificação de sinais de trânsito em ambientes exteriores, baseado na segmentação pela cor, reconhecimento de formas usando assinaturas de contornos e identificação do sinal através de correlação monocromática. Os resultados obtidos demonstram uma taxa de sucesso global na ordem dos 75% e um aumento muito significativo de produtividade na fase de processamento de informação.

Palavras-Chave

Visão por Computador, Segmentação, Identificação de Objectos, Sistema de Mapeamento Móvel, Georeferenciação.

1. INTRODUÇÃO

A inventariação e georeferenciação de mobiliário urbano é um processo que se reveste da maior importância para diversas entidades, pois permite um maior conhecimento, e logo tomadas de decisão e intervenção mais informadas, de vários aspectos do urbanismo. A lista de itens passíveis de inventariação é imensa e limitada apenas pela imaginação e área de interesse da entidade que realiza o inventário; podemos referir, por exemplo, sinalização de trânsito horizontal e vertical, tipo de tapete das faixas de rodagem, marcos de correio, caixas de semáforos ou electricidade, etc.

O levantamento da informação necessária para proceder a esta inventariação é um processo moroso, pois as malhas urbanas cobrem centenas de quilómetros, que necessitam de ser percorridos cuidadosamente para localizar, identificar e georeferenciar os objectos de interesse. Os Sistemas de Mapeamento Móvel (SMM), consistindo em veículos equipados com câmaras de filmar e material de geo-posicionamento, são uma opção comum para pro-

ceder a este levantamento quando o meio e os objectivos o permitem. Uma vez na posse de sequências de vídeo, etiquetadas com informação de geo-posicionamento, é ainda necessário percorrer estes dados para localizar os objectos de interesse e proceder à sua inventariação e georeferenciação. Este processo é tradicionalmente realizado por um operador humano, através de inspecção visual. Este operador visualiza horas de vídeo para detectar os objectos de interesse. Se estes se encontrarem dispersos no vídeo, muito deste tempo é passado sem localizar qualquer evento relevante, com a consequente baixa produtividade e ocorrência de erros humanos devidos à fadiga e ao tédio.

A GEONAV, empresa do ramo dos Sistemas de Informação Geográfica, realiza frequentemente trabalhos desta natureza para entidades encarregues da gestão de infra-estruturas urbanas, tais como estradas, redes de distribuição de energia eléctrica, sinalização do trânsito, comunicações, etc. Confrontada com os problemas de produtividade e erro acima descritos, contactou a Universidade do Minho, no sentido de realizar um protótipo que avalie a viabilidade de automatização do processo de localização e identificação de itens do mobiliário urbano

*Este trabalho foi parcialmente suportado pelo projecto "SIGMA - Sistema de Georeferenciação Móvel Assistido por imagem", financiado pela Agência de Inovação (POCTI 2.3 / POSI 1.3).

em sequências de imagens obtidas usando um SMM. Este artigo apresenta e avalia a abordagem desenvolvida para realizar essa automatização. Esta abordagem, baseada em técnicas de Visão por Computador, deverá resultar num aumento da produtividade dos operadores encarregues desta tarefa. Para efeitos de estudo de viabilidade, o mobiliário urbano em análise foi restringido à sinalização vertical de trânsito. No entanto, as opções tomadas não comprometem a extensão desta abordagem a outro tipo de objectos de interesse com características similares.

A detecção de sinais de trânsito em exteriores constitui um grande desafio para a área de Visão por Computador devido ao grande número de variáveis não controladas, entre as quais se destacam a variabilidade nas condições de iluminação, o estado de conservação e localização dos sinais e as variações de escala originadas pelas condições de captura de imagem. A principal contribuição deste artigo consiste na introdução de um novo método de localização e identificação de sinais de trânsito em ambientes exteriores, baseado na segmentação pela cor, reconhecimento de formas usando assinaturas de contornos e identificação do sinal através de correlação monocromática.

A próxima secção apresenta uma visão global do sistema. A terceira secção descreve a abordagem proposta. A avaliação experimental desta abordagem é feita na secção seguinte. A última secção apresenta as conclusões obtidas no final do projecto.

2. VISÃO GLOBAL DO SISTEMA

O principal objectivo deste projecto é combinar o potencial de um Sistema de Mapeamento Móvel (SMM) com técnicas de Visão por Computador para localizar e classificar automaticamente itens de mobiliário urbano, em particular, sinais de trânsito. O SMM utilizado é uma carinha modificada (figura 1), equipada com duas câmaras de vídeo digital, uma unidade de GPS e uma unidade de medição inercial (IMU).

Figura 1. Carrinha modificada utilizada como Sistema Móvel de Mapeamento.



Para proceder ao levantamento e referenciação dos sinais de trânsito existentes numa determinada zona de interesse a carrinha percorre essa zona, armazenando o vídeo dig-

ital. Cada imagem do vídeo é etiquetada com o tempo fornecido pelo sistema de GPS para que a posição e atitude do veículo possam ser posteriormente determinadas com grande precisão. A integração dos dados diferenciais obtidos pelo GPS com os dados fornecidos pela IMU permite medir o posicionamento do veículo com uma precisão inferior a um metro, ultrapassando assim erros de leitura do GPS devidos a obstrução do sinal. Efectivamente, em ambientes urbanos, o GPS não mantém nem uma taxa constante de aquisição de informação, nem uma precisão constante, devido a múltiplas obstruções do sinal. Os dados fornecidos pela IMU (atitude e velocidade) também divergem lentamente, garantindo intervalos de precisão conhecidos apenas durante um curto intervalo de tempo. Mas com a integração dos dados de ambos os sensores, realizada usando um filtro de Kalman [Tomé 00], a precisão e fiabilidade do sistema de geoposicionamento aumentam drasticamente, bem como a taxa de aquisição da informação, ultrapassando o 1 Hz possível com a maioria dos receptores de GPS. As relações entre o sistema de georeferenciação e o sistema de aquisição de imagem são esquematizadas na figura 2.

Figura 2. Integração do sensores de georeferenciação.




As posições relativas dos vários componentes do sistema mantêm-se constantes durante todo o trabalho de campo e são cuidadosamente determinadas durante a fase de calibração. O sistema de eixos referencial do veículo coincide com o referencial da IMU e todos os parâmetros são medidos relativamente a estas coordenadas. De particular importância é a determinação dos parâmetros intrínsecos e extrínsecos das câmaras, tais como distância focal, posições e orientações relativas. Estes são determinados usando técnicas de processamento de imagem e calibragem descritas em [Madeira 05].

Uma vez recolhidos os vídeos da zona a analisar, com as imagens devidamente etiquetadas com a respectiva posição e orientação, esta informação é posteriormente processada para localizar e identificar nas imagens o mobiliário urbano relevante - no caso em apreciação, sinalização de trânsito vertical. Este processamento era tipicamente realizado por um operador humano, que localizava e classificava os sinais de trânsito por inspecção visual, resultando num processo moroso, dispendioso e sujeito a erros causados por vários factores humanos, tais como fadiga. O objectivo do projecto financiado pela Agência de Inovação e descrito neste artigo é precisamente automatizar este processo de localização, classificação e georeferenciação de sinais de trânsito presentes em sequências de vídeo. As

técnicas de Visão por Computador usadas para atingir este objectivo são descritas em detalhe nas secções seguintes.

O resultado deste processo automático consiste nos identificadores dos sinais detectados e respectivas coordenadas no espaço da imagem. Estas são convertidas em coordenadas do mundo, usando o conhecimento sobre os parâmetros das câmaras e explorando o facto de que cada objecto de interesse é detectado em várias imagens consecutivas (figura 3). A abordagem utilizada parte de um conjunto alargado de coordenadas no espaço da imagem (15 .. 20 imagens) e aplica o método dos mínimos quadrados para satisfazer a condição de colinearidade [Madeira 05, Wolf 00]. Particularmente importante é o valor esperado da precisão das coordenadas absolutas, nomeadamente a precisão linear e angular. O sistema de geoposicionamento atrás descrito apresenta um desvio padrão linear de cerca de um metro e um desvio angular inferior a um minuto. A este erro angular deve ainda ser adicionado o erro associado à selecção dos pixels no processo de localização de objectos de interesse, que depende da dimensão dos pixels e da distância focal. No geral, o erro linear associado ao sistema de geoposicionamento é transportado para as coordenadas absolutas, sofrendo ainda uma degradação adicional devido à resolução finita da imagem.

Figura 3. Cálculo das coordenadas absolutas.



3. LOCALIZAÇÃO E CLASSIFICAÇÃO AUTOMÁTICAS DE SINAIS DE TRÂNSITO

A localização e classificação de sinais de trânsito está dividida em 3 fases:


segmentação baseada na cor – selecção de regiões da imagem com grande probabilidade de conter sinais, baseada na cor, tamanho e localização destas regiões;

deteccção de formas – selecção de regiões com formas pré-definidas, nomeadamente, círculos, triângulos e quadrados;

classificação – comparação de regiões com padrões pré-definidos com o objectivo de identificar o respectivo conteúdo.

Este processo automático de segmentação e classificação é completamente autónomo, não requerendo nenhuma intervenção por parte do operador humano. Uma vez que este sistema está orientado para os sinais de trânsito verticais, uma base de dados contendo pictogramas destes sinais foi analisada, tendo-se concluído que as características que mais os distinguem de outros objectos num cenário urbano são a cor e a forma. O desenvolvimento do sistema foi orientado no sentido de detectar estas características, dividindo o problema da deteção em 2 fases: deteção da cor, característica interna, e deteção da forma, característica externa.

Figura 4. Árvore de deteção.



3.1. Segmentação Baseada na Cor

A deteção automática de objectos requer o conhecimento de um número significativo de características que distingam um objecto de interesse tanto do fundo como de outros objectos presentes na imagem [Yilmaz 06]. Na abordagem que apresentamos esta distinção é baseada na cor das regiões, na sua dimensão e na sua localização dentro da imagem.

A análise dos vários pictogramas presentes em sinais de trânsito permitiu concluir que a cor é uma característica fundamental para localizar sinais dentro de uma imagem. No entanto, o espaço de cor RGB não é uma boa escolha para segmentar uma imagem, por várias razões: os três canais RGB estão fortemente correlacionados, as condições de iluminação no momento de aquisição das imagens não estão sob o controlo do operador (resultando em grandes variações de luminância) e as cores dos sinais tendem a degenerar com o tempo e os elementos. O espaço de cor HSI, por outro lado, representa diferentes componentes da informação em cada canal [Arnoul 96, Hibi 96, Piccioli 96], e concentra a informação dependente da iluminação no canal I; H apresenta-se assim pouco correlacionado com I, permitindo uma análise da imagem fortemente independente das condições de iluminação no momento da aquisição dos dados.

A segmentação é particularmente difícil quando regiões externas aos sinais exibem valores de Hue (canal H) muito semelhantes aos mesmos. Por exemplo, o céu apresenta um azul apenas ligeiramente mais claro do que alguns

sinais, enquanto algumas estradas exibem um azul apenas ligeiramente mais escuro. A saturação - que quantifica a distância entre a cor de cada pixel e o correspondente valor monocromático (branco/cinza/preto), dependendo de I - poderia ser usada como mais um classificador para distinguir sinais de outros objectos. No entanto, é extremamente sensível ao ruído, para baixos valores de I (figura 5). Assim, usamos para a segmentação em regiões, além do

Figura 5. Saturação versus componente cromático.



canal H, o componente cromático $A_{x,y}$ [Escalera 04], calculado a partir dos valores RGB de acordo com a fórmula 1. Os intervalos de valores apresentados na tabela 1 são utilizados para classificar um pixel como pertencendo, ou não, a um sinal vermelho ou azul. Uma operação de binarização é aplicada a todos os pontos da imagem, determinando se pertencem ou não a uma região candidata a ser classificada como um sinal. A figura 6 apresenta um exemplo dos resultados obtidos.

$$L_{x,y} = 0.3 * R_{x,y} + 0.6 * G_{x,y} + 0.1 * B_{x,y}$$

$$l_i = \frac{|L_{x,y} - i_{x,y}|}{L_{x,y}}, i \in R, G, B \quad (1)$$

$$A_{x,y} = \max(l_R, l_G, l_B)$$

	Hue	$A_{x,y}$
Sinais vermelhos	[0 .. 15] [200 .. 255]	≥ 32
Sinais azuis	[135 .. 200]	≥ 84

Tabela 1. Valores de Hue e componente cromático usados na segmentação

A segmentação baseada na cor resulta ainda num número elevado de regiões, sendo que uma fracção significativa não corresponde a sinais de trânsito. Um processo de filtragem adicional baseado em características espaciais, tais como a dimensão e localização na imagem destas regiões, permite refinar estes resultados. Este processo de filtragem inclui quatro critérios de eliminação de regiões:

1. regiões conectadas com os limites da imagem são eliminadas, pois representam ou ruído ou objectos que estão a entrar (ou sair) da área de visualização e serão (terão sido) detectados em imagens posteriores (respectivamente, anteriores);

Figura 6. Segmentação Hue/Saturação versus Hue/componente cromático.



2. regiões com um rácio Altura/Largura superior a um limite determinado experimentalmente são subdivididas, subentendendo-se que correspondem a vários sinais montados no mesmo suporte vertical;
3. regiões com área, altura ou largura inferiores a limites experimentalmente determinados são eliminadas;
4. regiões totalmente contidas dentro de outras regiões são também eliminadas para evitar múltiplas referências ao mesmo sinal.

A figura 7 apresenta exemplos de cada um destes critérios aplicados a uma imagem e a figura 8 apresenta o resultado final obtido após a filtragem. Para permitir a comparação com os padrões armazenados na base de dados estas regiões são redimensionadas e armazenadas como uma imagem de 64 por 64 pontos.

Figura 7. Imagem original e filtragem.





Figura 8. Resultado da segmentação por cor e filtragem.



3.2. Detecção de Formas

Cada região é classificada de acordo com a sua forma, sendo distinguidas quatro das formas mais comuns nos


sinais de trânsito: circular, quadrangular, triangular e triangular invertida (figura 4). A detecção das formas é feita usando um classificador baseado em assinaturas de contornos. Este classificador baseia-se em $r(\theta)$ que representa a distância do contorno ao centro da região como uma função unidimensional do ângulo de azimute θ . As assinaturas do contorno são independentes da posição, mas dependentes da rotação e escala. Uma vez que o sistema aqui descrito processa sinalização vertical a rotação não é considerada, sendo que o ângulo $\theta = 0$ representa a direcção vertical. Alterações de escala são compensadas normalizando a dimensão das regiões (64x64). O classificador é avaliado para um número n de ângulos empiricamente determinado como

$$n = \sqrt{x^2 + y^2}$$

$$\Delta\theta = \frac{360}{n}$$

sendo x e y a dimensão em pixels da região. A figura 9 apresenta a assinatura de contorno de um sinal triangular com $n=90$, sendo facilmente identificáveis os 3 vértices (máximos de $r(\theta)$) e os 3 pontos médios dos lados (mínimos de $r(\theta)$).

Figura 9. Assinatura de contorno de um sinal triangular.



A assinatura de contorno é calculada para cada região resultante do processo de segmentação pela cor e comparada com as assinaturas das formas padrão. Esta comparação consiste no cálculo de uma métrica de similaridade, σ , definida como o desvio padrão entre as assinaturas da região e de cada uma das formas padrão:

$$\sigma = \frac{1}{n} \sum_{i=1}^n ||R_i - F_i| - \mu| \quad (2)$$

onde R_i e F_i são, respectivamente, os valores das assinaturas da região e da forma padrão no ponto i e

$$\mu = \frac{1}{n} \sum_{i=1}^n |R_i - F_i|$$

é a média aritmética da diferença ponto a ponto dos valores das assinaturas.

Para cada região são calculadas quatro métricas de similaridade, uma para cada forma padrão, sendo a região classificada como a forma padrão que exibir o menor σ , desde que menor do que um limite k determinado empiricamente.

3.3. Classificação

A classificação automática de sinais de trânsito é dificultada por um número de factores inerentes ao próprio problema: existe um elevado número de sinais diferentes e para cada sinal existem diferentes pictogramas [Paclik 99], os sinais podem estar parcialmente ocluídos, existem grandes variações nas condições de iluminação no momento da aquisição dos dados e a escala varia de imagem para imagem. Os dois últimos problemas foram abordados nas secções anteriores. O problema da oclusão não é tratado directamente nesta abordagem. A diversidade de sinais e pictogramas associados implica uma base de dados alargada, que contem todos os pictogramas a reconhecer como sinais de trânsito. Outras abordagens limitam drasticamente o conjunto de sinais a reconhecer ou usam sistemas de reconhecimento de padrões baseados em redes neuronais [Aoyagi 96]; esta última opção requer uma base de dados enorme para a fase de treino e aprendizagem da rede.

A abordagem seguida no sistema aqui descrito utiliza a correlação monocromática normalizada [Betke 95, Escalera 04, Miura 02], não requerendo uma fase de aprendizagem. A correlação monocromática normalizada é dada por

$$C = \frac{\sum_{x,y} (R_{x,y} - \bar{R})(S_{x,y} - \bar{S})}{\sqrt{\sum_{x,y} (R_{x,y} - \bar{R})^2 \sum_{x,y} (S_{x,y} - \bar{S})^2}} \quad (3)$$

onde $R_{x,y}$ e $S_{x,y}$ representam os pontos da região candidata e do padrão do sinal, respectivamente, e

$$\bar{R} = \frac{1}{N} \sum_{x,y} R_{x,y} \quad , \quad \bar{S} = \frac{1}{N} \sum_{x,y} S_{x,y}$$

sendo N o número de pixels na região normalizada ($N = 64 * 64$, neste caso particular).

Uma vez que os padrões armazenados na base de dados estão subdivididos por cor e forma (figura 4), a correlação C para cada região candidata é calculada apenas para aqueles padrões que correspondem à mesma classe, permitindo assim reduzir o número de sinais padrão candidatos. No entanto, para evitar erros de correlação causados por pequenas translações, cada candidato é deslocado horizontal e verticalmente ± 2 pixels, resultando em 25 correlações por sinal padrão candidato. O sinal padrão que exibir o menor valor de C é seleccionado como correspondendo à região em análise, desde que C seja menor que um limite empiricamente determinado.

4. RESULTADOS

O sistema proposto foi submetido a testes de campo para validar o seu grau de sucesso, sendo utilizadas imagens recolhidas em condições reais de utilização. Estes testes foram divididos em três partes:

detecção baseada na cor – 172 imagens com uma resolução de 320x240 pontos, contendo um total de

238 sinais de trânsito, foram submetidas ao processo de detecção baseado na cor. A tabela 2 sumaria as características deste conjunto de dados;

classificação baseada na forma – as regiões candidatas detectadas no item anterior foram submetidas ao processo de detecção e classificação de forma;

identificação – este último passo foi aplicado ao conjunto final de dados para aferir a capacidade de reconhecimento e identificação de sinais do sistema.

Formas	Quantidade	Percentagem
Circular	132	55,4%
Triangular	43	18,2%
Quadrangular	32	13,6%
Triangular Inv.	31	12,8%
Total	238	100,0%

Tabela 2. Conjunto de dados utilizados na verificação experimental

4.1. Detecção Baseada na Cor

Esta operação segmenta a imagem em regiões que apresentam uma cor uniforme de acordo com os procedimentos descritos na secção 3.1 e os intervalos de valor apresentados na tabela 1. Cada uma destas regiões é depois sujeita ao processo de filtragem descrito na mesma secção, parametrizado com valores determinados experimentalmente e apresentados na tabela 3.

Descrição	Observação	Valor
Área	Rejeitar se	< 64
Altura	Rejeitar se	< 16
Largura	Rejeitar se	< 16
Altura/Largura	Subdividir se	> 1,46

Tabela 3. Parâmetros usados no processo de filtragem

A tabela 4 apresenta os resultados obtidos nesta fase. O processo de detecção falha em 7 casos, devido a sinais que estão ligados a outros ou ao fundo, não tendo sido possível isolá-los, e a situações em que o processo de segmentação pela cor resulta em fragmentação da região efectivamente correspondente ao sinal de trânsito. A taxa de sucesso é de 97,06%, o que foi considerado altamente satisfatório por todos os elementos do consórcio.

4.2. Classificação da Forma

Esta fase tem como objectivos eliminar regiões identificadas no passo anterior mas que não correspondem a qualquer forma padrão e classificar as restantes de acordo com a sua forma. O limite máximo, k , aceitável para que uma região seja classificável como uma das formas padrão,

Não detectados	
Ligados a outro sinal	2
Ligados ao fundo	3
Fragmentados	2
Total não detectados	7
Total detectados (#)	231
Total detectados (%)	97,06%

Tabela 4. Resultados - detecção baseada na cor

de acordo com a métrica de similaridade σ , foi experimentalmente determinado como 2,43. As 231 regiões identificadas no passo anterior foram submetidas a este processo de classificação, sendo os resultados apresentados na tabela 5. A taxa de sucesso é de 90,5%, valor considerado satisfatório por todos os elementos do consórcio.


Regiões analisadas		231
Eliminadas pelo classificador		12
Falsos positivos		3
Erro na forma detectada		7
Classificados correctamente (#)		209
Classificados correctamente (%)		90,5%

Tabela 5. Resultados - classificação baseada na forma

4.3. Reconhecimento

O reconhecimento de sinais foi validado usando uma base de dados com 38 pictogramas, classificados de acordo com a sua cor e forma e devidamente normalizados para 64x64 pontos (figura 10). O reconhecimento é efectuado usando a correlação monocromática normalizada, entre a região candidata e o pictograma padrão. A tabela 6 apresenta os resultados obtidos. A taxa de sucesso de 82,8% indicia que este processo necessita de afinamento, particularmente no que respeita à taxa de sinais erradamente reconhecidos.

Figura 10. Pictogramas de sinais presentes na base de dados.



Sinais analisados	209
Atribuídos a sinais errados	36
Correctamente reconhecidos (#)	173
Correctamente reconhecidos (%)	82,8%
Taxa de insucesso (%)	17,2%

Tabela 6. Resultados - reconhecimento de sinais

5. CONCLUSÕES

Apresentou-se um sistema de localização e identificação automáticas de mobiliário urbano, recorrendo a técnicas de Visão por Computador, cujo principal objectivo é aumentar a produtividade na inventariação e georeferenciação destes objectos. O trabalho de campo, correspondente à aquisição de imagens digitais da zona a inventariar, é realizado usando um Sistema de Mapeamento Móvel, constituído por uma carrinha equipada com duas câmaras de vídeo digital e um sistema de geo-posicionamento. Estes vídeos devem posteriormente ser processados para localizar, identificar e geoposicionar os objectos de interesse - neste caso, sinalização vertical de trânsito. O processo tradicional consistia na inspecção visual de toda a sequência de imagens por um operador humano. O sistema aqui proposto permite automatizar esta fase, reduzindo a duração, taxa de erro e custo do processo.

A abordagem seguida consiste em usar a cor e a forma para detectar sinais e realizar a segmentação da imagem, seguido de um processo de correlação monocromática normalizada para identificar cada um dos sinais. A validação experimental, realizada com um conjunto de 172 imagens recolhidas em situações reais e contendo um total de 238 sinais, produziu resultados encorajadores: as fases de segmentação pela cor, detecção de formas e reconhecimento apresentaram taxas de sucesso de 97,06%, 90,5% e 82,8%, respectivamente. Foram devidamente detectados e classificados 173 sinais em 238, representando uma taxa de sucesso global de 72,7%. Este resultado revelou-se muito encorajador, traduzindo-se num indicador de sucesso do projecto, que visava demonstrar a viabilidade do conceito através do desenvolvimento de uma metodologia e um protótipo, e não produzir um produto acabado.

Merece especial destaque o ganho de produtividade conseguido no processo de georeferenciação executado pela GEONAV. Com a automatização do processo de localização e identificação dos sinais de trânsito cerca de 75% dos sinais são imediatamente encontrados. Os restantes, apesar de não identificados, são assinalados pela aplicação desenvolvida em conjunto com o trabalho aqui descrito. O operador pode saltar directamente para as imagens assinaladas como passíveis de conter um sinal e realizar a inspecção visual, sem necessidade de visualizar toda a sequência de imagens. De realçar que a fase de detecção por cor detectou 231 sinais em 238. Destes apenas 173 foram identificados, mas as imagens onde se

situam os restantes 58 sinais são marcadas para referência do operador da GEONAV. O ganho em tempo de processamento dos dados, e consequentemente no custo, é significativo.

O trabalho futuro concentrar-se-à no aumento da robustez da abordagem, relativamente quer às condições de iluminação no momento de captura das imagens, quer ao processo de identificação dos sinais, que é aquele que apresenta a taxa de sucesso mais baixa. Apesar do desempenho do sistema - entendido como tempo de processamento médio de cada imagem - não ter sido uma preocupação nesta fase de prototipagem, as técnicas propostas prestam-se a várias optimizações que permitem prever um desempenho próximo do interactivo.

Referências

- [Aoyagi 96] Y. Aoyagi e T. Asakura. A study on traffic sign recognition in scene image using genetic algorithms and neural networks. Em *22nd IEEE Int. Conf. Industrial Electronics, Control, and Instrumentation*, Taiwan, 1996.
- [Arnoul 96] P. Arnoul, M. Viala, J. Guerin, e M. Mergy. Traffic signs localisation for highways inventory from a video camera on board a moving collection van. Em *IEEE Intelligent Vehicles Symp.*, Tokyo, Japan, 1996.
- [Betke 95] M. Betke e N. Makris. Fast object recognition in noisy images using simulated annealing. Em *5th IEEE Int. Conf. Computer Vision*, Cambridge, USA, 1995.
- [Escalera 04] A. Escalera, J. Armingol, J. Pastor, e F. Rodríguez. Visual sign information extraction and identification by deformable models for intelligent vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 5(2):57-68, June 2004.
- [Hibi 96] T. Hibi. Vision based extraction and recognition of road sign region from natural color image, by using hsl and coordinates transformation. Em *29th Int. Symp. Automotive Technology and Automation*, Florence, Italy, 1996.
- [Madeira 05] Sérgio Madeira, Luísa Bastos, António Sousa, João Sobral, e Luís Paulo Santos. Automatic traffic signs inventory using a mobile mapping system. Em *GISPLANET*, Lisbon, Portugal, 2005.
- [Miura 02] J. Miura, T. Kanda, S. Nakatani, e Y. Shirai. An active vision system for on line traffic sign recognition. *IEICE Transactions on Information Systems*, E85-D(11), 2002.
- [Paclik 99] P. Paclik, J. Novovicova, P. Pudil, e P. Somol. Road sign classification using the

laplace kernel classifier. Em *11th Scandinavian Conf. on Image Analysis*, Greenland, 1999.

- [Piccioli 96] G. Piccioli, E. Micheli, P. Parodia, e M. Campani. Robust method for road sign detection and recognition. *Image Vis. Comput.*, 14(3):209–233, April 1996.
- [Tomé 00] P. Tomé, S. Cunha, e L. Bastos. Evaluation of a dgps/imu integrated navigation system. Em *ION GPS*, Salt Lake City, Utah, USA, 2000.
- [Wolf 00] P. Wolf e B. Dewitt. *Elements of photogrammetry, with applications in GIS*, páginas 233–259. McGraw-Hill, 2000.
- [Yilmaz 06] A. Yilmaz, O. Javed, e M. Shah. Object tracking: a survey. *ACM Computing Surveys*, 38(4), December 2006.