

Uma Nova Arquitetura para Classificação de Tráfego de Veículos Baseado em Processamento de Imagens

Andre Luis Cristiani¹, Renan Guilherme Nespolo^{1,2}, Luis F. C. Maschi¹,
Luis Nakamura¹, Jo Ueyama², Rodolfo I. Meneguette¹

¹ Instituto Federal de São Paulo - IFSP
² Universidade Estadual de São Paulo - USP

{renan.nespolo, nakamura, luis.maschi}@ifsp.edu.br joueyama@icmc.usp.br meneguette@isfp.edu.br

Abstract. *With the increase of vehicles in the big urban centers we can observe an increase in the number of congestion and accidents in the public ways caused not only by the lack of attention of the driver but also by the lack of a traffic infrastructure that assists the driver in the decision making before a event or condition of the route. One of the services provided to the driver is the monitoring of the roads to detect the flow of vehicles that are traveling in a road. In order to increase the efficiency of the traffic flow and optimize the process of propagating this information to the user, we propose an architecture in which to detect and classify the flow of vehicles on the highway. For this, the proposed architecture has a mechanism in which the concepts of computational vision are used to extract the maximum information from the roads in order to inform drivers about the traffic conditions of vehicles on Brazilian highways. The efficiency of the proposed method was evaluated. The results showed that the developed method obtained a lower false positive around 3%, a lower false negative (9%), consequently a better classification of vehicles. In addition, the proposed solution obtained a flow classification score around 90*

Resumo. *Com o aumento de veículos nos grandes centros urbanos podemos observar um acréscimo no número de congestionamento e acidentes nas vias públicas, ocasionado, não só pela falta de atenção do condutor, mas também pela falta de uma infraestrutura de tráfego que auxilie o motorista na tomada de decisão perante um evento ou condição da rodovia. Um dos serviços prestados ao condutor é o monitoramento das vias, para detectar o fluxo de veículos que está trafegando em uma via. Com objetivo de trazer maior eficiência da detecção do fluxo dos veículos, bem como otimizar o processo de propagação dessa informação para o usuário, propomos uma arquitetura na qual detectará e classificará o fluxo de veículos na rodovia. Para isso, a arquitetura proposta possui um mecanismo na qual utiliza-se dos conceitos de visão computacional, para extrair o máximo de informações das vias, com intuito de informar aos condutores sobre as condições de tráfego de veículos nas rodovias brasileiras. Foi analisado a eficiência do método proposto. Os resultados providos do método desenvolvido se mostraram promissores, alcançando taxas menores de falso-positivos, cerca de 3%, falso-negativos (9%) e, conseqüentemente, uma melhor classificação dos veículos. Além disso, a solução proposta obteve um acerto de classificação de fluxo em torno de 90%.*

1. Introdução

Atualmente, os veículos podem estar equipados por dispositivos embarcados que poderão auxiliar inúmeros serviços e aplicações, para o gerenciamento de tráfego de uma via ou até de uma grande cidade [Boukerche and Meneguette 2017]. Portanto, esses dispositivos permitirão o sensoriamento das ruas e rodovias de uma cidade, trazendo novos serviços e auxiliando os sistemas de transporte inteligente, na qual visa a otimização de toda a infraestrutura do sistema de transporte de uma cidade [Meneguette and Boukerche 2017].

Para verificar o potencial dos sistemas de transportes inteligentes, com o uso dessas aplicações e serviços, é tomado como exemplo o estudo conduzido pelo Instituto de Pesquisa Econômica e Aplicada [Federal-PRF et al. 2015], realizado em 2015, que mostra o número de acidentes nas rodovias federais do Brasil, no qual registrou cerca de 169 mil acidentes de trânsito por ano, que custa em média R\$ 72,7 mil ao país. No caso dos acidentes com morte, esse custo médio sobe para R\$ 646 mil. Parte desses acidentes é referente a desatenção ou falta de informações futuras. Esses estudos mostram que 33,7% desses acidentes são causados por colisões frontais. Além disso, 32,6% são causados por falta de atenção. Assim, tais acidentes podem ser reduzidos com o uso de dispositivos e mecanismos que monitoram o tráfego e detectam possíveis eventos nas rodovias.

Para a realização do monitoramento da condição do tráfego de uma via pública utiliza-se um mecanismo que realiza a contagem dos veículos que estão trafegando na rodovia monitorada. Esse mecanismo tem como objetivo detectar quais vias estão com tráfego lento, possíveis pontos de congestionamentos e trechos com interrupção do tráfego [Hankey et al. 2017].

Os mecanismos utilizam cabos piezoelétricos e sensores, tais como: ultrassom, infravermelho, micro-ondas, laser e óticos, para realizar a contagem de veículos que estão trafegando nas vias [Seenouvong et al. 2016]. Geralmente, são utilizados sensores indutivos fixados ao pavimento, para detectar o veículo automaticamente. Estes realizam a contagem dos veículos que cruzam a seção da rodovia, tendo, ainda, a capacidade de classificar estes, através da análise dos perfis magnéticos dos mesmos [Magalhaes 2008].

Outra forma de realizar o monitoramento de tráfego automaticamente é o uso de câmera previamente instalada ao longo das vias. A câmera de vídeo torna-se um meio promissor e de baixo custo para o monitoramento do fluxo de tráfego [Robert 2009], a qual as concessionárias que gerenciam as vias a utiliza para verificar possíveis eventos. Portanto, o uso dos conceitos de visão computacional para o monitoramento do tráfego urbano ou rodoviário torna-se um campo emergente para pesquisa de novos serviços e aplicação para os sistemas de transporte inteligente [Wang et al. 2016].

A análise do tráfego utilizando câmeras possui muitas vantagens em relação aos outros meios de monitoramento. As câmeras possuem fáceis instalações, não causam danos às estradas e possuem custo relativamente baixo de instalação e manutenção [Xia et al. 2016]. Reduz-se, desta forma, a utilização de outros recursos, como, por exemplo, a instalação de outros sensores. Geralmente, um grande número de câmeras já estão instaladas nas vias, para fins de fiscalização. Uma única câmera é capaz de monitorar mais de uma faixa de tráfego ao longo de várias centenas de metros de estrada. Portanto, elas fornecem uma ampla área de monitoramento, podendo monitorar diversas pistas ao mesmo tempo, permitindo uma melhor análise do fluxo do tráfego, cálculo de velocidade, contagem de veículos, classificação de veículos e avaliação de

rodovias. O monitoramento automático do tráfego é uma fonte rica de informações e os dados coletados, através das câmeras, podem ser utilizados para as mais diversas finalidades.

Assim, sistemas baseados em visão computacional podem ser utilizados para extrair uma variedade de informações, tais como: o caminho percorrido pelo veículo; a forma do veículo; as dimensões e a cor. Um sistema de visão poderia, potencialmente, ter os mesmos poderes de observação de um agente humano, mas sem os efeitos prejudiciais de cansaço e tédio causados pela tarefa repetitiva [Bhaskar and Yong 2014]. Apesar de existirem vantagens na utilização de câmeras de vídeo, também existem algumas desvantagens. As câmeras estão sujeitas à vibrações devido ao vento e passagem de veículos pesados. A posição da câmera também é um fator importante, pois, por estar posicionada acima da via, dependendo da posição e ângulo que a câmera captura, podem ocorrer obstruções na presença de veículos grandes. Muitas vezes, são aproveitadas câmeras de vigilância que já estavam previamente instaladas, que geralmente não foram originalmente especificadas ou instaladas com a finalidade de utilizar algoritmos de visão computacional [Hankey et al. 2017], aumentando a complexidade dos métodos de monitoramento por câmeras, pois será necessário contornar também essas dificuldades não diretamente relacionadas ao monitoramento do tráfego. Outros fatores que podem impactar nos algoritmos de visão computacional são: o clima; a iluminação; objetos parados na via e etc. Assim, é muito difícil um algoritmo de visão computacional levar em conta todas essas variações e definir parâmetros que funcionem em todas as diferentes situações.

Na literatura existem diversas arquiteturas [Cucchiara et al. 2000, Tai et al. 2004, Xia et al. 2016] na qual utilizam processamento de imagens para a gestão de congestionamento. Entretanto, tais sistemas não consideram o processamento dos vídeos no qual o ambiente está escuro, ou seja, quando estiver nublado, noite ou chuvoso. Outros trabalhos utilizam a comunicação entre os veículos para disseminar informações e determinar congestionamento, tais como os trabalhos [Meneguette et al. 2016b, Meneguette et al. 2016a, de Souza et al. 2015]. No entanto, tais tecnologias ainda não se encontram embarcadas no veículo, ou seja, ainda não é possível, de forma comercial, estabelecer a comunicação entre os veículos de forma espontânea.

Assim, neste trabalho propomos uma arquitetura que permite a classificação e propagação de informações, referentes aos fluxos de veículos nas vias. Para isso, foi desenvolvido um método baseado nos conceitos de visão computacional, com objetivo de classificar e detectar os fluxos de veículos que estão trafegando nas rodovias, principalmente nas rodovias brasileiras. Deste modo, foram utilizados vídeos disponibilizados pelas concessionárias, por exemplo, a AutoBAN [AutoBAN], para realizar a classificação do fluxo de veículos. Baseada nessa classificação, a arquitetura informará as condições das rodovias através de dispositivos móveis, para que os motoristas possam ser informados sobre as condições de tráfego do local e tomar uma ação. A principal contribuição desse mecanismo é realizar a classificação e detecção do fluxo dos veículos, independente da iluminação do vídeo. Além disso, informar os motoristas, em tempo real, as condições das vias de modo automático.

O restante do trabalho está estruturado da seguinte maneira. A seção 2 apresenta os trabalhos da literatura. A seção 3 propõe a arquitetura focada na detecção de veículos e classificação dos fluxos de veículos nas rodovias. Os resultados da comparação do mecanismo proposto em relação às outras soluções encontradas na literatura, são apresentados na

seção 4. A seção 5 apresenta a conclusão e os trabalhos futuros.

2. Trabalhos Relacionados

Nessa seção serão discutidas algumas arquitetura encontradas na literatura [Fernández-Caballero et al. 2008, Cucchiara et al. 2000, Bhaskar and Yong 2014, Xia et al. 2016, Barcellos et al. 2015, Bouvié et al. 2013] na qual usa o processamento de imagem e vídeo para realizar o rastreamento do veículo bem como o monitoramento do tráfego de veículos nas ruas e estradas de uma cidade.

Caballero e colaboradores [Fernández-Caballero et al. 2008] propuseram um mecanismo de processamento de imagens para detectar veículos e para verificar e executar o rastreamento de veículos ao longo do tempo. Essa solução é similar ao método proposto em [Cucchiara et al. 2000] na qual descreve um módulo de processamento de imagens de dados visuais extraídos da cena. Essa abordagem usa uma análise de espaço temporal e módulos de alto nível para executar em veículos e seus atributos para explorar alto conhecimento em condições de tráfego. Essa abordagem determina se o veículo realmente deixou a cena, foi sobreposto ou ocultado por outro veículo.

Outro trabalho foi o de Xia e colaboradores [Xia et al. 2016] que apresentaram uma solução baseada em laços virtuais para melhorar a qualidade do método de contagem de veículos. Os autores usaram a estação de base para melhorar a detecção de movimento dos veículos fundindo o Modelo de Mistura Gaussiana (GMM) com o algoritmo de Maximização de Expectativa (EM) para obter melhores resultados de rastreamento. Portanto, a fusão do algoritmo de EM com o GMM resultou na melhora da qualidade de segmentação dos veículos em movimento. Além disso, os autores desenvolveram um método de restauração para remoção de ruídos e preenchimento de frestas para obter a melhor região do objeto. O autor também usou uma característica morfológica e o histograma de cores para resolver problemas de obstrução.

Outra abordagem apresentada foi a descrita por Barcellos e colaboradores [Barcellos et al. 2015]. Os autores propuseram um sistema para detectar e realizar a contagem de veículos em vídeos de tráfego urbanos com laços virtuais de usuários definidos. A abordagem usou a ligação de movimentos e a adjacência espacial para agrupar amostragens de partículas em sequências de vídeos urbanos. Além disso, o autor também usou GMM e imagens de energia de movimentos para determinar os locais ideais que as partículas retirem as amostras e os grupos de partículas convexas são então analisadas para detecção dos veículos. O veículo é rastreado usando a similaridade de suas cores em *frames* adjacentes e são contados em laços virtuais de usuários definidos pela detecção de intersecção do rastreamento de veículos. Essa abordagem melhora o esquema apresentado em [Bouvié et al. 2013] apresentando uma nova segmentação do movimento de veículos em relação ao fundo.

No entanto, a maioria dessas soluções não leva em conta todas as condições do ambiente, ou seja não consideraram um ambiente com pouca luz, como o anoitecer, o clima nublado ou a chuva. Além disso, essas soluções não avaliam as condições do tráfego de veículos, mas apenas contam o número de veículos nas estradas. Portanto, a arquitetura proposta além de realizar a detecção do número de veículos como forma de permitir que o tráfego seja classificado abrange vários cenários diferentes com uma gama de níveis de luz, ou seja, incluindo a detecção diurno e noturno. No proposto trabalho também é apresentado um classificação do fluxo de veículos em condições de tráfego em três

níveis, que são: livre; moderado e congestionado. De maneira complementar aos estudos apresentados na literatura que apenas realizam a contagem de veículos.

3. Uma Nova Arquitetura para Classificação de Tráfego de Veículos Baseado em Processamento de Imagens

Na presente seção será apresentado o desenvolvimento de uma arquitetura voltada para a detecção e classificação de congestionamento em vias públicas, denominada APIA: Arquitetura para classificação de tráfego de veículos baseado em Processamento de Imagem. Essa arquitetura tem como principal objetivo detectar os veículos que estão trafegando nas vias públicas, classificando o tipo de tráfego de veículos, ou seja, a arquitetura verificará as condições do tráfego das vias nas, quais possuem um sistema de monitoramento por câmeras. Assim, APIA utilizará de conceitos de visão computacional, para detectar e classificar tráfego de veículos de uma cidade. A arquitetura disponibilizará informações para o condutor, para que ele possa tomar alguma ação em relação às condições de tráfego de veículos nas vias, proporcionando um melhor fluxo de tráfego.

Em busca desse objetivo, para o funcionamento da arquitetura proposta é necessário: (i) armazenamento e disseminação de informações de forma escalável; (ii) identificar um veículo através de uma imagem de um vídeo ou de uma foto; (iii) contar a quantidade de veículos que estão trafegando dentro de uma via monitorada; (iv) realizar a classificação e a propagação dessa informação para os condutores. Assim, a arquitetura APIA utilizará das câmeras distribuídas pelas cidades, fornecendo imagens das vias, possibilitando uma classificação do tráfego. Além disso a APIA utiliza dos conceitos de *Web Service*, para a realização do armazenamento dos *frames* e processamento das informações, bem como oferece um mecanismo de divulgação de classificação baseado na web. Uma visão geral da arquitetura será descrita na próxima seção.

3.1. Visão Geral da Arquitetura APIA

A arquitetura APIA está dividida em 3 principais componentes: (i) visualização da classificação; (ii) armazenamento e processamento das informações; (iii) monitoramento e abstração das informações como apresentada na Figura 1.

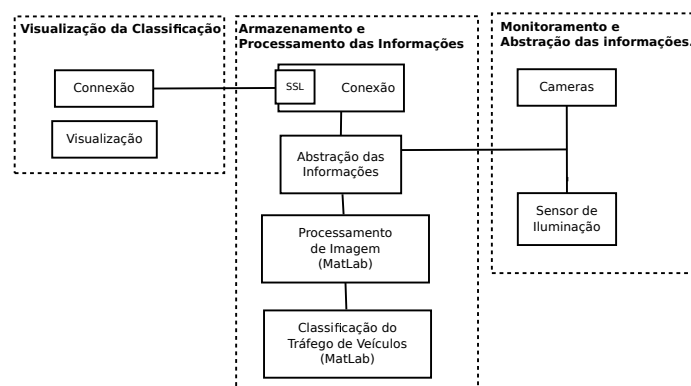


Figure 1. Arquitetura APIA e seu principais componentes

A visualização da informação é realizada por um cliente web no qual permite o monitoramento da via, bem como a visualização da classificação da condição do tráfego,

por meio de alertas na tela. Esse componente está diretamente conectado ao armazenamento e processamento de informação, na qual utiliza-se de um *Web Service* na qual recebe os *frames* vindos das câmeras de vigilância, bem como uma *flag* da condição de iluminação do local para a realização do processamento.

O *Web Service* utilizado foi o RESTful *Web Services* no qual foram adicionados os mecanismos de abstração das informações, realizando a comunicação com os sensores (câmera e sensor de luminosidade) e abstrações de informação. Também foram adicionados módulos de processamento dos *frames* recebidos, no qual realiza o pré-processamento das informações e a comunicação com o Matlab, para que seja feita a classificação do tráfego dos veículos. O Matlab executará o algoritmo de classificação de condição de tráfego, posteriormente retornando essa informação para o *Web Service*.

A captura dos vídeos e da luminosidade da via monitorada foi realizada utilizando câmeras de vigilância, bem como sensores de iluminação para selecionar qual o melhor mecanismo de detecção de tráfego. A escolha de utilizar um sensor que verifica a iluminação do local foi decorrente ao tempo que se leva para realizar o pré-processamento da imagem, antes de se realizar a classificação. Portanto, foi definida a utilização do sensor para trazer maior agilidade da classificação e também fornecer mais uma informação para possíveis serviços disponíveis pelo *Web Service*.

3.2. Sensores e Câmeras

As câmeras de vigilância previamente instaladas em ruas e avenidas, bem como em rodovias, foram utilizadas para a captação das imagens das vias públicas. Considerando que estas possam ser acessadas via web, através de um mecanismo de *streaming*.

Para a captação de luminosidade, foi utilizado o sensor de luminosidade LDR (*Light Dependent Resistor*). Nesse sensor, quanto maior a luz incidente, maior será a sua resistência. O LDR é constituído de um semiconductor de alta resistência, que ao receber uma grande quantidade de fótons oriundos da luz incidente, ele absorve elétrons que melhoram sua condutibilidade, reduzindo, sua resistência. Dessa forma, esse semiconductor pode assumir resistências na ordem de mega Ohm no escuro e resistência na ordem de poucas centenas, quando exposto a luz como mostra na Figura 2.




Figure 2. Circuito do LDR

Para ajustar a potência e precisão do sensor LDR, foi utilizado um trimpot, do inglês *timmer potentiometer*, que é um potenciômetro miniatura ajustável. É de simples instalação e ideal para pequenos circuitos e placas. Com a utilização deste potenciômetro, foi possível regular a potência do sensor LDR, de forma que melhor ele se adapte aos fatores ambientais de luminosidade. O sensor LDR transmite diferentes taxas de tensões, variando de acordo com a quantidade de luminosidade nele aplicada. Para tornar um valor mais preciso, utilizou-se um transistor s8050, que altera a tensão dele de forma

que o valor 1 representa dia e 0 representa noite ou possíveis dias chuvosos com muitas nuvens. Essas informações podem ser transmitidas tanto por uma rede sem fio, quanto por uma rede celular para o *Web Service*.

3.3. Abstração e Processamento no Webservice

Para o armazenamento e processamento das informações foi utilizado a tecnologia *Web Service* e também para a realização de todas as chamadas voltadas para o html5, para auxiliar na abstração das informações dos vídeos. Assim, para a captura dos *frames* do vídeo, é realizado um espelhamento no qual permite transformar cada *frame* em uma imagem em tempo real. O algoritmo 1 descreve as chamadas da função para a captura da imagem.

```
1 video.addEventListener('loadedmetadata', function() {
2   canvas.width = video.videoWidth;
3   canvas.height = video.videoHeight;
4 });
5
6 video.addEventListener('play', function() {
7   var $this = this; //cache
8   (function loop() {
9     if (!$this.paused && !$this.ended) {
10      ctx.drawImage($this, 0, 0);
11      setTimeout(loop, 1000 / 30); // drawing at 30fps
12      dataURLstring = canvas.toDataURL();
13      imgData=ctx.getImageData(0,0,canvas.width,canvas.height);
14      RequestService(cont);
15    }
16  }
17  )();
18 }, 0);
```

Algoritmo 1. Abstração dos frames do vídeos

O método extrai 30 *frames* por segundo, um padrão aplicado em monitores, para que não seja visível ao olho humano a atualização das imagens e é aceitável ao problema abordado no presente trabalho. O método `getImageData` extrai o *frame* no formato de um vetor hexadecimal, sendo necessário a conversão de base hexadecimal para a base 64 devido ao padrão adotado na linguagem Matlab. A conversão é feita utilizando o algoritmo 2

```
1 function TransformBase64(imgData) {
2   var uInt8Array = imgData.data;
3   var i = uInt8Array.length;
4   var binaryString = [i];
5   while (i--) {
6     binaryString[i] = String.fromCharCode(uInt8Array[i])
7     ;
8   }
9   var data = binaryString.join('');
10  var base64 = window.btoa(data);
11  return base64;
12 }
```

Algoritmo 2. Conversão para a Chamada do Matlab

Assim cada *frame* do vídeo é estruturado pela marcação *canvas*, onde é possibilitada a extração da imagem no formato base64, que é enviado no corpo da requisição (HTTP POST) através da tecnologia Ajax por meio do modo assíncrono para a página não recarregar, deixando, dessa forma, a transmissão do vídeo fluir sem cortes.

Além disso, o *Web Service* busca o valor da luminosidade que foi informada pelo sensor LDR e que foi armazenado em um arquivo XML por meio da função `getLuminosidadeXML()`, com o nome do arquivo previamente determinado (foi definido como uma constante no método que salva o valor no XML), busca pela *tag* Valor que contém o status da luminosidade em tempo real e fornece um retorno para ser armazenado em uma variável que o método possa ter acesso e verificar qual arquivo XML utilizar, para a identificação dos veículos. Quando o valor da luminosidade for igual a um (luminosidade == 1), representará a identificação de luz ideal para a utilização do XML treinado para a identificação no período do dia, atribuindo o valor "CarsDay.xml" na variável que armazenará o nome do arquivo a ser utilizado no Matlab. Quando o valor da luminosidade for igual a zero (luminosidade == 0), representa a oclusão de luz, o que torna o arquivo XML, descrito acima, inviável para a identificação de frações de luz (como a iluminação da lanterna do carro), devendo atribuir o valor "CarsNight.xml" na variável do nome do arquivo, pois, este foi treinado e preparado para identificar veículos em ambientes pouco iluminados e, por meio da iluminação das lanternas, como podemos ver no algoritmo 3.

```
1 @POST
2     public String getJson(@RequestParam("imagem") String imagem) {
3         String caminho = "C:\\Users\\Andre\\Desktop\\
4             CalcularVeiculos\\imagem.png";
5         byte[] decoded = Base64.getDecoder().decode(imagem.
6             substring(1, imagem.length() - 1));
7         Object[] r = null;
8         String luminosidade = "1";
9         luminosidade = this.getLuminosidadeXML();
10        System.err.println(luminosidade);
11        String arquivo = "";
12        if("1".equals(luminosidade)){
13            arquivo = "CarsDay.xml";
14        }else{
15            arquivo = "CarsNight.xml";
16        }
17        try{
18            FileOutputStream out = new FileOutputStream(caminho)
19                ;
20            out.write(decoded);
21            out.close();
22            CalcVehicles.CalcularTrafego t = new CalcVehicles.
23                CalcularTrafego();
24            r = t.calcularTrafego(1, caminho, arquivo);
25        } catch (Exception ex) {
26            System.err.println("Erro: " + ex);
27        }
28        return r[0].toString();
29    }
```


Algoritmo 3. Conversão para a Chamada do Matlab

Com a utilização da função `FileOutputStream`, que pertence ao pacote `java.io` do Java e o `array` de bytes da imagem, é gerado um arquivo de imagem com o nome `imagem.png`; imagem essa que é salva em um caminho previamente determinado. Esse é utilizado pela chamada do método `calcularTrafego`, no qual se comunica com o Matlab para o processamento e classificação das imagens.

3.4. Classificação de tráfego

Após a captação do vídeo por meio de uma transmissão *streaming* disponibilizada por uma empresa que cuida da rodovia, ou por um dispositivo que transmite seus *frames* para a central de controle, é chamado o método de processamento de imagens para a realização da classificação dos veículos e, posteriormente, a classificação do tráfego de veículos na rodovia.

Para a detecção do veículo, primeiramente, é importante extrair as características dos veículos, na qual as mesmas serão responsáveis por diferenciar um veículo de outros objetos. Para isso, é separado um conjunto de características encontrado no veículo que é distinto em relação aos conjuntos encontrados em outros objetos. A maior motivação para o uso de características de um objeto, ao invés do uso de seus pixels, é que, a velocidade da análise de uma imagem, baseada no conjunto de suas principais características, é muito maior do que a análise.

Antes de aplicar o algoritmo proposto por Viola-Jones, é necessário construir uma base de imagens de treinamento. Assim, o número de imagens positivas e negativas irão influenciar na classificação do objeto. Portanto, neste trabalho foram utilizados 5690 imagens para treinamento de cenários em ambientes diurnos e condições climáticas favoráveis. Dessas imagens, 2370 foram positivas, ou seja imagens de veículos e 3320 foram negativas, imagens que não são veículos. Para ambientes noturnos foram utilizadas 962 imagens, sendo 193 positivas e 769 negativas. Portanto, foram utilizadas mais de 6652 imagens. A diferença no número de imagens retiradas com a luz do dia para as retiradas ao anoitecer está na dificuldade da obtenção das mesmas, bem como na quantidade de vídeos e imagens que são disponibilizadas pela internet, como, por exemplo, o *streaming* das rodovias que pertence a empresa AutoBAN que disponibiliza online os *frames* vindo de seus sistemas de monitoramento.

Após a detecção dos veículos, é necessário classificar o fluxo do tráfego na rodovia. Para isso é usado um mecanismo de contagem de veículos, considerando a quantidade de mesmos que estão na imagem, bem como os veículos que deixam a mesma após um período de tempo.

Portanto, neste trabalho, usamos um mecanismo de limiar para classificar o fluxo de veículos. O fluxo do veículo é classificado em 3 níveis, tráfego livre, tráfego moderado e congestionado. Depois de alguns testes, estabeleceu-se os valores dos limiares para definir os níveis de congestionamento. Assim, assumimos que:

- Tráfego livre = número de veículos contados deve ser menor que 12
- Tráfego moderado = número de veículos contados deve ser maior 12 e menor que 20

- Congestionado = número de veículos contados deve ser maior que 20

Assim, quando a função `calcularTrafego` é chamada, ela carrega o detector proposto (arquivo XML previamente treinado com as imagens positivas e negativas) e a imagem que está localizada no caminho que foi recebido; identifica os veículos; realiza a contabilidade dos mesmos, e com base nisso, identifica o fluxo de tráfego e retorna os dados identificados por meio de um *object*, como podemos ver no algoritmo 4.

```

1 function [result, numCars] = calcularTrafego( router, archive )
2     detector= vision.CascadeObjectDetector(archive);
3     frame = imread(router);
4     bbox = step(detector, frame);
5     numCars = size(bbox, 1);
6     if numCars > 20
7         result = 'Congestionado';
8     elseif numCars > 12 && numCars <= 20
9         result = 'Moderado';
10    else
11        result = 'Livre';
12    end
13 end

```

Algoritmo 4. Abstração da chamada do classificador de trafego de veículos

3.5. Visualização

Essas informações são disponibilizadas por uma pagina web, na qual o usuários pode ter acesso a condição do tráfego do local monitorado. como podemos ver na Figura 3.




Figure 3. Visualização do sistema via um Cliente Web

4. Caso de Uso e Avaliação de Performance

Como caso de uso e avaliação da arquitetura foram utilizados 35 vídeos retirados do *streaming* disponibilizado pela empresa AutoBAN, que gerencia as principais rodovias que interligam as cidades de Campinas, Cordeirópolis, Jundiaí e São Paulo. O objetivo desses experimentos foi avaliar métodos de classificação de veículos e detecção de desempenho em ambientes noturnos e diurnos. Isso envolveu testar nosso mecanismo, considerando as classes de detecção de veículos em ambos os cenários, bem como a classificação do tráfego em ambos.

Para esse motivo, realizamos a comparação da arquitetura proposta com Bhaskar et. al. [Bhaskar and Yong 2014] quando analisamos a detecção dos veículos. Entretanto, quando consideramos a detecção do fluxo de veículos na rodovia, comparamos APIA com

a visão de um especialista para realizar uma comparação do que realmente está acontecendo com o que o mecanismo proposto está percebendo.

Foram realizados testes, referentes à detecção dos veículos, com objetivo de verificar se a APIA está identificando os veículos na imagem. Para esse teste foram avaliados 3 fatores que impactam diretamente na quantidade de veículos identificação que são, (i) falso-positivo; (ii) falso-negativo; e (iii) classificação correta

Neste cenário, os vídeos incluídos possuem diversas condições de fluxo de tráfego. Além disso, contamos com 35 vídeos para o ambiente noturno e 35 vídeos para o ambiente diurno.

Primeiramente, avaliamos a APIA com relação à detecção dos veículos em ambientes com uma boa iluminação, ou seja, os veículos enviados para avaliação que foram capturados durante o dia.

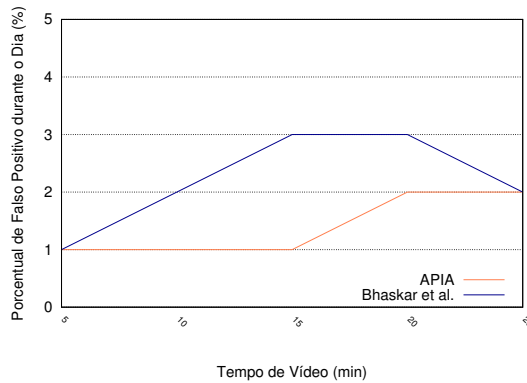
A Figura 4(a) apresenta a porcentagem de falso-positivos, ou seja, a quantidade de veículos que foram identificados de forma errada, classificando outros objetos como se fosse um veículo. Assim, como no falso-negativo, pode-se observar que a APIA obteve uma pequena melhora com relação a solução proposta em [Bhaskar and Yong 2014]. A APIA conseguiu reduzir a porcentagem de falso positivo em aproximadamente 3%. Isso ocorre devido a base de imagens utilizado pelo APIA para a realização da classificação dos veículos.

Na Figura 4(b) é apresentada a porcentagem dos falso-negativos, ou seja, da porcentagem dos veículos que os métodos não conseguiram identificar. Os gráficos mostram que o método proposto obteve uma quantidade menor de falso-negativos, comparado com outros trabalhos na Literatura. Isso ocorre pois o método utilizado em [Bhaskar and Yong 2014] algumas vezes não consegue identificar os veículos que estão próximo aos outros, ou seja, quando um carro está atrás e muito próximo de outro, devido à segmentação da imagem. Assim, a APIA reduziu em aproximadamente 9% a quantidade de falso-negativos em relação ao método apresentado em [Bhaskar and Yong 2014].


Após a avaliação do APIA com os vídeos capturados durante o dia, começamos avaliar o comportamento do método proposto também em vídeos capturados durante a noite e madrugada, quando a iluminação é menor e a dificuldade de realizar a classificação dos veículos aumenta.

É apresentado na Figura 4(c) a porcentagem de falso-positivos, considerando vídeos capturados à noite. Assim, como nos falso-negativos, constatou-se que a APIA obteve uma pequena melhora com relação a solução proposta em [Bhaskar and Yong 2014]. A APIA conseguiu reduzir a porcentagem de falso-positivos em aproximadamente 2%. Isso ocorre devido à base de imagens utilizada pelo APIA para a realização da classificação dos veículos.

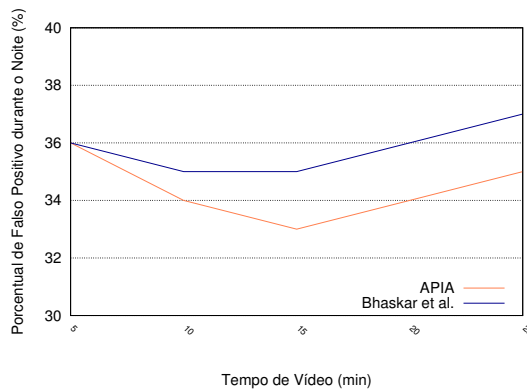
A Figura 4(d) apresenta a porcentagem dos falso-negativos em um ambiente noturno. Nesse cenário, podemos observar pelos gráficos que o método proposto obteve um quantidade menor de falso-negativos comparado com outros trabalhos na Literatura. Isso ocorre porquê o método apresentado em [Bhaskar and Yong 2014] algumas vezes não consegue identificar os veículos devido ao fundo escuro da imagem, detectando apenas pontos isolados na mesma. Portanto, a APIA reduziu em aproximadamente 5% a quanti-



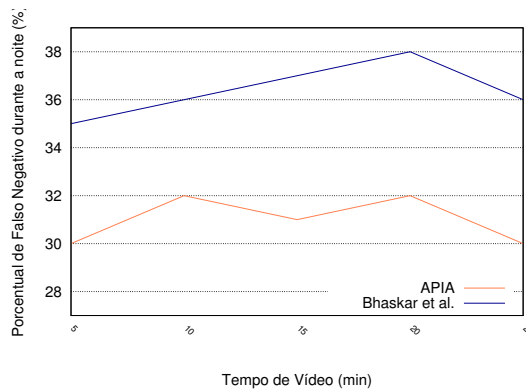
(a) Porcentagem de Falso Positivo durante o dia




(b) Porcentagem de Falso Negativos durante o dia



(c) Porcentagem de Falso Positivo durante a noite



(d) Porcentagem de Falso Negativo durante a noite



(e) Porcentagem de Acerto durante a Classificação do Tráfego de veículos

Figure 4. Resultados obtidos através de testes para fazer a comparação entre os cenários de nossa proposta com outros documentos e levando em consideração: (a) Porcentagem de Falso Negativo e (b) Porcentagem de Falso Positivo à luz do dia. (c) Porcentagem de Falso-Negativo e (d) Porcentagem de Falso-Positivo à noite (e) Porcentagem de Acerto durante a Classificação do Tráfego de veículos

dade de falso-negativos com relação a solução apresentada em [Bhaskar and Yong 2014].

Na Figura 4(e) constata-se que na classificação do fluxo dos vídeos que foram capturados à noite, a classificação do nível de tráfego é menor devido ao método de classificação dos objetos (veículos). Entretanto, a APIA atingiu um percentual de aproximadamente 90% de classificação correta dos níveis de tráfego em um ambiente mais claro.

5. Conclusão

No presente trabalho é proposta uma nova arquitetura para detecção e classificação do tráfego de veículos em cidades, baseadas nos conceitos de visão computacional. A arquitetura explorou o uso de câmeras e sensores de luminosidade para captação de informações de tráfego de veículos, para realizar a classificação do mesmo de uma determinada via monitorada. Para isso foi utilizado o processamento de imagem para realizar a detecção de veículos e a classificação do tráfego. Comparando a solução proposta no presente trabalho com outras soluções presentes na literatura, constata-se que a abordagem proposta neste trabalho apresentou uma porcentagem menor de falso-positivos e falso-negativos, obtendo uma melhor classificação da condição de tráfegos de veículos.

Como trabalhos futuros, pretendemos melhorar o padrão de classificação, especialmente no que diz respeito à estabilidade e adaptabilidade. Nosso objetivo é realizar novas pesquisas sobre outros métodos que podem ser empregados para enfrentar problemas de obstruções de veículos.

Agradecimentos

A Rodolfo I. Meneguette e a CNPq (processos 150545/2018-5) por financiarem seus projetos de pesquisas.

References

- AutoBAN, C. Camera ao vivo. last visited in August, 2017, <http://www.autoban.com.br/ao-vivo>.
- Barcellos, P., Bouvié, C., Escouto, F. L., and Scharcanski, J. (2015). A novel video based system for detecting and counting vehicles at user-defined virtual loops. *Expert Systems with Applications*, 42(4):1845 – 1856.
- Bhaskar, P. K. and Yong, S.-P. (2014). Image processing based vehicle detection and tracking method. In *Computer and Information Sciences (ICCOINS), 2014 International Conference on*, pages 1–5. IEEE.
- Boukerche, A. and Meneguette, R. I. (2017). Vehicular cloud network: A new challenge for resource management based systems. In *2017 13th International Wireless Communications and Mobile Computing Conference (IWCMC)*, pages 159–164.
- Bouvié, C., Scharcanski, J., Barcellos, P., and Escouto, F. L. (2013). Tracking and counting vehicles in traffic video sequences using particle filtering. In *2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, pages 812–815.
- Cucchiara, R., Piccardi, M., and Mello, P. (2000). Image analysis and rule-based reasoning for a traffic monitoring system. *IEEE Transactions on Intelligent Transportation Systems*, 1(2):119–130.

- de Souza, A. M., Yokoyama, R. S., Botega, L. C., Meneguette, R. I., and Villas, L. A. (2015). Scorpion: A solution using cooperative rerouting to prevent congestion and improve traffic condition. In *2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing*, pages 497–503.
- Federal-PRF, P. R. et al. (2015). Acidentes de trânsito nas rodovias federais brasileiras. caracterização, tendências e custos para a sociedade.
- Fernández-Caballero, A., Gómez, F. J., and López-López, J. (2008). Road-traffic monitoring by knowledge-driven static and dynamic image analysis. *Expert Systems with Applications*, 35(3):701–719.
- Hankey, S., Lu, T., Mondschein, A., and Buehler, R. (2017). Spatial models of active travel in small communities: Merging the goals of traffic monitoring and direct-demand modeling. *Journal of Transport and Health*.
- Magalhaes, H. A. (2008). Análise em alta resolução de perfis magnéticos de sensores a laço indutivo para classificação de veículos automotores.
- Meneguette, R., Filho, G., Bittencourt, L., Ueyama, J., and Villas, L. (2016a). A solution for detection and control for congested roads using vehicular networks. *IEEE Latin America Transactions*, 14(4):1849–1855.
- Meneguette, R. I. and Boukerche, A. (2017). Servites: An efficient search and allocation resource protocol based on v2v communication for vehicular cloud. *Computer Networks*, 123:104 – 118.
- Meneguette, R. I., Filho, G. P. R., Guidoni, D. L., Pessin, G., Villas, L. A., and Ueyama, J. (2016b). Increasing intelligence in inter-vehicle communications to reduce traffic congestions: Experiments in urban and highway environments. *PLOS ONE*, 11(8):1–25.
- Robert, K. (2009). Video-based traffic monitoring at day and night vehicle features detection tracking. In *Intelligent Transportation Systems, 2009. ITSC'09. 12th International IEEE Conference on*, pages 1–6. IEEE.
- Seenouvang, N., Watchareeruetai, U., Nuthong, C., Khongsomboon, K., and Ohnishi, N. (2016). A computer vision based vehicle detection and counting system. In *2016 8th International Conference on Knowledge and Smart Technology (KST)*, pages 224–227.
- Tai, J.-C., Tseng, S.-T., Lin, C.-P., and Song, K.-T. (2004). Real-time image tracking for automatic traffic monitoring and enforcement applications. *Image and Vision Computing*, 22(6):485–501.
- Wang, X., Liu, C., and Zhu, M. (2016). Instant traveling companion discovery based on traffic-monitoring streaming data. In *2016 13th Web Information Systems and Applications Conference (WISA)*, pages 89–94.
- Xia, Y., Shi, X., Song, G., Geng, Q., and Liu, Y. (2016). Towards improving quality of video-based vehicle counting method for traffic flow estimation. *Signal Processing*, 120:672–681.