

INTRODUÇÃO

- Veículos autônomos e sistemas de assistência de motorista requerem um sistema robusto de detecção e reconhecimento de ambiente.
- O reconhecimento de semáforos é algo essencial para veículos baseados em visão computacional.
- No ambiente urbano há muito ruído visual e objetos que têm cores ou formatos similares aos que o sistema de detecção está procurando.
- Também há a possibilidade de encontrar-se varios tipos de semáforos, como horizontais, verticais, com luzes circulares ou com flechas.
- Nosso foco foi de criar uma solução para o tipo mais comum de semáforo. Esse algoritmo foi feito para procurar por semáforos verticais ou horizontais com luzes circulares.

ALGORITMO

O algoritmo tem três objetivos: detecção, classificação e rastreo. Para isso, o algoritmo foi separado nos seguintes passos:

• Recorte e conversão de espaço de cor:

Nesse passo a imagem é recortada para a remoção de informações irrelevantes. A imagem também é convertida para escala de cinza e espaço de cor HSV(Hue-Saturation-Value) para passos futuros.

• Limiar Adaptativo, Erosão e Dilatação:

A imagem em escala de cinza é então limiada, erodida e dilatada para a redução de informação na imagem e para identificarmos os blobs.

• Máscara de cor e detecção de blob:

Três máscaras(vermelha, verde e amarela) são aplicadas à imagem em que aplicamos a conversão HSV. Após isso, blobs de cada cor são detectados.

• Detecção de orientação:

A orientação do sinal de trafego é então detectada. A detecção é feita por uma análise de quantidade de pixels pretos em cada orientação possível.

• Rastreo:

Para reduzir o número de falsos positivos e para reduzir o tempo de processamento, os semáforos detectados são rastreados ao longo do tempo. O tracking é atualizado a cada três quadros. A cada atualização do rastreamento, o programa é rodado novamente para evitar a perda de novas informações.

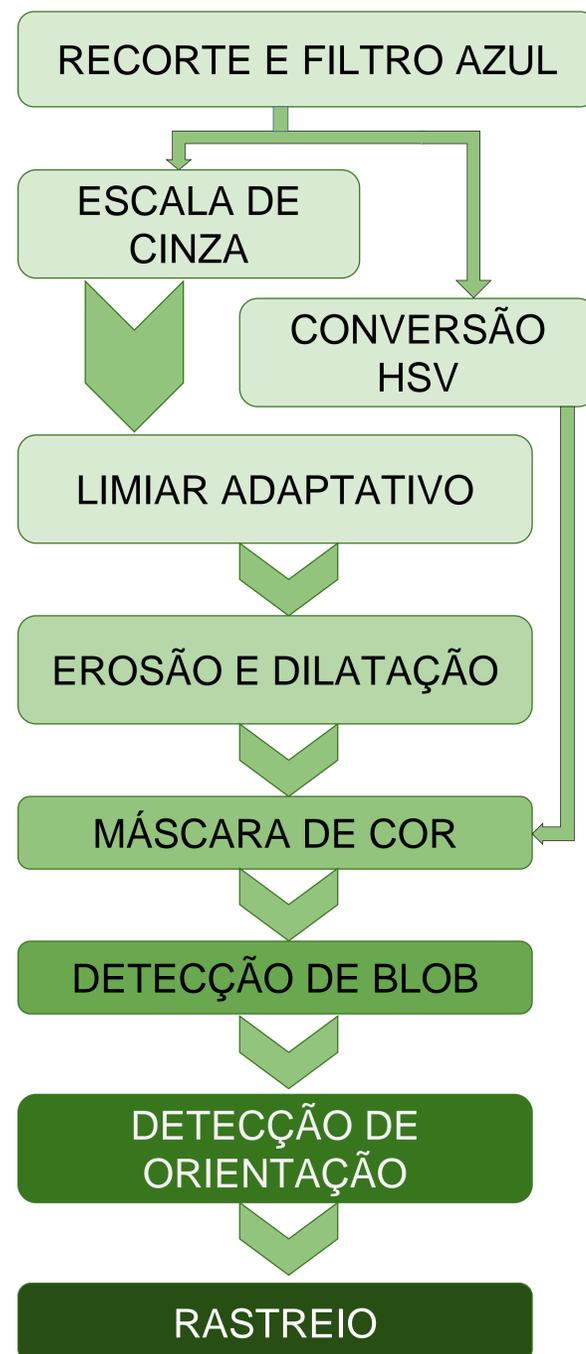


Figura 1 - Diagrama de blocos

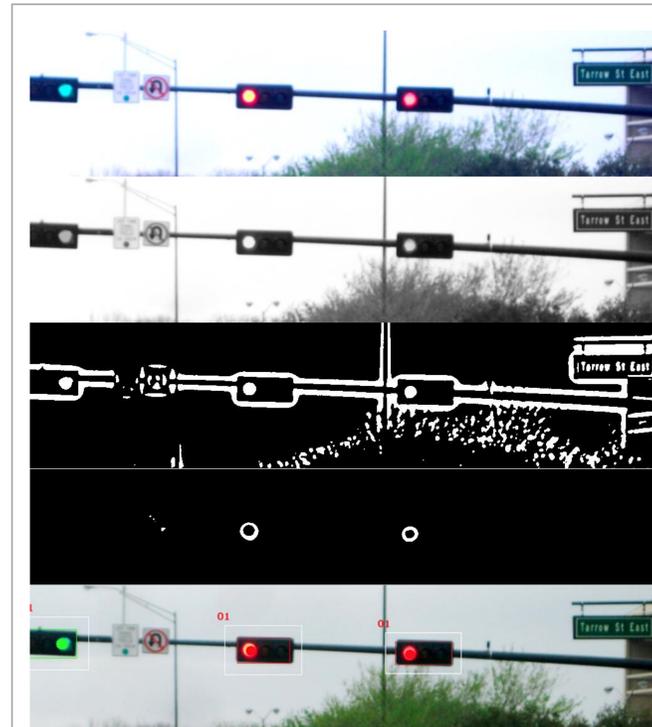


Figura 2 – Recorte e filtro azul; Conversão para escala de cinza; limiar adaptativo, erosão e dilatação; Máscara vermelha de cor; Blobs detectados e contador de rastreo..

RESULTADOS E DISCUSSÃO

O algoritmo foi testado num conjunto de imagens com 1789 quadros e sua performance foi avaliada por meio de comparação manual dos resultados. Os resultados seguem na figura 3.



Figura 3 - Acertos, erros e falsos positivos para luzes vermelhas, amarelas e verdes.

Os resultados obtidos foram, em geral, satisfatórios, exceto a detecção de luzes amarelas. Utilizando o espaço de cor HSV, a luz amarela é especialmente difícil de se distinguir da luz vermelha, devido à distorção de cores causada pela câmera em diferentes condições de luz.

Um detalhe importante é de que os resultados do programa e sua performance variam grandemente de acordo com a qualidade da camera utilizada, quadros por segundo, condições de luz e resolução de imagem.

O tempo de processamento atingido para este conjunto de imagens, com imagens em 720p e sem otimizações é em média 13.5 quadros por segundo e num processador ARM 0.5 quadros por segundo.

Tabela 1 – Tempo de computação médio

Intel Core i7 Linux Ubuntu 14.04	74.37 ms
ARM Cortex-A9 Linux Ubuntu 12.04 sem otimizações	2059.61 ms

REFERENCIAS

- Guo Mu, Zhang Xinyu, Li Dey, Zhang Tianlei, An Lifeng. Traffic light detection and recognition for autonomous vehicles. Tsinghua University, Beijing China.
- Charette R., Nashashibi F. Real Time Visual Traffic Lights Recognition Based on Spot Light Detection and Adaptive Traffic Lights Templates.
- Fairfield N., Urmson C. Traffic Light Mapping and Detection. Google, Inc.
- OpenCV Library Docs. (<http://docs.opencv.org>).
- Xilinx Zedboard Docs. (<http://zedboard.org/content/documentation>).

AGRADECIMENTOS