

UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE TECNOLOGIA  
DEPARTAMENTO DE TRANSPORTES  
CURSO DE ENGENHARIA CIVIL

Lucas Paz Saffi

**ANÁLISE DA VIABILIDADE DA UTILIZAÇÃO DE VISÃO  
COMPUTACIONAL NO LEVANTAMENTO DE TRÁFEGO PARA O  
DIMENSIONAMENTO DE PAVIMENTOS ASFÁLTICOS**

Santa Maria, RS  
2019

**Lucas Paz Saffi**

**ANÁLISE DA VIABILIDADE DA UTILIZAÇÃO DE VISÃO  
COMPUTACIONAL NO LEVANTAMENTO DE TRÁFEGO PARA O  
DIMENSIONAMENTO DE PAVIMENTOS ASFÁLTICOS**

Trabalho de Conclusão de Curso  
apresentado ao Curso de Engenharia  
Civil da Universidade Federal de Santa  
Maria (UFSM, RS), como requisito  
parcial para obtenção do título de  
**Engenheiro Civil.**

Orientador: Deividi da Silva Pereira

Santa Maria, RS

2019

Lucas Paz Saffi

**ANÁLISE DA VIABILIDADE DA UTILIZAÇÃO DE VISÃO  
COMPUTACIONAL NO LEVANTAMENTO DE TRÁFEGO PARA O  
DIMENSIONAMENTO DE PAVIMENTOS ASFÁLTICOS**

Trabalho de Conclusão de Curso  
apresentado ao Curso de Engenharia  
Civil da Universidade Federal de Santa  
Maria (UFSM, RS), como requisito  
parcial para obtenção do título de  
**Engenheiro Civil.**

Aprovado em 12 de julho de 2019.

---

Deividi da Silva Pereira, Dr. (UFSM)  
(Presidente/Orientador)

---

João Carlos D. Lima, Dr. (UFSM)

---

Débora Tanise Bordin, Me.

Santa Maria, RS

2019

## AGRADECIMENTOS

A conclusão desse trabalho e período só foi possível graças ao apoio, parceria e compreensão de diversas pessoas. Agradeço a todos que, de alguma forma, contribuíram com meu período acadêmico e agradeço especialmente a:

- a Deus, por ter me abençoado com saúde, família e amigos incríveis;
- a meu pai e mãe que sempre me apoiaram de todas as formas possíveis a alcançar os meus objetivos e a ser uma excelente pessoa e profissional;
- a meu irmão, meu melhor amigo e, que junto com meus pais, me inspira a ser o melhor que posso todos os dias como pessoa e profissional;
- Aos meus colegas da i9 Liga de Empreendedorismo, que me ensinaram muito e até hoje são grandes amigos;
- aos companheiros de Objetiva Jr, que me motivaram a seguir a carreira que estou seguindo hoje;
- à FALCONI Consultores de Resultado, que me proporcionou uma das maiores experiências de aprendizado e onde começarei minha carreira em 2019;
- ao professor Deividi pela orientação e valorização do meu interesse pela área de engenharia civil juntamente com a de computação e, acima de tudo, por ter acreditado em mim no desenvolvimento deste projeto;

Saio muito feliz com todas as amizades que fiz, todo o conhecimento adquirido e por hoje ter a certeza de que sou capaz de fazer a diferença na vida das pessoas através do meu trabalho e conhecimento. Devo muito isso a todos vocês.

“Se você pensa que pode ou se pensa que não pode,  
de qualquer forma você está certo.”

(Henry Ford)

## RESUMO

### **ANÁLISE DA VIABILIDADE DA UTILIZAÇÃO DE VISÃO COMPUTACIONAL NO LEVANTAMENTO DE TRÁFEGO PARA O DIMENSIONAMENTO DE PAVIMENTOS ASFÁLTICOS**

AUTOR: Lucas Paz Saffi  
ORIENTADOR: Deividi da Silva Pereira

Considerando a grande importância do modal rodoviário, tanto para o transporte de mercadorias quanto o de pessoas no Brasil, é fundamental que a malha rodoviária brasileira conecte diversos pontos do país e, principalmente, atenda aos requisitos de qualidade exigidos. Para isso, é necessário que sejam realizados estudos na área de dimensionamento de pavimentos e desenvolver tecnologias que possibilitem um melhor levantamento e estudo do tráfego. O estudo do tráfego é importante para que seja determinado o valor "N", o número de passagens de um eixo padrão por uma rodovia, e que é utilizado para a determinação da espessura de cada uma das camadas dos pavimentos rodoviários. Atualmente as duas principais formas de levantamento de tráfego são a contagem manual e a utilização de sensores, que apesar de serem eficientes, possuem um custo relativamente elevado e/ou não possibilitam o acompanhamento da evolução do tráfego por longos períodos. O presente trabalho teve o objetivo de estudar a viabilidade do uso de visão computacional, um campo da inteligência artificial, no levantamento de tráfego através de gravações do fluxo de veículos de uma rodovia. Concluiu-se ao fim do projeto que a qualidade do modelo identificador de rodas e de eixos tem impacto direto nas abordagens utilizadas pelo programa, tempo de desenvolvimento e, conseqüentemente, nos resultados obtidos. Com base nos resultados e as diferentes possibilidades de melhoria pensadas e apresentadas ao longo do projeto é necessário que estudos mais aprofundados nessa área sejam realizados para definir sua viabilidade.

Palavras-chave: Tráfego. Dimensionamento. Visão Computacional.

## **ABSTRACT**

### **ANALYSIS OF THE VIABIABILITY OF THE USE OF COMPUTER VISION IN TRAFFIC SURVEY FOR THE SIZING OF ASPHALTIC PAVEMENTS**

AUTOR: Lucas Paz Saffi  
ORIENTADOR: Deividi da Silva Pereira

Given the great importance of road transportation for both freight transport and people in Brazil, it is essential that the Brazilian road network connects several points of the country and mainly meets the quality requirements. For this, it is necessary study the area of pavement design and develop technologies that allow a better survey and study of traffic. The traffic study is important in order to determine the value "N", the number of passes of a standard axle by a highway, which is used to determine the thickness of each layer of road pavements. Currently the two main ways of surveying traffic are manual counting and the use of sensors, which, despite being efficient, have a relatively high cost and / or do not allow to control traffic evolution over long periods. The present work had the objective of studying the feasibility of the use of computer vision, a field of artificial intelligence, in the survey of traffic through recordings of the flow of vehicles of a highway. It was concluded at the end of the project that the quality of the wheel and axle model has a direct impact on the approaches used by the program, the development time and, consequently, the results obtained. Based on the results and the different possibilities of improvement thought and presented throughout the project, it is necessary that further studies in this area being developed to define its viability.

Keywords: Traffic. Sizing. Computer vision.

## LISTA DE FIGURAS

Figura 1 – Frota de veículos no Brasil de 2001 a 2017 .....	13
Figura 2 – Porcentagem da malha pavimentada pesquisada para cada classificação de qualidade do pavimento no Brasil .....	18
Figura 3 - Principais tipos de eixos rodoviários .....	20
Figura 4 - Fatores de Equivalência de Carga do USACE .....	22
Figura 5 - Fatores de Equivalência de Carga da AASHTO.....	23
Figura 6 – Modelo de contador manual utilizado para o levantamento de tráfego ....	26
Figura 7 - Contador automático portátil “Hi-Star” .....	28
Figura 8 - Estrutura de um neurônio biológico.....	32
Figura 9 - Comparação de uma rede neural biológica e artificial .....	32
Figura 10 - Modelo de um neurônio artificial .....	33
Figura 11 – Perceptron multicamada com uma camada escondida .....	34
Figura 12 - Exemplo do funcionamento da retropropagação de uma rede neural ....	35
Figura 13 - Imagem RGB separada em 3 planos (vermelho, verde e azul) de dimensões 4x4.....	37
Figura 14 - Imagem utilizada para treinar a rede neural .....	38
Figura 15 - Estrutura de uma rede neural convencional (a) e uma rede neural convolucional (b).....	38
Figura 16 - Exemplo de funcionamento de um filtro em redes neurais convolucionais .....	39
Figura 17 - 96 filtros com dimensões 11x11x3 utilizados para identificação de diferentes formas e cores em uma imagem .....	40
Figura 18 - Exemplo do funcionamento da camada "Pooling" .....	41
Figura 19 - Arquitetura geral de uma rede neural convolucional .....	41
Figura 20 - Imagem da primeira gravação realizada diagonal e de frente para os veículos.....	44
Figura 21 - Imagem da primeira gravação realizada perpendicularmente a pista.....	45
Figura 22 - Imagem da primeira gravação realizada diagonal e de costas para os veículos.....	45
Figura 23 - Visão da câmera durante a gravação do fluxo no segundo levantamento de tráfego.....	47
Figura 24 - Organização dos diretórios para execução do treinamento da rede neural .....	53
Figura 25 - Janela do programa Labellmg para a marcação das rodas nas imagens selecionadas para treinamento da rede neural.....	55
Figura 26 – Parcela das imagens utilizadas para o treinamento da rede neural .....	56
Figura 27 - Informações contidas no arquivo “label_map.pbtxt” .....	57
Figura 28 - Código utilizado para exportação dos arquivos .csv e .TFRecord .....	57
Figura 29 - Código utilizado para execução do treinamento.....	59
Figura 30 - Tela que informações do treinamento em execução são apresentadas .	60
Figura 31 - Código utilizado para exportação do arquivo de pesos e que é lido pelo programa computacional para detectar rodas .....	60
Figura 32 - Caixa desenhada na região de movimento detectada na imagem .....	62
Figura 33 - Disposição das linhas de contagem no momento do processamento ....	63



Figura 34 - Modelo do processo de identificação dos tipos de eixos passantes pela linha central da imagem .....	64
Figura 35 - Modelo de identificação dos tipos de eixos finais para cada parte do veículo .....	66
Figura 36 - Dimensões e caminhões escolhidos para base na identificação dos eixos .....	67
Figura 37 - Identificação de rodas durante trecho do vídeo teste .....	69
Figura 38 - Marcação da distância entre duas rodas de um eixo tandem.....	78
Figura 39 - Ficha de contagem volumétrica I para o levantamento de tráfego .....	86
Figura 40 - Ficha de contagem volumétrica II para o levantamento de tráfego .....	87

## LISTA DE QUADROS

Quadro 1 – Valores de carga máximas estabelecidas por eixo desde a resolução nº 210/06 do CONTRAN .....	24
Quadro 2 - Qualidade de estimativas de contagem.....	27
Quadro 3 - Métodos manuais de contagem de volume .....	27
Quadro 4 - Métodos automáticos de contagem de volume .....	29
Quadro 5 – Características do hardware do celular utilizado como câmera (Samsung Galaxy S8 SM-G950FD) .....	43
Quadro 6 - Características da tela do celular utilizado como câmera (Samsung Galaxy S8 SM-G950FD) .....	43
Quadro 7 - Bibliotecas utilizadas para o treinamento e desenvolvimento do programa computacional.....	52
Quadro 8 - Modelos pré-treinados disponibilizados pelo COCO-dataset.....	58
Quadro 9 - Tipos de eixos utilizados como base para cada faixa .....	67

## LISTA DE TABELAS

Tabela 1 - Resultados obtidos no primeiro teste realizado no levantamento de veículos para 1h08min de gravação.....	70
Tabela 2 - Resultados obtidos no primeiro teste realizado no levantamento de eixos para 1h08min de gravação.....	71
Tabela 3 - Resultados obtidos no segundo teste realizado no levantamento de veículos 1h08min de gravação.....	73
Tabela 4 - Resultados obtidos no segundo teste realizado no levantamento de eixos para 1h08min de gravação.....	73
Tabela 5 - Resultados obtidos no segundo teste realizado no levantamento de veículos para 4h de gravação .....	74
Tabela 6 - Resultados obtidos no segundo teste realizado no levantamento de eixos para 4h de gravação .....	74
Tabela 7 - Resultados do valor de "N" a partir do método USACE e AASHTO .....	75

## Sumário

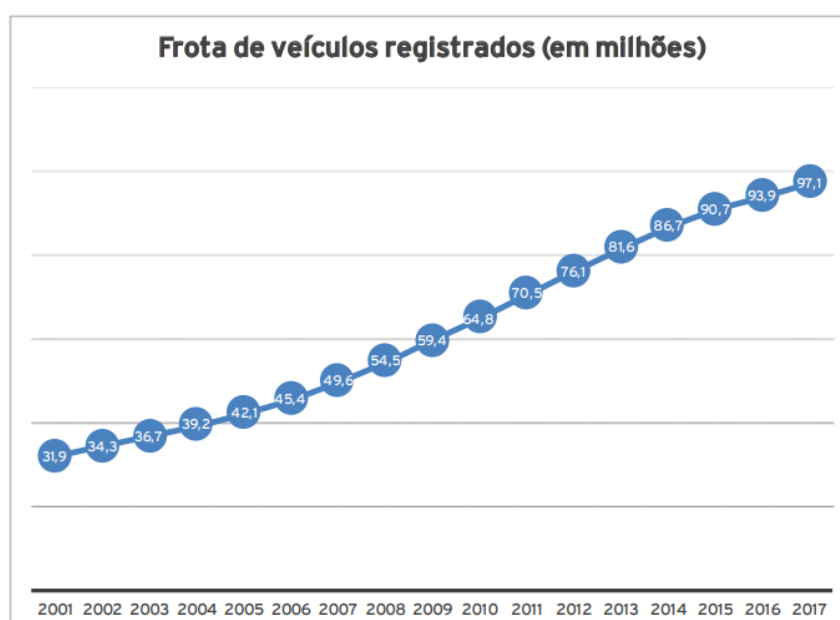
<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>13</b>
1.1	JUSTIFICATIVA .....	15
1.2	OBJETIVO GERAL .....	15
1.3	OBJETIVOS ESPECÍFICOS .....	16
1.4	ESTRUTURA DO TRABALHO .....	16
<b>2.</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	<b>18</b>
2.1	IMPORTÂNCIA DA CONTAGEM DE TRÁFEGO .....	18
<b>2.1.1</b>	<b>Tráfego Rodoviário</b> .....	<b>19</b>
<b>2.1.2</b>	<b>Avaliação das Solicitações de Tráfego</b> .....	<b>20</b>
<b>2.1.3</b>	<b>Pesagem de Veículos</b> .....	<b>23</b>
2.2	METODOLOGIA PARA AVALIAÇÃO DO TRÁFEGO .....	25
<b>2.2.1</b>	<b>Contagens Manuais</b> .....	<b>25</b>
<b>2.2.2</b>	<b>Contagens Automáticas</b> .....	<b>28</b>
<b>2.2.3</b>	<b>Videoteipe</b> .....	<b>29</b>
<b>2.2.4</b>	<b>Método do Observador Móvel</b> .....	<b>29</b>
2.3	INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA .....	30
<b>2.3.1</b>	<b>Redes Neurais Profundas</b> .....	<b>31</b>
<b>2.3.2</b>	<b>Retropropagação</b> .....	<b>34</b>
2.4	VISÃO COMPUTACIONAL .....	36
<b>3</b>	<b>METODOLOGIA</b> .....	<b>42</b>
3.1	LEVANTAMENTOS DE CAMPO DE TRÁFEGO .....	42
<b>3.1.1</b>	<b>Levantamento de campo de tráfego – Trevo dos Quartéis</b> .....	<b>44</b>
<b>3.1.2</b>	<b>Levantamento de campo de tráfego – BR-158, km 319, PRF</b> .....	<b>46</b>
3.2	RECURSOS COMPUTACIONAIS .....	47
3.3	TREINAMENTO DA REDE NEURAL CONVOLUCIONAL .....	50
<b>3.3.1</b>	<b>Instalação dos recursos necessários</b> .....	<b>51</b>
<b>3.3.2</b>	<b>Organização da área de trabalho</b> .....	<b>52</b>
<b>3.3.3</b>	<b>Coleta, transformação e anotação de imagens</b> .....	<b>54</b>
<b>3.3.4</b>	<b>Configuração do modelo pré-treinado e geração de arquivos</b> .....	<b>56</b>
<b>3.3.5</b>	<b>Treinamento e exportação do modelo final</b> .....	<b>59</b>
3.4	ABORDAGEM PARA A SOLUÇÃO DO PROBLEMA .....	61
<b>3.4.1</b>	<b>Abordagem para aceleração do processamento</b> .....	<b>61</b>
<b>3.4.2</b>	<b>Abordagem para quantificação de veículos</b> .....	<b>62</b>
<b>3.4.3</b>	<b>Abordagem para quantificação de eixos</b> .....	<b>63</b>

<b>4.</b>	<b>RESULTADOS E ANÁLISES .....</b>	<b>70</b>
4.1.	SISTEMA DE USO.....	77
4.2	LIMITAÇÕES DO PROGRAMA.....	78
<b>5.</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>80</b>
5.1	CONCLUSÕES .....	81
5.2	SUGESTÕES PARA TRABALHOS FUTUROS.....	81

## 1 INTRODUÇÃO

O começo do desenvolvimento das rodovias brasileiras teve início durante o governo de Washington Luís (1926-1930), com o plano Catrambi, no qual foram estabelecidas as bases da rede rodoviária brasileira. No entanto, foi em 1934, com o Plano Geral Nacional de Viação, que o governo brasileiro começou efetivamente a priorizar o modal rodoviário como o principal do Brasil. Desde então, o crescimento da malha rodoviária e do número de automóveis cresceu progressivamente, devido a diversos fatores como a criação do Departamento Nacional de Estradas de Rodagem (DNER), o qual em 2001 após uma reestruturação se tornou o Departamento Nacional de Infraestrutura de Transportes (DNIT), o posicionamento da capital nacional no interior do país e também a implantação da indústria automobilística nacional em 1957. De acordo com a Confederação Nacional do Transporte (CNT, 2018), havia aproximadamente 97,1 milhões de veículos registrados no Brasil até 2017, valor 63,5% superior ao de 2009, assim como mostra a Figura 1.

Figura 1 – Frota de veículos no Brasil de 2001 a 2017



Fonte: Confederação Nacional de Transportes (CNT).

Hoje no Brasil, conforme a CNT, o transporte rodoviário é responsável pela movimentação de mais de 60% das mercadorias e de mais de 90% dos passageiros, porém apenas 12,4% de toda a malha rodoviária é pavimentada, sendo 92,7% dessas pistas simples e, além disso, as condições dos pavimentos são abaixo do esperado. Em 2017, 50% dos pavimentos foram classificados como regular, ruim ou péssimo.

A combinação dos fatores de crescimento da frota de veículos, pequena malha rodoviária pavimentada e a baixa qualidade, resultam na insatisfação dos usuários e a geração de acidentes. De acordo com o Departamento Nacional de Trânsito (Denatran, 2018), em 2018, 1.117 ocorrências de acidentes registrados, de um total 69.206, foram ocasionados por problemas na via.

Dada a situação das rodovias brasileiras, estudos na área de dimensionamentos de pavimentos asfálticos e dos materiais que compõem sua estrutura tem se intensificado ao longo dos anos com o objetivo de se desenvolverem pavimentos que atendam as devidas requisições de projeto, como tempo, qualidade e durabilidade. Devido a fatores como diferença de carga, composição de eixos, rodas e velocidades variadas, veículos distintos degradam de forma diferente os pavimentos. O entendimento dessas características que influenciam na degradação do pavimento é fundamental para o desenvolvimento de métodos de dimensionamentos que levem em consideração de forma assertiva a influência do tráfego.

Por esse motivo é usual representar o tráfego e intensidade de carga de uma rodovia de acordo com o número "N", o qual representa o número de repetições de carga de um eixo padrão de 8,2 toneladas a que o pavimento estará sujeito ao longo de sua vida de serviço (Manual de Estudos de Tráfego, DNIT, 2006, p. 245). O objetivo dessa representação é reproduzir o mesmo efeito destrutivo do tráfego real com base em passagens de um único eixo. Com a obtenção desse valor é possível realizar o dimensionamento da via de acordo com os métodos da American Association of State Highway Officials (AASHTO) ou US Army Corps of Engineers (USACE), os quais se baseiam nos critérios de serventia e de ruptura plástica do subleito respectivamente (Manual de Restauração de Pavimentos Asfálticos, DNIT, 2006, p. 113)

Logo, é essencial que se tenha o conhecimento do real comportamento do tráfego em uma rodovia para que seja realizado um dimensionamento assertivo. Para isso, há basicamente duas formas de medir e verificar o comportamento do tráfego:

através da contagem manual de veículos; e da instalação de sensores na pista de rodagem.

Visto a necessidade de contratação de pessoas e os custos de instalação e manutenção ocasionados pela instalação de sensores em vários pontos de uma via, propõe-se a investigação da aplicação de uma tecnologia diferente, visão computacional. Esta tecnologia é um campo da inteligência artificial e busca viabilizar a compreensão do tráfego de uma rodovia com apenas a utilização de gravações do fluxo de veículos.

### 1.1 JUSTIFICATIVA

A qualidade das rodovias brasileiras é um fator que impacta a segurança, satisfação e economia dos usuários, sendo assim fundamental garantir que os pavimentos sejam corretamente dimensionados e conservados. Devido a necessidade da determinação do valor "N" no dimensionamento, é necessário o estabelecimento de procedimentos e/ou tecnologias que auxiliem nesse processo. O procedimento de contagem manual de veículos apesar de ser um procedimento simples, não consegue obter um resultado que represente o fluxo de veículos durante longos períodos por ser necessário a contratação de pessoas. Já a utilização de sensores, requer um investimento considerável e possibilita a medição em pontos específicos apesar de serem extremamente precisos. Visto as lacunas encontradas na aplicação dos dois métodos existentes, justifica-se a investigação de uma tecnologia que realize o levantamento de tráfego, a qual, neste projeto, será a visão computacional.

### 1.2 OBJETIVO GERAL

Analisar a viabilidade da utilização de visão computacional para o levantamento de tráfego para dimensionamento de pavimentos asfálticos, através do desenvolvimento de um programa computacional utilizando métodos de inteligência artificial. Além disso, procurar compreender os pontos fortes e limitações da utilização dessa tecnologia e avaliar a perspectiva e prioridades para estudos futuros.



### 1.3 OBJETIVOS ESPECÍFICOS

- Desenvolver protótipo do programa computacional que realize o levantamento do tráfego de veículos e eixos passantes em uma rodovia através de filmagens do fluxo de veículos;
- Comparar resultados obtidos a partir do programa desenvolvido com o valor real levantado a partir de contagem manual;
- Definir problemas específicos a partir dos resultados e implementar contramedidas ao programa a fim de diminuir os erros;
- Identificar limitações do programa e prioridades para estudos futuros e aprimoramento da tecnologia para o levantamento do tráfego.

### 1.4 ESTRUTURA DO TRABALHO

Esse trabalho está dividido em cinco partes principais:

- Introdução
- Revisão Bibliográfica
- Metodologia
- Resultados e Análises
- Considerações Finais

Na introdução, seção já apresentada, o grande objetivo era investigar rapidamente o porquê da relevância de se estudar a viabilidade de uma tecnologia para o levantamento de tráfego.

Na seção de Referências Bibliográficas será apresentado mais detalhes justificando a análise da viabilidade de visão computacional para compreensão do tráfego de uma rodovia, principalmente através da comparação com demais métodos já utilizados. Também, serão apresentados os fundamentos que norteiam a tecnologia utilizada, a visão computacional.

O propósito da metodologia é apresentar a sequência de passos para o desenvolvimento do projeto e características relativas à tecnologia e da resolução do problema a ser solucionado.

Os Resultados e Análises tem o intuito de apresentar e comparar resultados obtidos através da contagem manual e do programa computacional antes e após as correções, além de explicar o seu funcionamento de uso.

Por fim, nas Considerações Finais, as principais conclusões do projeto serão apresentadas juntamente com sugestões e prioridades para trabalhos futuros na área de visão computacional e levantamento de tráfego.

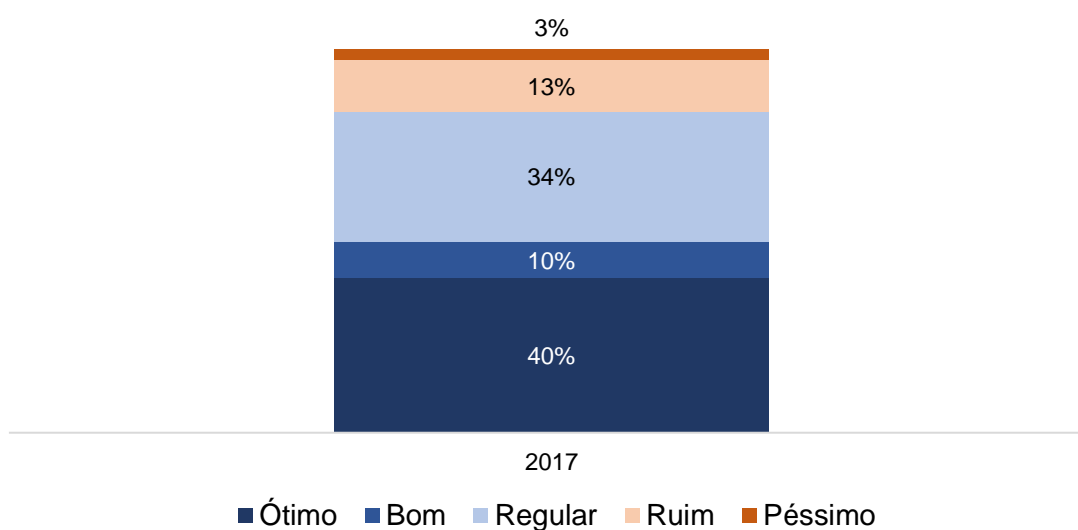
## 2. REVISÃO BIBLIOGRÁFICA

### 2.1 IMPORTÂNCIA DA CONTAGEM DE TRÁFEGO

A infraestrutura do transporte rodoviário do Brasil é de fundamental importância para o desenvolvimento do país, pois, conforme já mencionado, o modal é responsável por 60% do transporte de mercadorias e 90% do transporte de pessoas no Brasil de acordo com a CNT. Uma das explicações para a grande representatividade e influência na economia, é o grande crescimento nos últimos anos da frota de veículos, tanto de passeio quanto comerciais, os quais, de 2009 a 2017, cresceram 63,5%. Apesar desse crescimento da frota, a malha pavimentada brasileira cresceu apenas 0,5% nesse período, resultando assim no aumento do fluxo de veículos que trafegam pelas rodovias e, conseqüentemente, sobrecarregando mais o pavimento e diminuindo sua qualidade mais rapidamente.

Em 2017, conforme a Figura 2, aproximadamente 50% da malha rodoviária brasileira possuía pavimento classificado como regular, ruim ou péssimo (CNT, 2018).

Figura 2 – Porcentagem da malha pavimentada pesquisada para cada classificação de qualidade do pavimento no Brasil



Fonte: Confederação Nacional de Transportes (CNT), 2018.

O fato de metade da malha rodoviária brasileira estar com qualidade insatisfatória pode ser devido a diferentes causas, como: a falta de manutenção periódica, falhas no processo de execução e acabamento das camadas do pavimento e excesso de carga transportado por veículos comerciais. No entanto, a partir dos dados apresentados, uma outra possível causa pode ser levantada: o dimensionamento pouco assertivo das camadas que compõem o pavimento rodoviário devido ao crescimento muito acelerado da frota nos últimos anos, dificultando o levantamento do fluxo de veículos juntamente com outros fatores como custo, precisão e sazonalidade. Dessa forma, a contagem de tráfego e principalmente a compreensão de todos os fatores que influenciam e são necessários para o dimensionamento é fundamental.

### **2.1.1 Tráfego Rodoviário**

O tráfego é responsável por grande parte dos danos causados ao pavimento ao longo de sua vida útil, devido a fatores como o volume de veículos, características de distribuição de eixos e rodas e das cargas aplicadas. Dessa forma, é fundamental compreender os principais tipos de veículos existentes. Classificam-se os veículos usuais em cinco categorias (Manual de Projeto de Interseções, DNIT, 2005, p. 79):

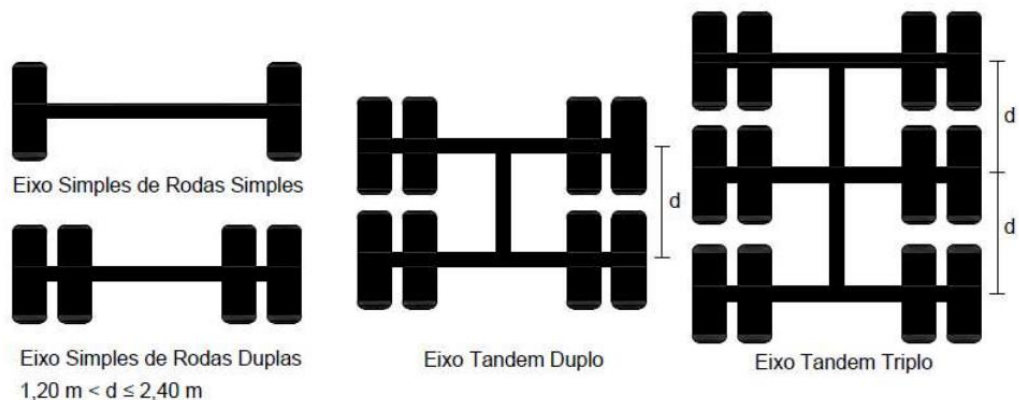
- Veículos leves (automóveis, incluindo minivans, vans, utilitários e pick-ups);
- Veículos comerciais rígidos não articulados (caminhões e ônibus convencionais);
- Veículos comerciais rígidos de maiores dimensões (caminhões e ônibus longos);
- Veículos comerciais articulados;
- Veículos comerciais com reboque.

Cada um desses tipos de veículos possui diferentes distribuições e conjuntos de eixos e rodas, sendo classificados isoladamente em quatro eixos:

- Eixo Simples de Rodas Simples (ESRS);
- Eixo Simples de Rodas Duplas (ESRD);
- Eixo tandem duplo (ETD);
- Eixo Tandem Triplo (ETT).

Na Figura 3 são apresentadas as configurações dos tipos de eixos.

Figura 3 - Principais tipos de eixos rodoviários



Fonte: (BOSSO, 2018, p. 20).

### 2.1.2 Avaliação das Solicitações de Tráfego

Para o dimensionamento do reforço de uma rodovia ou a realização de outras intervenções, é necessário que seja determinado o valor de "N", o qual representa o número de repetições de carga de um eixo padrão de 8,2 toneladas a que o pavimento estará sujeito ao longo de sua vida de serviço (Manual de Estudos de Tráfego, DNIT, 2006, p. 245). Dessa forma, os seguintes elementos devem ser levantados em relação ao tráfego de uma via:

- Projeção do Volume Diário Médio (VDM);
- Volume de cada tipo de conjunto de eixo e roda passante;

- Carregamento da Frota;
- Levantamento de faixa e sentido de maior presença de veículos comerciais.

O valor “N” é estabelecido conforme as Equações 1 ou 2, sendo a primeira considerando crescimento linear do tráfego durante o período de projeto e a segunda crescimento geométrico:

$$N = 365.VDM. \left[ \frac{(1 + P.t)^2 - 1}{2t} \right]. FV.Ff.Fs.Fd.Fr \quad (1)$$

$$N = 365.VDM. \frac{[(1 + t)^P - 1]}{\ln(1 + t)}. FV.Ff.Fs.Fd.Fr \quad (2)$$

Onde:

*FV* = Fator de Veículo

*Ff* = Fator de Frota

*Fs* = Fator de Sentido

*Fd* = Fator de Distribuição

*Fr* = Fator Climático Regional

*VDM* = Volume Diário Médio

*t* = Taxa de Crescimento

*P* = Período de Projeto

O Volume Diário Médio (*VDM*) é o volume de veículos total que passa por uma rodovia. A contagem é bidirecional e, conforme o DNIT, o mínimo é que três dias de contagem (24h/dia) sejam realizados, porém o recomendado são sete dias ininterruptos em uma semana típica e sem feriados. O Fator de Veículo (*FV*) é índice representativo do potencial destrutivo médio dos veículos comerciais que trafegam na rodovia em relação ao eixo padrão. A Taxa de Crescimento do Tráfego (*t*) é determinada a partir de dados históricos e pode ser considerado uma taxa de crescimento linear ou geométrica do tráfego. O Fator de Frota (*Ff*) é a porcentagem que os veículos comerciais representam do *VDM*. O Fator de Sentido (*Fs*) a porcentagem de veículos que trafegam em um sentido. O Fator de Distribuição (*Fd*) a proporção de veículos que passa pela pista mais carregada. O Fator Climático

Regional ( $F_r$ ) considera a variação da umidade dos materiais constituintes do pavimento durante o ano.

Para que seja possível o estabelecimento do valor “N”, é necessário determinar um fator de equivalência de carga (Fec) para cada tipo de composição de eixo roda. O cálculo da Fec pode ser baseado nos métodos dos fatores de equivalência de carga da American Association of State Highway Officials (AASHTO) ou US Army Corps of Engineers (USACE), atendendo aos critérios de serventia e de ruptura plástica respectivamente. O método de projeto estabelecido pelo DNIT (PRO 269/94) para dimensionamento utiliza os fatores de equivalência determinados pela USACE. As expressões para o cálculo dos fatores de equivalência de carga são apresentadas nas Figuras 4 e 5.

Figura 4 - Fatores de Equivalência de Carga do USACE

TIPO DE EIXO	FAIXA DE CARGAS (t)	EQUAÇÕES (P em tf)
Dianteiro simples e traseiro simples	0 – 8	$FC = 2,0782 \times 10^{-4} \times P^{4,0175}$
	$\geq 8$	$FC = 1,8320 \times 10^{-6} \times P^{6,2542}$
Tandem duplo	0 - 11	$FC = 1,592 \times 10^{-4} \times P^{3,472}$
	$\geq 11$	$FC = 1,528 \times 10^{-6} \times P^{5,484}$
Tandem triplo	0 - 18	$FC = 8,0359 \times 10^{-5} \times P^{3,3549}$
	$\geq 18$	$FC = 1,3229 \times 10^{-7} \times P^{5,5789}$
$P$ = Peso bruto total sobre o eixo		

Fonte: Manual de Restauração de Pavimentos Asfálticos, DNIT, 2006, p. 114.

Figura 5 - Fatores de Equivalência de Carga da AASHTO

TIPO DE EIXO	EQUAÇÕES (P em tf)
Simple de rodagem Simple	$FC = (P / 7,77)^{4,32}$
Simple de rodagem Dupla	$FC = (P / 8,17)^{4,32}$
Tandem duplo (rodagem dupla)	$FC = (P / 15,08)^{4,14}$
Tandem triplo (rodagem dupla)	$FC = (P / 22,95)^{4,22}$
$P$ = Peso bruto total sobre o eixo	

Fonte: Manual de Restauração de Pavimentos Asfálticos, DNIT, 2006, p. 114.

A aplicação dessas expressões para cada faixa de carga e de eixo dos veículos possibilita o cálculo do Fator de Veículo ( $FV$ ), calculado pela Equação 3:

$$FV = \frac{\sum_{i=1}^n (p_i(\%) \times FEC_{i,p})}{100} \quad (3)$$

Onde:

$FV$  = Fator de Veículo

$p_i(\%)$  = relação entre a quantidade de um tipo de eixo com a soma total de eixos

$FEC_{i,p}$  = Fator Equivalente de Carga

Assim, com o levantamento de quantidades de veículos, tipos de eixos e rodas, carga e análise histórica do crescimento de tráfego da rodovia, é possível determinar o valor “N”, o número de repetições de carga de um eixo padrão de 8,2 toneladas a que o pavimento estará sujeito ao longo de sua vida de serviço (período de projeto).

### 2.1.3 Pesagem de Veículos

O objetivo da pesagem é conhecer de que forma os veículos de carga solicitam o pavimento, ou seja, conhecer as cargas por eixo e, a partir disso, ser possível realizar análises estatísticas, fiscalização, controle, avaliação e dimensionamento do pavimento (Manual de Estudos do Tráfego, DNIT, 2006, p. 187).



Devido ao excesso de peso dos veículos de carga causarem transtornos a segurança, fluidez do tráfego e estruturas da via, é necessário haver uma caracterização que viabilize o controle de peso. Os excessos podem ser caracterizados de duas maneiras: o excesso no peso bruto total; e o excesso no peso por eixo. Veículos com peso bruto total acima do limite podem atuar contra a segurança nos seguintes aspectos: solicitar além do limite seus componentes como eixos, molas e freios; desgastar prematuramente seus equipamentos; trafegar em velocidades muito pequenas, prejudicando o tráfego dos veículos mais rápidos; e afetar a capacidade da via provocando trechos ondulados e montanhosos devido à baixa velocidade. O excesso de carga por eixo além de solicitar acima do esperado os componentes dos veículos, aumenta exponencialmente o efeito de carga no pavimento, reduzindo sua vida útil e afetando os custos com conservação e manutenção. O Quadro 1 abaixo mostra os valores de carga máximos estabelecidos desde a resolução nº 210/06 do CONTRAN.

Quadro 1 – Valores de carga máximas estabelecidas por eixo desde a resolução nº 210/06 do CONTRAN

<b>Eixo ou conjunto de eixos</b>	<b>Rodagem</b>	<b>Suspensão</b>	<b>Distância (d) entre eixos (m)</b>	<b>Carga máxima (t)</b>
Isolado	Simple	Direcional	-	6,0
Isolado	Dupla	-	-	10,0
Duplo	Simple	Direcional	-	12,0
Duplo	Dupla	Tandem	$1,2 < d \leq 2,4$	17,0
Duplo	Dupla	Não em tandem	$1,2 < d \leq 2,4$	15,0
Duplo	Simple + dupla	Especial	$d \leq 1,2$	9,0
Duplo	Simple + dupla	Especial	$1,2 < d \leq 2,4$	13,5
Triplo	Dupla	Tandem	$1,2 < d \leq 2,4$	25,5

Fonte: Adaptado (Bosso, 2018, p. 22).

Os efeitos negativos do excesso de carga justificam o controle de carga nas rodovias. Há, de acordo com o DNIT, duas formas de se realizar os procedimentos de pesagem: postos fixos e postos móveis.

Postos fixos são posicionados em praças de pesagem posicionadas em posições estratégicas possuindo infraestrutura e equipamentos de pesagem seletiva dinâmica como: balança de precisão, pátio de retenção e transbordo de carga. As vantagens dos postos fixos são a realização de uma fiscalização mais completa, pois é possível que opera 24h por dia, 7 dias por semana.

Postos móveis possuem equipamentos de pesagem transportáveis. Tendo como ponto negativo a não pesagem da totalidade dos veículos, realizando a verificação por amostragem. A vantagem desse procedimento é a não necessidade de grandes áreas e investimentos em instalações e equipamentos e a atuação em diversos pontos, minimizando o uso de rotas de fuga.

Para ambos os procedimentos há dois métodos de pesagem: pesagem estática e pesagem dinâmica. A pesagem estática é realizada com o veículo estacionado. Apesar de possuir ótima precisão e custo relativamente mais baixo, possui grandes dimensões e o tempo necessário para pesagem é elevado. A pesagem dinâmica possibilita que o veículo não pare durante o processo, porém é subdividido em pesagem seletiva e lenta. A pesagem seletiva permite realizar pesagens com veículos em velocidade até 60km/h, porém apenas daqueles que estão acima do permitido ou muito próximos do limite. A pesagem lenta, apesar de possibilitar de veículos em velocidades até 10km/h, permite a pesagem de um volume muito maior.

## 2.2 METODOLOGIA PARA AVALIAÇÃO DO TRÁFEGO

Conforme o DNIT, atualmente há quatro métodos de contagens volumétricas de veículos: Contagens Manuais, Contagens Automáticas, Videoteipe e Método do Observador Móvel. O objetivo dessa seção é apresentar o funcionamento de cada uma das quatro formas de levantamento de tráfego e suas respectivas vantagens e desvantagens.


### 2.2.1 Contagens Manuais

O método de contagem manual é realizado por pesquisadores, os quais, com o auxílio de fichas e contadores manuais, contam os veículos passantes por um determinado período. Este método tem a vantagem de possuir baixos custos, flexibilidade para a mudança de locais durante períodos curtos e fácil operação. No

entanto, é necessário que pessoas sejam alocadas durante dias para a execução de um trabalho bastante operacional, além de dificultar um levantamento por longos períodos. Sendo assim difícil obter conhecimento do comportamento do tráfego em períodos com variação devido a sazonalidade.

São utilizados dois modelos de fichas, a ficha I – anexo A possui os tipos de veículos e é utilizada para trechos com baixo volume de tráfego e é preenchida com traços a lápis conforme a passagem dos veículos. Ficha II – anexo B é utilizada juntamente com o apoio de um contador manual mecânico e é preenchida escrevendo os totais de passagem para cada tipo de veículo durante determinado período. A utilização de um contador manual possibilita dispensar anotações periódicas de dados durante o levantamento e reduzir o número de erros nos cálculos necessários. A Figura 6 apresenta de um modelo de contador manual.

Figura 6 – Modelo de contador manual utilizado para o levantamento de tráfego



Fonte: Manual de Estudos do Tráfego, DNIT, 2006.

Esse método é bastante utilizado para classificação de veículos, análise de movimentos em interseções e contagens em rodovias com várias faixas.

Para a determinação da amostra na utilização desse método é necessário se estabelecer um erro “tolerável”. A orientação estabelecida pelo DNIT segue os estudos feitos pela Road Research Laboratory em 1965 em Londres. Os Quadros 2 e 3 apresentam os níveis de precisão existentes e a relação de métodos possíveis de serem utilizados e sua precisão respectivamente.

Quadro 2 - Qualidade de estimativas de contagem

Nível de precisão	90% de probabilidade do erro não ultrapassar	Interpretação da estimativa
A	5%	Excelente
B	5% a 10%	Satisfatória para todas as necessidades normais
C	10% a 25%	Suficiente com estimativa grosseira
D	25 a 50%	Insatisfatória
E	mais de 50%	Inútil

Fonte: Manual de Estudos de Tráfego, DNIT, 2006.

Quadro 3 - Métodos manuais de contagem de volume


I – Usando Contadores Manuais			
Método	Nível de Precisão	Variações aceitáveis	Observações
(1) - Contagem durante 1 hora, em um dia de semana, entre 9 a.m. e 6 p.m.	D	A contagem pode ser estendida	
(2) - Contagem em um dia de semana, de 6 a.m. até 10 p.m.	C ou D		
(3) - Contagem entre 6 a.m. e 10 p.m. de 5ª Feira até Domingo	C	Pode ser estendida para dias incluindo 2ª Feira	Para a semana use 5 x 5ª + Sábado + Domingo
(4) - Contagem entre 6 a.m. e 10 p.m. em 7 dias consecutivos	C		
(5) - Métodos (1) a (4) em 4 vezes (6) - em intervalos de 3 meses (7) - (usando para (1) e (2) diferentes horas (8) - e dias)	C C B B	O número de vezes pode ser 2,3 ou 6 em vez de 4, alterando de forma semelhante o espaçamento	Calcule os totais de cada semana e então a média das 4 semanas
(9) - Contagem das 6 am às 10 pm de 52 em 52 dias durante 1 ano (7 contagens)	B		Estes métodos são de grande utilidade quando se tem que contar em vários pontos de uma mesma área. Podem ser feitas variações para atender a condições especiais
(10) - Contagem das 6 am às 10 pm de 26 em 26 dias durante 1 ano (14 contagens)	A ou B		
(11) - Contagem das 6 am às 10 pm de 13 em 13 dias durante 1 ano (28 contagens)	A		
(12) - Como em (9), mas divida o trecho do dia de interesse em 7 partes iguais (p. ex 2 horas. Em cada uma das 7 contagens conte uma parte, na ordem 1,4,7,3,6,2,5	C	Pode variar a parte em que inicia a contagem, mantendo a ordem, como 4,7,3,6,6,5,1, ou 3,6,2,5,1,4,7	
(13) - Como em (10) mas divida o trecho do dia de interesse em 14 partes iguais (por ex. 14 partes de 1 hora) e conte sucessivamente as partes 1,4,7,10,13,2,5,8,11,14,3,6,9,12	C		
(14) - Como em (11) divida o trecho do dia de interesse em 14 partes iguais e conte sucessivamente as partes 1,6,11,2,7,12,3,8,13,4,9,14, e então repita este ciclo	B		

Fonte: Manual de Estudos de Tráfego, DNIT, 2006.

### 2.2.2 Contagens Automáticas

Para a realização de contagens automáticas podem ser utilizadas diferentes contadores, os quais detectam os veículos através de tubos pneumáticos ou dispositivos magnéticos, sonoros, radar ou células fotoelétricas. Esses contadores são formados por dois componentes básicos: um detector de passagem de veículos e uma unidade acumuladora de dados. Além disso podem ser portáteis, conforme mostra a Figura 7, ou permanentes.

Figura 7 - Contador automático portátil “Hi-Star”



Fonte: Manual de Estudos do Tráfego, DNIT, 2006.

Os contadores automáticos possuem a desvantagem do alto custo e a exposição a roubos e vandalismos e a vantagem de possuírem uma alta precisão e possibilitarem a contagem tanto por tempos limitados quanto ilimitados.

Para a determinação da amostra na utilização de contadores automáticos, assim como no método de contagem manual, é necessário se estabelecer um erro “tolerável”. A orientação estabelecida pelo DNIT também segue os estudos feitos pela Road Research Laboratory, 1965, Londres. O Quadro 4 mostra a relação de métodos possíveis de serem utilizados e sua precisão respectivamente.

Quadro 4 - Métodos automáticos de contagem de volume

II – Usando Contadores Automáticas			
Método	Nível de Precisão	Variações aceitáveis	Observações
(1) - Contagem contínua durante uma semana	C		
(2) - 4 contagens contínuas de uma semana em intervalos de 3 meses	B	Substitua 4 contagens por 2, 3, ou 6, em intervalos adequados	
(3) - Contagem contínua durante um ano	A		

Fonte: Manual de Estudos de Tráfego, DNIT, 2006.

### 2.2.3 Videoteipe

O volume de tráfego também pode ser determinado através da utilização de filmagens do fluxo de veículo, sendo as principais vantagens da utilização desse método: maior confiança nos levantamentos, devido a possibilidade de comprovação dos dados, a necessidade de apenas um observador, maior conforto para o observador ao abrigo do tempo e a possibilidade de obtenção de outros dados de interesse. Apesar das vantagens apresentadas, a instalação da câmera pode demandar mais tempo do que o levantamento dos dados manualmente e, para simples contagens de veículos, pode ter um custo mais elevado em comparação com demais métodos.

### 2.2.4 Método do Observador Móvel

O método do observador móvel tem o objetivo de, ao invés de determinar a quantidade de veículos passantes em um ponto específico, determinar o volume passante por um trecho. Tem como vantagem o auxílio no estabelecimento de tempos e velocidades de percurso médias, sendo dessa forma mais utilizado em vias urbanas. No entanto, tem a desvantagem de ser aplicável apenas em vias de dois sentidos de tráfego, onde os veículos são visíveis o tempo todo. A aplicação do método consiste em um veículo-teste percorrer várias vezes o trecho, sendo registrado as seguintes informações:

- Número de veículos  $E_S$  que percorrem a via em sentido contrário;
- Número de veículos  $U_n$  que o ultrapassam;
- Número de veículos  $P_n$  ultrapassados pelo veículo-teste;
- Tempo de percurso  $T_n$  no sentido norte (min);
- Tempo de percurso  $T_S$  no sentido sul (min).

Após a coleta dessas informações é determinado o volume de tráfego  $V_n$ :

$$V_n = 60 \left( \frac{E_S + U_n - P_n}{T_n + T_S} \right) \quad (4)$$

### 2.3 INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA

A inteligência artificial (IA) apesar de parecer uma área de bastante crescimento apenas nos últimos anos teve início ainda durante a segunda guerra mundial. Alan Turing foi um dos pioneiros do seu desenvolvimento, com o artigo “Computing Machinery and Intelligence” em 1950. Turing, no artigo, apresenta um teste que possibilita avaliar a capacidade de uma máquina exibir comportamento inteligente e similar ao de um humano. Essa é justamente uma das inúmeras definições de inteligência artificial. Conforme Coppin (2010) “Inteligência Artificial envolve utilizar métodos baseados no comportamento inteligente de humanos e outros animais para solucionar problemas complexos”.

A partir de 1970, técnicas de IA começaram a ser mais utilizadas para a resolução de problemas, porém a principal abordagem era a de obtenção de conhecimento através de especialistas da área da qual se buscava solucionar os desafios e, a partir disso, desenvolver a lógica computacional. Para a resolução de problemas relativamente simples essa abordagem era o suficiente, porém conforme a elevação da complexidade e do volume de dados a serem utilizados, abordagens mais sofisticadas se tornaram necessárias. Ou seja, era necessário que formas menos dependentes de intervenção humana e principalmente de especialistas da área fossem utilizadas com o objetivo de, a partir de experiências passadas, o algoritmo ser capaz de criar uma hipótese para a resolução de problemas. A utilização do

processo de indução de hipótese se tornou conhecido como Aprendizado de Máquina (AM).

Aprendizado de máquina é definida por Mitchell (1997) como “A capacidade de melhorar o desempenho de uma tarefa por meio da experiência”, ou seja, os programas que fazem uso desses princípios aprendem conforme a realização das tarefas. Dessa forma, há diferentes aplicações de AM, como por exemplo: reconhecimento de fala, produção de programas com desempenho superior a grandes campeões em jogos, problemas logísticos, detecção de compras fraudulentas de cartões de crédito e previsão de taxas de cura de pacientes. Apesar da possibilidade de aplicar AM em diversas áreas, um dos fatores fundamentais para viabilizar sua utilização é o desenvolvimento da capacidade de processamento dos computadores, devido a necessidade de execução de milhares de tarefas durante períodos muito curtos. Por esse motivo que, conforme hardwares de processamento mais sofisticados foram lançados no mercado, a inteligência artificial e aprendizado de máquina se tornaram assuntos muito mais recorrentes.


Dentre os principais métodos de AM estão: aprendizagem supervisionada, aprendizagem não supervisionada, aprendizagem por reforço e redes neurais profundas. Cada um desses métodos é utilizado nas mais diversas áreas dependendo de fatores como complexidade do problema a ser solucionado e disponibilidade de dados. Neste trabalho será apresentado apenas o conceito e funcionamento das redes neurais profundas devido a sua fundamental aplicação para a realização do projeto.

### **2.3.1 Redes Neurais Profundas**

Conforme Haykin (2007, p. 28), “[...] uma rede neural é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse.”, ou seja, a rede neural aplicada na área computacional busca replicar o funcionamento dos neurônios do cérebro humano, o qual tem sua estrutura apresentada pela Figura 8.a. Os neurônios basicamente se comunicam através de impulsos detectados pelos dendritos, os quais são responsáveis pelo recebimento das informações, e repassar para o corpo da célula através do axônio. O axônio, ao dividir-se em colaterais, passa as informações para os dendritos de neurônios vizinhos conectados através das sinapses, conforme a apresentado da Figura 8.b.



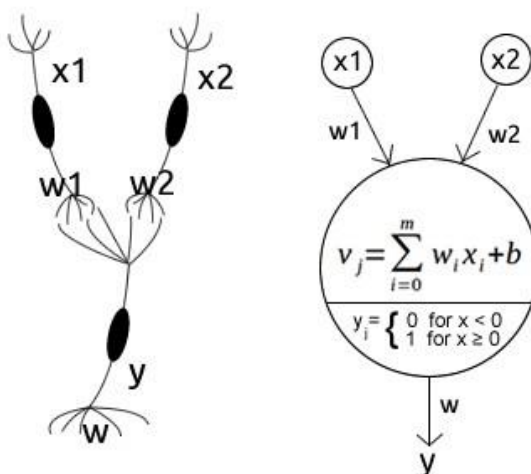
Figura 8 - Estrutura de um neurônio biológico



Fonte: Entendendo as Redes Neurais, Medium.com.

Para mostrar a similaridade do funcionamento entre as redes neurais computacionais e o neurônio cerebral, a rede neural mais simples, chamada Perceptron, foi utilizada. Conforme apresentado na Figura 9, a letra “x” representa as informações recebidas, a letra “w” as sinapses e “y” o valor final obtido.


Figura 9 - Comparação de uma rede neural biológica e artificial



Fonte: Entendendo as Redes Neurais, Medium.com.

De acordo com Haykin (2010, p.36), um neurônio é uma unidade de processamento de informação fundamental para o funcionamento da rede neural. A Figura 10 apresenta um modelo de um neurônio base de projetos de rede neural.

Figura 10 - Modelo de um neurônio artificial




Fonte: (Haykin, 2010, p. 36).

Há três componentes básicos do modelo neural:

- Um conjunto de valores de entrada ( $x$ ) e pesos ( $w$ );
- Um somador para definir o valor da adição de todos os conjuntos;
- Uma função de ativação, a qual tem o objetivo de restringir o valor de saída de um neurônio.

A partir desse modelo básico é possível a solução de problemas lineares, porém para solução de problemas não lineares é necessário que mais camadas de neurônios sejam adicionadas, sendo chamadas assim de camadas escondidas, formando a Rede Neural Multilayer Perceptron. Conforme apresentado na Figura 11, a sua estrutura é composta por dados de entrada (Inputs), camadas escondidas (Hidden Layers), formadas nesse caso por quatro neurônios, e a camada final (Output Layer) formada por dois neurônios, sendo ela responsável por obter o resultado do problema o qual quer se resolver.

Figura 11 – Perceptron multicamada com uma camada escondida



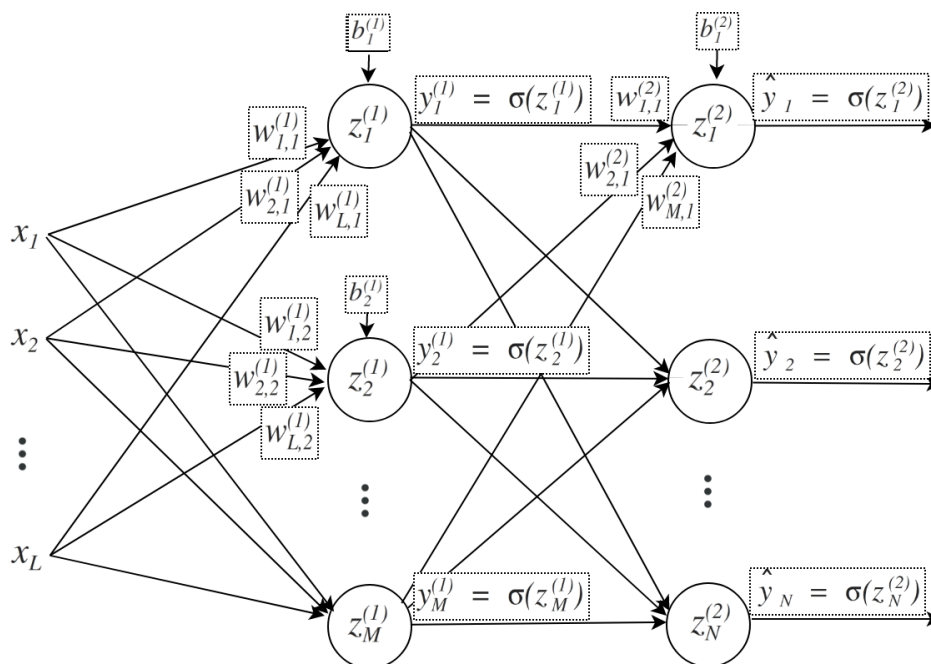
Fonte: Perceptron and Backpropagation, Medium.com.

O intuito da utilização de redes neurais é a determinação dos pesos ( $w$ ) que ao serem multiplicados pelos valores de entrada e os valores resultantes das camadas escondidas possam obter um valor de saída mais próximo do valor real. Dessa forma, para que seja possível que a rede neural aprenda com experiência passadas, uma grande quantidade de informações coletadas é utilizada e, para a determinação dos valores dos pesos que possibilitem a resolução do problema, o método de retropropagação é aplicado.

### 2.3.2 Retropropagação

A retropropagação funciona a partir da utilização do cálculo do erro de saída da rede neural em comparação com o valor real das informações de experiências passadas. Dessa forma os pesos podem ser ajustados de trás para frente utilizando a regra da cadeia e assim reduzir o erro para a próxima predição. A Figura 12 mostra todos os componentes presentes em uma rede neural: entradas ( $x_i$ ), pesos ( $w_{j,i}^n$ ), vieses ( $b_i^n$ ), resultados obtidos do somatório ( $z_i^n$ ), saídas de cada neurônio ( $y_i^n$ ) e as saídas ( $\hat{y}_i^n$ ).

Figura 12 - Exemplo do funcionamento da retropropagação de uma rede neural



Fonte: Redes Neurais, Perceptron Multicamadas e o Algoritmo Backpropagation, Medium.com.

O primeiro passo para a utilização da retropropagação é o estabelecimento de valores aleatórios para  $w_{j,i}^n$ . Com os pesos iniciais determinados é possível iniciar o processo de aprendizado da rede neural. Assim, são passados os valores de entrada ( $x_i$ ) para a rede e o processo de cálculo do somatório para cada neurônio é realizado conforme a Equação 5:

$$z_i^n = \sum x_i \times w_{j,i}^n + b_i^n \quad (5)$$

Após a obtenção do somatório de cada neurônio, o valor obtido é passado para uma função de ativação, a qual tem o objetivo de limitar o valor de saída do neurônio. Para apenas exemplificar o funcionamento será utilizada a função de ativação sigmoid, a qual segue a Equação 6 abaixo:

$$y_i^n = \frac{1}{1 + e^{-z_i^n}} \quad (6)$$

O resultado obtido de saída de cada neurônio ( $y_i^n$ ) é utilizado para a camada subsequente para o cálculo do seu respectivo resultado de saída. Após a obtenção

desse resultado, é então realizado o cálculo do erro entre o valor de saída obtido e o valor real conforme a Equação 7:

$$E(y_i^n, \hat{y}_i^n) = \sum (y_i^n - \hat{y}_i^n)^2 \quad (7)$$

Com o valor erro calculado, é então utilizada a regra da cadeia de trás para frente da rede neural para identificar de que forma o valor do erro final se comporta com a variação de cada um dos pesos das camadas. Assim, é possível realizar a alteração nos pesos de forma que o erro seja minimizado. A Equação 8 mostra um da regra da cadeia:

$$\frac{dE}{dw_{j,i}^n} = \frac{dE}{dz_i^n} \frac{dz_i^n}{dw_{j,i}^n} \quad (8)$$

Então, a partir de retropropagação e da utilização de informações de experiências passadas é possível ajustar os pesos da rede neural de forma a minimizar os erros obtidos entre os valores previstos e reais.

## 2.4 VISÃO COMPUTACIONAL


Visão computacional é uma área de aprendizado de máquina que visa obter informações a partir de vídeos e imagens através de tarefas como: classificação de imagens; identificação de diferentes objetos e sua localização; e identificação de eventos. Dessa forma, são utilizados algoritmos que possibilitem a extração das características presentes, como forma, textura e movimento. Para isso, um dos principais recursos computacionais utilizados são as redes neurais convolucionais.

Redes neurais convolucionais funcionam de forma muito semelhante as redes neurais, são compostas por pesos ( $w$ ) e vieses ( $b$ ), valores de entrada e de saída. A grande diferença é o fato de os valores de entrada serem imagens, o que permite que uma nova arquitetura de rede neural seja aplicada, obtendo excelentes resultados com uma eficiência no processamento muito maior.

No caso dos valores de entrada, ao invés de dados sobre um determinado assunto, são os valores de cores que formam uma imagem para cada pixel, ou seja, cada pixel é representado por uma matriz de três valores que variam entre 0 e 255

representando as cores vermelho, verde e azul. A Figura 13 apresenta a estrutura de valores que compõem uma imagem de dimensões 4x4.

Figura 13 - Imagem RGB separada em 3 planos (vermelho, verde e azul) de dimensões 4x4



Fonte: Capítulo 40 – Introdução as Redes Neurais Convolucionais. [deeplearningbook.com.br](http://deeplearningbook.com.br).

Conforme mencionado na seção anterior, as redes neurais são compostas pela camada de valores de entrada, a qual é representada por um único vetor, camadas escondidas, as quais são compostas por neurônios e completamente conectadas a camada anterior, e pela camada de valores de saída, que expressam a solução do problema. Se essa mesma estrutura fosse aplicada a imagens, o número de pesos seria muito grande. Por exemplo, a Figura 14 possui dimensões 500x334 pixels, como cada pixel é representado por três valores, o total de valores de entrada e, conseqüentemente, o número de pesos da primeira camada escondida é igual a  $500 \times 334 \times 3$ , totalizando em 501.000.


Figura 14 - Imagem utilizada para treinar a rede neural



Fonte: ImageNet. image-net.org.

Redes Neurais Convolucionais, diferentemente das redes neurais convencionais (Figura 15.a), utilizam o formato tridimensional das imagens em sua arquitetura. Dessa forma, são compostas por um comprimento, largura e profundidade conforme está representado na Figura 15.b.

Figura 15 - Estrutura de uma rede neural convencional (a) e uma rede neural convolucional (b)




Fonte: Stanford University. CS231 Convolutional Neural Networks for Visual Recognition. 2018.

Cada camada das redes convolucionais transforma essas dimensões. As principais camadas utilizadas são de Convolução, Pooling e camadas completamente conectadas (como nas redes neurais convencionais). Ao serem empilhadas essas camadas a arquitetura da rede é formada.

A camada de convolução funciona através de filtros, os quais percorrem toda a extensão da imagem em busca de traços e características mais marcantes. Filtros são matrizes formadas por valores (pesos) que multiplicam os valores RGB de cada pixel ao longo de diversas partes de uma imagem. A Figura 16 mostra um exemplo do funcionamento de um filtro.

Figura 16 - Exemplo de funcionamento de um filtro em redes neurais convolucionais



Fonte: Adaptado Stanford University. CS231 Convolutional Neural Networks for Visual Recognition. 2018.

Conforme apresentado na Figura 16, o filtro W0 é formado por valores pesos e possui dimensões 3x3x3, sendo que cada uma das três dimensões de profundidade multiplicam uma região de dimensão 3x3 de cada uma das dimensões de valores



vermelho, verde e azul. As Equações 9, 10, 11 e 12 mostram matematicamente o que está representado na Figura 16.

$$x[:, :, 0] \times w0[:, :, 0] =$$

$$1 \times -1 + 0 \times -1 + 1 \times -1 + 1 \times 1 + 0 \times 0 + 1 \times 0 + 1 \times -1 + 2 \times 1 + 2 \times -1 = -2 \quad (9)$$

$$x[:, :, 1] \times w0[:, :, 1] =$$

$$0 \times 0 + 1 \times 0 + 0 \times -1 + 1 \times -1 + 0 \times -1 + 0 \times -1 + 1 \times 1 + 2 \times -1 + 0 \times -1 = -2 \quad (10)$$

$$x[:, :, 2] \times w0[:, :, 2] =$$

$$1 \times -1 + 2 \times -1 + 1 \times 1 + 0 \times 0 + 1 \times 0 + 0 \times 1 + 2 \times -1 + 2 \times -1 + 0 \times -1 = -6 \quad (11)$$

$$x[:, :, 0] \times w0[:, :, 0] + x[:, :, 1] \times w0[:, :, 1] + x[:, :, 2] \times w0[:, :, 2] + b0 = -2 - 2 - 6 + 1 = 9 \quad (12)$$

No artigo “ImageNet Classification with Deep Convolutional Neural Networks“, escrito por Alex Krizhevsky, Ilya Sutskever e Geoffrey E. Hinton, o qual tem o objetivo de desenvolver uma rede neural capaz de classificar mais de 1000 tipos de objetos diferentes, é apresentado visualmente quais as formas que os 96 filtros com dimensões 11x11x3 da primeira camada convolucional buscam em uma imagem após a realização do treino da rede neural. A Figura 17 apresenta as formas dos 96 filtros.


Figura 17 - 96 filtros com dimensões 11x11x3 utilizados para identificação de diferentes formas e colorações em uma imagem



Fonte: Krizhevsky, A., ImageNet Classification with Deep Convolutional Neural Networks, 2012.

Além das convoluções, uma outra etapa realizada é o “Pooling”, o qual tem o objetivo de reduzir o tamanho das matrizes geradas, mantendo as características mais importantes, o que, conseqüentemente, auxilia no aumento da velocidade de processamento. Na Figura 18 é apresentado um tipo de “Pooling”, o qual, a partir de uma matriz, são seleccionados os valores mais elevados para cada parte em um filtro de dimensões 2x2.


Figura 18 - Exemplo do funcionamento da camada "Pooling"



Fonte: Stanford University. CS231 Convolutional Neural Networks for Visual Recognition. 2018.

A camada completamente conectada é utilizada nas últimas camadas e possui o mesmo funcionamento das redes neurais mais simples. A Figura 19 exemplifica uma seqüência de camadas de uma rede neural convolucional.

Figura 19 - Arquitetura geral de uma rede neural convolucional



Fonte: STROSKY, P. O que são redes neurais convolucionais?. electricallibray.com.

### 3 METODOLOGIA

Evidenciada a importância da contagem de tráfego na qualidade das rodovias brasileiras e de que forma a visão computacional pode ser aplicada no auxílio dessa tarefa, buscou-se desenvolver um programa computacional que, através de gravações do fluxo de veículos de uma rodovia, pudesse levantar as principais informações do tráfego: volume de cada tipo de veículo e volume de cada tipo de eixo passante por sentido. Dessa forma, esta seção tem o objetivo de apresentar detalhadamente cada uma das etapas necessárias para o desenvolvimento do programa computacional:

- Levantamentos de campo de tráfego;
- Recursos Computacionais;
- Treinamento da rede neural;
- Abordagens para solução do problema.

#### 3.1 LEVANTAMENTOS DE CAMPO DE TRÁFEGO

O levantamento de campo de tráfego teve o objetivo de coletar gravações do tráfego de dois pontos da BR-158: O Trevo dos Quartéis, localizado na BR-158, Santa Maria – RS e a Polícia Rodoviária Federal (PRF), BR-158, km 319, Santa Maria – RS. Os dois pontos foram escolhidos por serem passagem de um volume de veículos de carga representativo e possuírem áreas afastadas da rodovia de forma que garantisse uma boa amplitude para a câmera e segurança.

Para a realização dos dois levantamentos de tráfego foram utilizados apenas três equipamentos: um tripé de câmera, com altura máxima de 1,4m; um celular Samsung Galaxy S8 SM-G950FD; e um suporte para fixar celular ao tripé. O celular utilizado possui algumas características que estão apresentadas nos Quadros 5 e 6:

Quadro 5 – Características do hardware do celular utilizado como câmera (Samsung Galaxy S8 SM-G950FD)

<b>Hardware e memória</b>	
<b>Arquitetura - Chipset</b>	64bits - Samsung Exynos 9 Octa 8895 (10nm)
<b>CPU Processador / Núcleos</b>	<b>Octa-Core</b> , 2 processadores: - 2.3Ghz Quad-Core Exynos M2 Mongoose - 1.7Ghz Quad-Core ARM Cortex-A53
<b>GPU Placa Gráfica</b>	ARM Mali-G71 MP20 550Mhz
<b>Memória RAM</b>	4GB LPDDR4
<b>Memória Interna</b>	64GB (51GB acessível pelo usuário) UFS 2.1
<b>Memória Externa</b>	Até 512GB microSD, microSDHC, microSDXC (híbrido, usa o mesmo slot do cartão SIM-2)

Fonte: Mais Celular. Samsung Galaxy S8 SM-G950FD. maiscelular.com.

Quadro 6 - Características da tela do celular utilizado como câmera (Samsung Galaxy S8 SM-G950FD)

<b>Tela</b>	
<b>Tipo da tela</b>	Super AMOLED
<b>Tamanho em polegadas</b>	5.8" polegadas
<b>Resolução da tela</b>	1440x2960 pixels
<b>Densidade (pixels por polegadas)</b>	568 PPI

Fonte: Mais Celular. Samsung Galaxy S8 SM-G950FD. maiscelular.com.

Todas as gravações foram feitas durante o período do dia, com bom tempo e no formato VGA – 640x480. Essa resolução inferior foi utilizada, pois, caso a resolução das filmagens fosse superior, maior seria o tempo de processamento de treino das redes neurais utilizadas e da execução do próprio programa.

### 3.1.1 Levantamento de campo de tráfego – Trevo dos Quartéis

O primeiro levantamento de campo realizado foi durante o período da tarde próximo ao Trevo dos Quartéis, localizado na BR-158, Santa Maria – RS, rodovia composta por duas pistas com duas faixas cada. O objetivo dessa primeira gravação foi coletar vídeos de apenas uma das pistas de visões diferentes em relação a rodovia por períodos curtos, entre 4min e 11min. Esses vídeos tem a finalidade de auxiliar na etapa de desenvolvimento do programa, principalmente na definição da melhor abordagem para desenvolvimento do algoritmo e resolução do problema. As Figuras 20, 21 e 22 abaixo mostram frames das diferentes posições da câmera:

Figura 20 - Imagem da primeira gravação realizada diagonal e de frente para os veículos



Fonte: O Autor.

Figura 21 - Imagem da primeira gravação realizada perpendicularmente a pista



Fonte: O Autor.

Figura 22 - Imagem da primeira gravação realizada diagonal e de costas para os veículos



Fonte: O Autor.

Foram realizadas no total 39min e 27seg de gravações divididos em cinco partes diferentes com os seguintes tempos: 7min e 37seg, 4min e 03seg, 7min e 24seg, 10min e 27seg, 9min e 56seg. O tempo das gravações variaram conforme as diferentes situações apresentadas, como os tipos de veículos que passaram durante o período ou conforme situações do ambiente que necessitaram interromper e/ou reposicionar a câmera, como a passagem muito lenta ou parada de caminhões coordenados por funcionários da prefeitura que estavam trabalhando na via.

Além de serem utilizadas para auxiliarem no processo de desenvolvimento do programa computacional, frames dos vídeos foram utilizados para o treinamento da rede neural de identificação de eixos, etapa a qual será melhor explicada na seção 3.3.

### **3.1.2 Levantamento de campo de tráfego – BR-158, km 319, PRF**

O segundo levantamento de campo realizado durante o período da manhã foi próximo à Polícia Rodoviária Federal, localizada na BR-158, km 319, Santa Maria – RS, rodovia composta por uma pista com duas faixas de sentidos opostos. A gravação dessa via teve o objetivo de servir como teste do programa computacional desenvolvido com o auxílio do primeiro levantamento. Logo, com o objetivo de apresentar o maior número de situações diferentes, a filmagem foi feita no maior tempo possível conforme a capacidade da bateria do celular utilizada para gravar, totalizando 4 horas. A Figura 23 apresenta uma imagem da visão da câmera durante a gravação do fluxo.

Figura 23 - Visão da câmera durante a gravação do fluxo no segundo levantamento de tráfego



Fonte: O Autor.

Após a gravação do tráfego da via, realizou-se a contagem de veículos e eixos durante todo o período de 4 horas. Esse resultado da contagem manual, será comparado com o resultado a ser obtido pelo programa computacional, e, assim, determinar as diferenças nos valores encontrados, calcular o erro, analisar a eficácia do programa e pontos que podem ser alterados para melhorar os resultados em estudos futuros.

### 3.2 RECURSOS COMPUTACIONAIS

Para o desenvolvimento do programa computacional escolheu-se a linguagem de programação Python. Além de ser amplamente utilizada em projetos de ciência de dados e de aprendizado de máquina, Python, ao longo dos anos, tem se tornado cada vez mais popular. Desde 2012 é a linguagem de programação com maior crescimento em popularidade em países com alta renda (Stackoverflow, 2017).

Utilizou-se Python para este projeto devido à grande facilidade de aprendizado, ser gratuitamente disponibilizado e por grande parte dos materiais relacionados a AM ser apresentado nessa linguagem.



Além da definição da linguagem de programação, foi necessária a escolha de outras aplicações e plataformas. O objetivo desta seção é apresentar os principais componentes computacionais do projeto.

### 3.2.1 Anaconda

O “Anaconda Distribution”, é uma plataforma de código aberto que tem o objetivo de facilitar tarefas executadas em ciência de dados e aprendizado de máquina em Python/R e nos SO Linux, Windows e Mac OS X. Conforme apresentado no site oficial, a plataforma possibilita:

- Baixar rapidamente mais de 1.500 pacotes de ciência de dados do Python/R;
- Gerenciar bibliotecas, dependências e ambientes;
- Desenvolver e treinar modelos de aprendizado de máquina e aprendizagem profunda com Scikit-learn, TensorFlow e Theano;
- Analisar dados com escalabilidade e desempenho;
- Visualizar resultados com Matplotlib, Bokeh, Datashader e Holoviews.

O “Anaconda Distribution” pode ser instalado através do site [www.anaconda.com/distribution](http://www.anaconda.com/distribution). Essa plataforma é de fundamental importância para instalação da linguagem python, Jupyter Notebook, Tensorflow assim como demais bibliotecas (subprogramas utilizados em desenvolvimento de softwares) usadas para o desenvolvimento do programa computacional: Numpy; Pandas; Pillow; lxml; Jupyter; Matplotlib; e Opencv.

### 3.2.2 Jupyter Notebook

O Jupyter Notebook, de acordo com seu site oficial, “[...] é um aplicativo da Web de código aberto que permite criar e compartilhar documentos que contêm código em diferentes linguagens de programação, equações, visualizações e texto narrativo. Pode ser utilizado para limpeza e transformação de dados, simulação numérica, modelagem estatística, visualização de dados e aprendizado de máquina”. Utilizando-se o Jupyter que o código do programa do projeto foi escrito e executado.

### 3.2.3 You Only Look Once (YOLO)

You Only Look Once (YOLO) é um sistema de detecção de objetos em tempo real desenvolvido por Joseph Redmon, Santosh Divvala, Ross Girshick e Ali Farhadi da Universidade de Washington em 2016. A YOLO utiliza apenas uma única rede neural para identificar e detectar diferentes objetos além de considerar características de toda imagem, tornando o processamento mais rápido em comparação com outros sistemas de detecção de objetos e ao mesmo tempo consideravelmente preciso (You Only Look Once: Unified, Real-Time Object Detection, 2016, p. 2). Desde 2016 esse Sistema foi atualizado algumas vezes e sua última versão foi apresentada em 2018 (YOLOv3: An Incremental Improvement, 2018)

No site [www.pjreddie.com](http://www.pjreddie.com) há os modelos pré-treinados da YOLO a partir do conjunto de imagens da Microsoft Common Objects in COntext (MS COCO). Esse banco de imagens possui 91 categorias de objetos e 328.000 imagens (Microsoft COCO: Common Objects in Context, 2015, p. 2). Dentre as 91 categorias estão presentes: motocicletas, carros, ônibus e caminhões. Logo, para identificação desses objetos não será necessário treinar uma rede neural.

### 3.2.4 Tensorflow

Para auxiliar no desenvolvimento do detector de rodas utilizou-se a plataforma Tensorflow, disponibilizada pelo Google gratuitamente. Conforme descreve o site oficial da plataforma “TensorFlow é uma plataforma de código aberto para aprendizado de máquina. Possui um ecossistema abrangente e flexível de ferramentas, bibliotecas e recursos da comunidade que permite que os pesquisadores promovam outras descobertas na área de AM e que os desenvolvedores criem e implementem facilmente aplicativos baseados em AM”.

Tensorflow foi escolhida para o desenvolvimento deste projeto devido à grande praticidade na instalação e, também, ser mais facilmente encontrado materiais explicativos e que possibilitem a utilização com o Sistema Operacional (SO) Windows.

### 3.2.5 Opencv

O OpenCV (Open Source Computer Vision Library), conforme seu site oficial, [www.opencv.org](http://www.opencv.org), é uma biblioteca de software de visão computacional e aprendizado de máquina de código aberto. O OpenCV tem o objetivo de fornecer infraestrutura comum para aplicativos de visão computacional e acelerar o uso da percepção da máquina nos produtos comerciais. A biblioteca é amplamente utilizada em empresas, grupos de pesquisa e órgãos governamentais, possuindo interfaces C++, Python, Java e MATLAB e suportando os sistemas operacionais Windows, Linux, Android e Mac.

O OpenCV é uma biblioteca extremamente útil para as mais variadas situações, como detectar intrusões em câmeras de vigilância, monitorar equipamentos de minas, ajudar robôs a navegar e pegar objetos, detectar acidentes e situações como afogamentos em piscinas e inspecionar rótulos de produtos de fábricas.

Apesar de possuir um escopo bastante distinto das situações citadas acima, este projeto também necessita de sua utilização para mais facilmente desenvolver o programa e alcançar melhores resultados. Foram usadas duas funcionalidades principais: detecção e identificação de objetos (atuando juntamente com a YOLO e Tensorflow) e o rastreamento de objetos em movimento.

## 3.3 TREINAMENTO DA REDE NEURAL CONVOLUCIONAL

Neste trabalho a utilização de rede neurais convolucionais tiveram duas tarefas: detectar e diferenciar veículos entre carros, ônibus e caminhões e detectar a presença de rodas. Para detectar e diferenciar veículos não foi necessário treinar uma rede neural, visto que foi utilizada uma pré-treinada para a diferenciação desses objetos com a utilização de um sistema de detecção de objetos em tempo real, conhecida como You Only Look Once (YOLO). Logo, esta seção tem o objetivo de apresentar as etapas necessárias para a execução do treinamento da rede neural convolucional responsável pela detecção de rodas.

Conforme apresentado na seção dos recursos computacionais, a plataforma Tensorflow foi a escolhida para desenvolver o modelo (rede neural convolucional) de detecção de rodas. As orientações de instalação e utilização da plataforma foram retiradas do site “[www.tensorflow-object-detection-api-tutorial.readthedocs.io](http://www.tensorflow-object-detection-api-tutorial.readthedocs.io)” da

seção “Training Custom Object Detector”. Todo o processo segue as seguintes etapas:

- Instalação dos recursos necessários
- Organização da área de trabalho
- Coleta, transformação e anotação de imagens
- Configuração do modelo pré-treinado e geração de arquivos
- Treinamento e exportação do modelo final

### **3.3.1 Instalação dos recursos necessários**

Há duas variações do TensorFlow, que utilizam diferentes partes de processamento (hardware) do computador para executar algoritmos de AM computacionalmente pesados. A mais simples de instalação, porém com desempenho inferior, é a “Tensorflow CPU”, a qual é processada diretamente na Unidade Central de Processamento (CPU). Há também a “Tensorflow GPU”, que realiza o processamento de forma muito mais rápida na Unidade Gráfica de Processamento (GPU), sendo que, para viabilizar a sua utilização, é necessário que haja um cartão gráfico Nvidia. Apesar do computador utilizado possuir um cartão gráfico Nvidia, não foi possível utilizar a “Tensorflow GPU” devido à dificuldade de instalação no SO Windows e, possivelmente, pelo cartão gráfico não ser da versão mínima necessária. Por esses motivos a “Tensorflow CPU” foi a escolhida para o desenvolvimento da rede neural convolucional responsável pela identificação de rodas.

Após a escolha e instalação de uma das variações da plataforma, instalou-se as bibliotecas conforme o Quadro 7. Os modelos utilizados pelo Tensorflow e Protocol Buffers, o qual é um método de serialização de dados estruturados necessários para configurar os modelos e parâmetros de treinamento, também foram instalados nessa etapa.

Quadro 7 - Bibliotecas utilizadas para o treinamento e desenvolvimento do programa computacional

<b>Pacotes</b>	
<b>Nome</b>	<b>Versão</b>
pillow	5.4.1-py36hdc69c19_0
lxml	4.3.1-py36h1350720_0
jupyter	1.0.0-py36_7
matplotlib	3.0.2-py36hc8f65d3_0
opencv	3.4.2-py36h40b0b35_0

Fonte: Tensorflow Object Detection API tutorial, 2018.

Posteriormente, instalou-se o programa “Labellmg”, utilizado para auxiliar na anotação de imagens, que será melhor explicado na seção 3.3.3.

### 3.3.2 Organização da área de trabalho

Conforme apresentado no tutorial utilizado para instalação dos recursos computacionais, é fundamental que os diretórios que contenham todos os arquivos em utilização sejam corretamente organizados para que a execução do treinamento ocorra adequadamente. Dessa forma, deve-se criar uma pasta de trabalho (workspace) aonde efetivamente estarão as imagens e arquivos a serem gerados e utilizados para o treinamento. A pasta com os arquivos utilizados segue a estrutura da Figura 24:

Figura 24 - Organização dos diretórios para execução do treinamento da rede neural

```

TensorFlow
├─ addons
│  └─ labelImg
├─ models
│  ├─ official
│  ├─ research
│  └─ samples
├─ tutorials
└─ workspace
    └─ training_demo
        ├─ annotations
        ├─ images
        │  ├─ test
        │  └─ train
        ├─ pre-trained-model
        └─ training
            └─ README.md

```

Fonte: Tensorflow Object Detection API tutorial, 2018

As finalidades de cada um dos diretórios contidos na pasta de trabalho apresentadas pela Figura 24 são:

- annotations: Pasta usada para armazenar todos os arquivos \* .csv e os respectivos arquivos TensorFlow \* .record, que contêm a lista de anotações para as imagens do conjunto de dados;
- images: Contém uma cópia de todas as imagens do conjunto de dados, bem como os respectivos arquivos \* .xml produzidos para cada um;
- images \ train: Contém uma cópia de todas as imagens e os respectivos arquivos \* .xml usados para treinar nosso modelo;
- images \ test: Esta pasta contém uma cópia de todas as imagens e os respectivos arquivos \* .xml usados para testar nosso modelo;
- pre-trained-model: Contém o modelo pré-treinado de nossa escolha usado como um ponto de verificação inicial para o trabalho de treinamento;
- Treinamento: Contém o arquivo de configuração de treinamento \* .config, bem como um arquivo de mapa de rótulos \* .pbtxt e todos os arquivos gerados durante o treinamento do modelo;

- README.md: Arquivo opcional que fornece informações gerais sobre as condições de treinamento do modelo.

### 3.3.3 Coleta, transformação e anotação de imagens

Para que seja possível a realização do treinamento da rede neural convolucional para a detecção de rodas, coletou-se imagens que esteja presente o objeto e se anotou cada uma, ou seja, marcou-se as regiões da imagem que as rodas se encontram. Logo, o primeiro passo nesta etapa foi a coleta de imagens. Coletou-se imagens que apresentassem veículos em posição similar as gravações utilizadas no teste do programa computacional, ou seja, perpendicular a câmera. Essa posição melhor viabiliza a identificação dos eixos como também a diferenciação de cada um deles em ESRS, ESRD, ETD e ETT pelo programa desenvolvido.

As imagens utilizadas nesse projeto foram obtidas através de frames do primeiro levantamento de tráfego, fotografias tiradas ao longo da BR 290 (trecho Porto Alegre-RS e Capão da Conoa-RS), fotografias de vias movimentadas do bairro São João em Porto Alegre, do site Image-net.org (organizado banco de imagens usado por pesquisadores e trabalhos acadêmicos em todo o mundo) e um conjunto de imagens da “ExDark Dataset” (Computer Vision and Image Understanding, 2019).

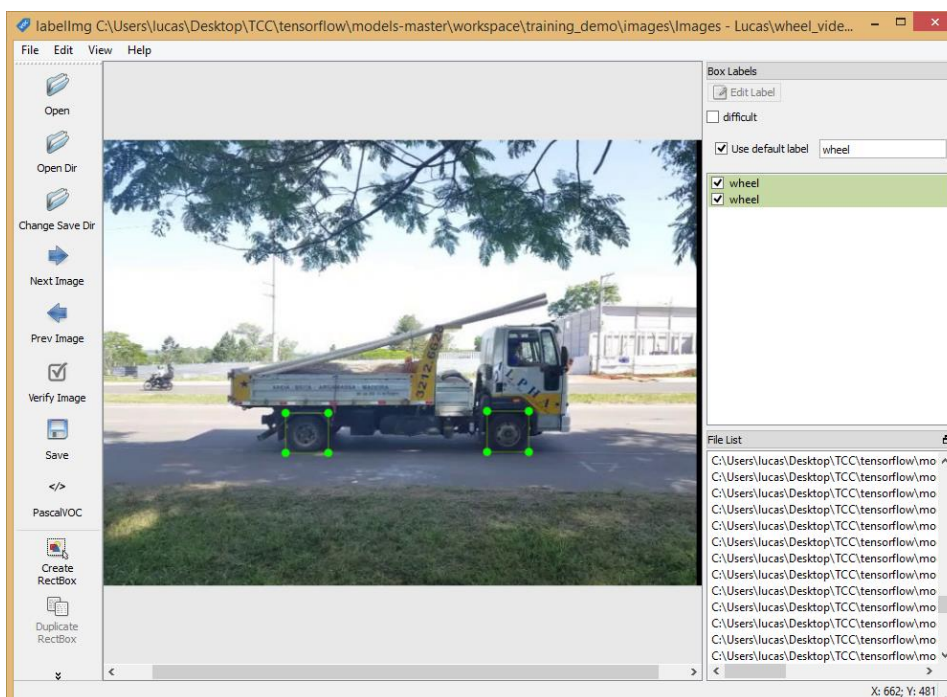
O “ExDark Dataset” é composto por 7.363 imagens de 12 objetos diferentes, porém, neste projeto, apenas imagens referentes a ônibus foram usadas. Diferentemente das demais imagens coletadas, esse conjunto de imagens apresenta imagens com baixa luminosidade, as quais servem para melhorar detecção de rodas em situações similares durante o vídeo teste.

Após a coleta das imagens foi necessária a transformação de suas dimensões, visto que imagens muito grandes além de aumentarem o tempo de processamento, podem não agregar valor na detecção do objeto. Durante todo o processo de treinamento diferentes tamanhos foram utilizados. Primeiramente os tamanhos permaneceram iguais aos originais, porém, devido ao grande tempo de processamento ou até mesmo a incapacidade de processar devido à grande quantidade de memória necessária, dimensões de 500 e 300 pixels de altura foram utilizadas.

Com a execução da coleta e redimensionamento das imagens, todas as rodas presentes foram marcadas. No total foram utilizadas para treinamento

aproximadamente 905 imagens considerando todas as tentativas. A Figura 25 apresenta um exemplo desse processo de marcação com uso do programa Labellmg. O programa foi configurado para gerar arquivos estruturados em formato Pascal/VOC para ser corretamente interpretado pelo Tensorflow.

Figura 25 - Janela do programa Labellmg para a marcação das rodas nas imagens selecionadas para treinamento da rede neural




Fonte: O Autor.

Após realizada a marcação das rodas na imagem, um arquivo .txt estruturado em formato Pascal/VOC foi gerado possuindo valores da posição de cada uma das rodas. A Figura 26 apresenta uma parte das imagens coletadas.



Figura 26 – Parcela das imagens utilizadas para o treinamento da rede neural



Fonte: O Autor.

Apesar de pastas com imagens para treino e teste terem sido criadas separadamente, não foi realizada nenhuma separação no desenvolvimento deste projeto. A gravação referente ao segundo levantamento de campo de tráfego servirá como teste da detecção de rodas da rede neural convolucional treinada através da plataforma Tensorflow.

### 3.3.4 Configuração do modelo pré-treinado e geração de arquivos

Nesta etapa foram criados os arquivos “label\_map”, convertidos os arquivos formato texto das anotações para o formato TFRecord e foram feitas as alterações necessárias nas configurações do modelo pré-treinado utilizado.

O arquivo “label\_map” foi criado com o formato .pbtxt. É utilizado para mapear cada um dos objetos a um valor inteiro e para o processo de treinamento e detecção. Como apenas um único objeto está sendo identificado, apenas a roda será relacionada a um valor. A Figura 27 abaixo apresenta as informações contidas no arquivo.

Figura 27 - Informações contidas no arquivo "label\_map.pbtxt"

```

    item {
      id: 1
      name: 'wheel'
    }

```

Fonte: O Autor.

Para a geração do arquivo com formato TFRecord utilizou-se os códigos disponibilizados no site com as orientações seguidas para toda etapa de treinamento. Dois códigos foram utilizados nesta etapa: um para consolidar todas as imagens anotadas em um arquivo em formato .csv; e um para efetivamente gerar o arquivo TFRecord. Para a execução dos códigos que possibilitassem a geração dos arquivos .csv e .TFRecord, utilizou-se a prompt de comando do Anaconda e se inseriu os comandos de execução disponibilizados no tutorial com os respectivos caminhos das pastas conforme apresenta a Figura 28.

Figura 28 - Código utilizado para exportação dos arquivos .csv e .TFRecord

```

# Cria arquivo .csv:
python xml_to_csv.py -i [PATH_TO_IMAGES_FOLDER]/train -o [PATH_TO_ANNOTATIONS_FOLDER]/train_labels.csv

# Cria arquivo TFRecord:
python generate_tfrecord.py --label=<LABEL> --csv_input=<PATH_TO_ANNOTATIONS_FOLDER>/train_labels.csv
--img_path=<PATH_TO_IMAGES_FOLDER>/train --output_path=<PATH_TO_ANNOTATIONS_FOLDER>/train.record

```

Fonte: Tensorflow Object Detection API tutorial, 2018.

Por fim, na etapa de configuração do modelo pré-treinado e geração de arquivos, foi escolhido um modelo pré-treinado e disponibilizado pelo Tensorflow e alterada suas configurações de forma que viabilize o treinamento para a identificação de rodas. Os modelos disponibilizados podem ser encontrados no site [www.github.com/tensorflow](http://www.github.com/tensorflow) e são pré-treinados a partir de um dos seguintes bancos de imagem: COCO dataset, Kitti dataset; Open Images dataset; AVA v2.1 dataset; ou iNaturalist Species Detection Dataset. Além de serem treinados com banco de imagens diferentes, os modelos têm características de precisão e velocidade distintos. Cada modelo é apresentado com as seguintes informações:

- Nome do modelo;
- Link de download para um arquivo tar.gz contendo o modelo pré-treinado;
- Velocidade do modelo em tempo de execução em microssegundos (ms) por imagem 600x600 utilizando um cartão Nvidia GeForce GTX TITAN X;
- Desempenho do detector em média das médias de precisão (Mean Average Precision - mAP);
- Tipos de saída (caixas ou máscaras).

O Quadro 8 apresenta alguns dos modelos pré-treinados com imagens do conjunto COCO-dataset disponíveis:

Quadro 8 - Modelos pré-treinados disponibilizados pelo COCO-dataset

<b>Nome do Modelo</b>	<b>Velocidade (ms)</b>	<b>Desempenho (mAP)</b>	<b>Saída</b>
ssd_mobilenet_v1_coco	30	21	Boxes
ssd_mobilenet_v1_0.75_depth_coco	26	18	Boxes
ssd_mobilenet_v1_quantized_coco	29	18	Boxes
faster_rcnn_inception_v2_coco	58	28	Boxes
ssd_inception_v2_coco	42	24	Boxes

Fonte: O Autor.

Neste projeto optou-se pelo modelo “ssd\_inception\_v2\_coco”, pois além de utilizado no tutorial, possui teoricamente velocidades e desempenho adequados para detecção em vídeos. Com o modelo escolhido, as alterações do arquivo .config podem ser feitas e devem seguir as etapas conforme indica o tutorial. É necessário alterar, principalmente, a quantidade de objetos a serem identificados de 90 para 1, o “batch size” o qual indica o número de imagens a passarem pelo modelo antes de haver ajuste dos pesos (quanto maior o número, mais capacidade de processamento é

necessária) e os locais em que se encontram cada um dos arquivos necessários para treinamento.

### 3.3.5 Treinamento e exportação do modelo final

Com os arquivos devidamente gerados e configurados foi possível iniciar o treinamento para exportar posteriormente o modelo com os pesos ajustados para identificação de rodas. Para ocorrer o processo de treinamento, o código utilizado foi o disponibilizado no site do tutorial e executado através do prompt de comando do Anaconda com comando apresentado na Figura 29:

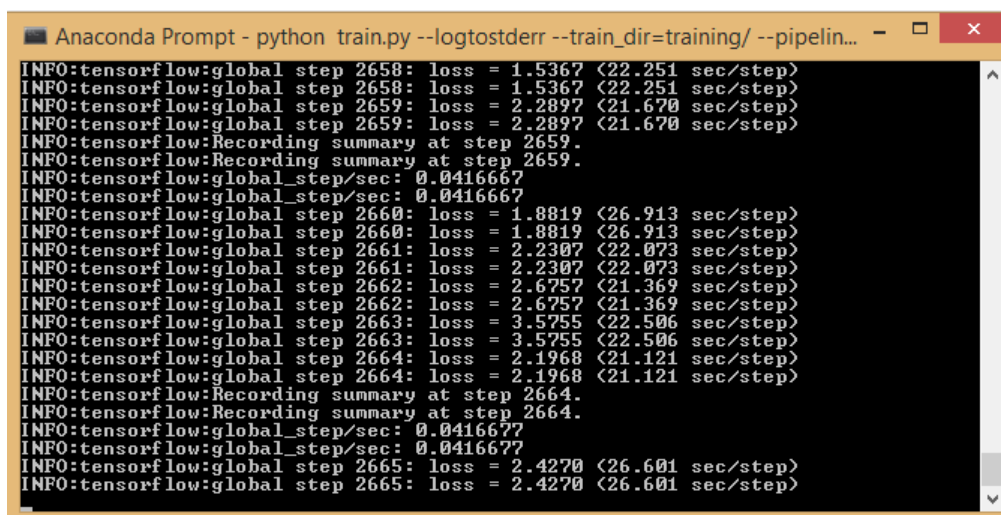
Figura 29 - Código utilizado para execução do treinamento

```
# Executar treinamento
python train.py --logtostderr --train_dir=training/ --
pipeline_config_path=training/ssd_inception_v2_coco.config
```

Fonte: Tensorflow Object Detection API tutorial, 2018.

Após o início do treinamento da rede neural, é apresentado o tempo de execução para a passagem do conjunto de imagens definido pelo parâmetro “batch size” (step) no arquivo de configuração e o erro encontrado (loss), conforme apresenta a Figura 30.

Figura 30 - Tela que informações do treinamento em execução são apresentadas



```

Anaconda Prompt - python train.py --logtostderr --train_dir=training/ --pipelin...
INFO:tensorflow:global step 2658: loss = 1.5367 <22.251 sec/step>
INFO:tensorflow:global step 2658: loss = 1.5367 <22.251 sec/step>
INFO:tensorflow:global step 2659: loss = 2.2897 <21.670 sec/step>
INFO:tensorflow:global step 2659: loss = 2.2897 <21.670 sec/step>
INFO:tensorflow:Recording summary at step 2659.
INFO:tensorflow:Recording summary at step 2659.
INFO:tensorflow:global_step/sec: 0.0416667
INFO:tensorflow:global_step/sec: 0.0416667
INFO:tensorflow:global step 2660: loss = 1.8819 <26.913 sec/step>
INFO:tensorflow:global step 2660: loss = 1.8819 <26.913 sec/step>
INFO:tensorflow:global step 2661: loss = 2.2307 <22.073 sec/step>
INFO:tensorflow:global step 2661: loss = 2.2307 <22.073 sec/step>
INFO:tensorflow:global step 2662: loss = 2.6757 <21.369 sec/step>
INFO:tensorflow:global step 2662: loss = 2.6757 <21.369 sec/step>
INFO:tensorflow:global step 2663: loss = 3.5755 <22.506 sec/step>
INFO:tensorflow:global step 2663: loss = 3.5755 <22.506 sec/step>
INFO:tensorflow:global step 2664: loss = 2.1968 <21.121 sec/step>
INFO:tensorflow:global step 2664: loss = 2.1968 <21.121 sec/step>
INFO:tensorflow:Recording summary at step 2664.
INFO:tensorflow:Recording summary at step 2664.
INFO:tensorflow:global_step/sec: 0.0416677
INFO:tensorflow:global_step/sec: 0.0416677
INFO:tensorflow:global step 2665: loss = 2.4270 <26.601 sec/step>
INFO:tensorflow:global step 2665: loss = 2.4270 <26.601 sec/step>

```

Fonte: O Autor.

O total de “steps” realizado para treino foi de 2664 na última tentativa, pois se percebeu que o valor erro não estava mais sendo reduzido. A média de tempo para cada “step” foi de aproximadamente 25 segundos, totalizando um tempo total de treino de 18 horas e 30 min. É importante ressaltar que devido ao processamento ter sido efetuado através da CPU (Intel® Core™ i7-4500U CPU 1.80GHz 2.40GHz), o tempo de processamento foi superior em comparação a se fosse utilizada a GPU ou até mesmo computadores mais novos com processadores de melhor desempenho.

Com o atingimento do erro considerado aceitável para realizar o teste (entre 1,5 e 3,0) foi exportado o modelo com o formato a ser utilizado pelo programa computacional. Novamente, através do Anaconda, foi realizada a exportação do modelo para o formato Protocol Buffer (.pb) através do comando presente na Figura 31.

Figura 31 - Código utilizado para exportação do arquivo de pesos e que é lido pelo programa computacional para detectar rodas

```

python export_inference_graph.py --input_type image_tensor --pipeline_config_path
training/ssd_inception_v2_coco.config --trained_checkpoint_prefix training/model.ckpt-13302
--output_directory trained-inference-graphs/output_inference_graph_v1.pb

```

Fonte: Tensorflow Object Detection API tutorial, 2018.

Finalizada a etapa de exportação do arquivo a ser utilizado pelo programa, o modelo treinado para detecção de rodas pode ser testado.

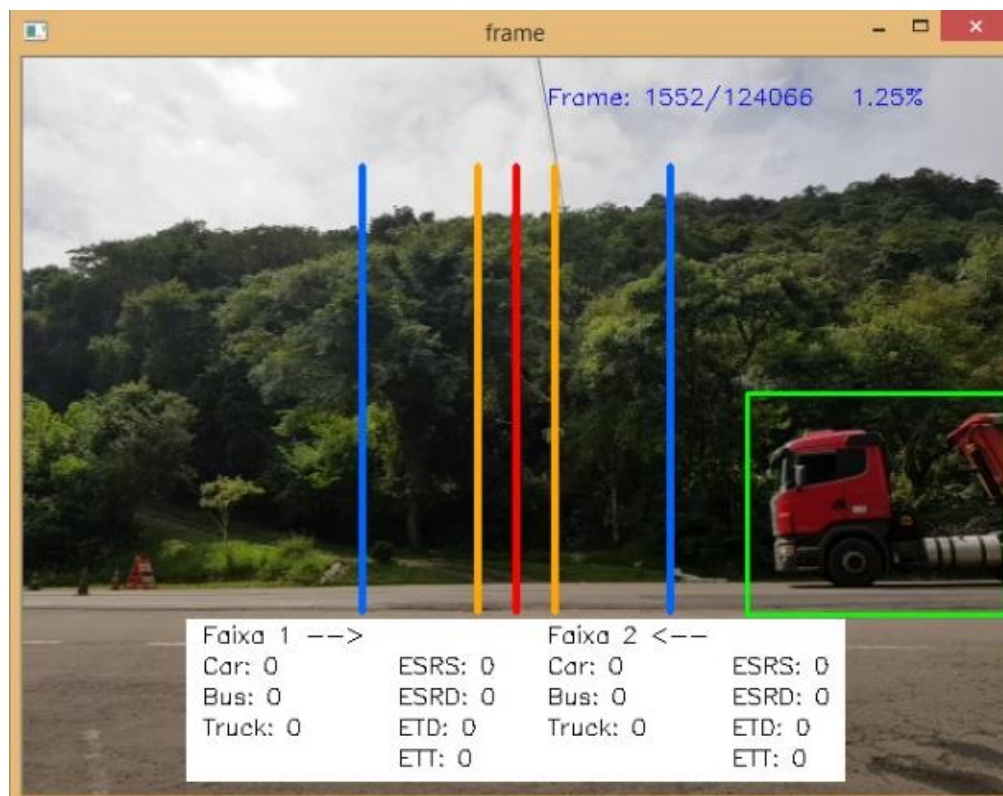
### 3.4 ABORDAGEM PARA A SOLUÇÃO DO PROBLEMA

Esta seção tem o objetivo de apresentar as abordagens definidas para a realização das tarefas de quantificar cada um dos tipos de veículos (carro, ônibus e caminhões) e dos tipos de eixos passantes (ESRS, ESRD, ETD e ETT) nos dois sentidos da BR-158, km 319, Santa Maria-RS.

#### 3.4.1 Abordagem para aceleração do processamento

Dadas as limitações de processamento da máquina utilizada no desenvolvimento do projeto, procurou-se uma alternativa de melhoramento do desempenho. Então, ao invés de todos os frames do vídeo serem processados para que diferentes tipos de objetos sejam encontrados, utilizou-se um recurso computacional da biblioteca Opencv de identificação de movimentos. O objetivo desse recurso é de sinalizar a aparição de algum veículo na imagem e apenas processar os frames para identificar o tipo de objeto e de eixos apenas no momento de detecção de movimento na área das linhas de contagem. A Figura 32 apresenta as caixas de movimento desenhadas a partir da detecção de movimentos do caminhão.

Figura 32 - Caixa desenhada na região de movimento detectada na imagem



Fonte: O Autor.

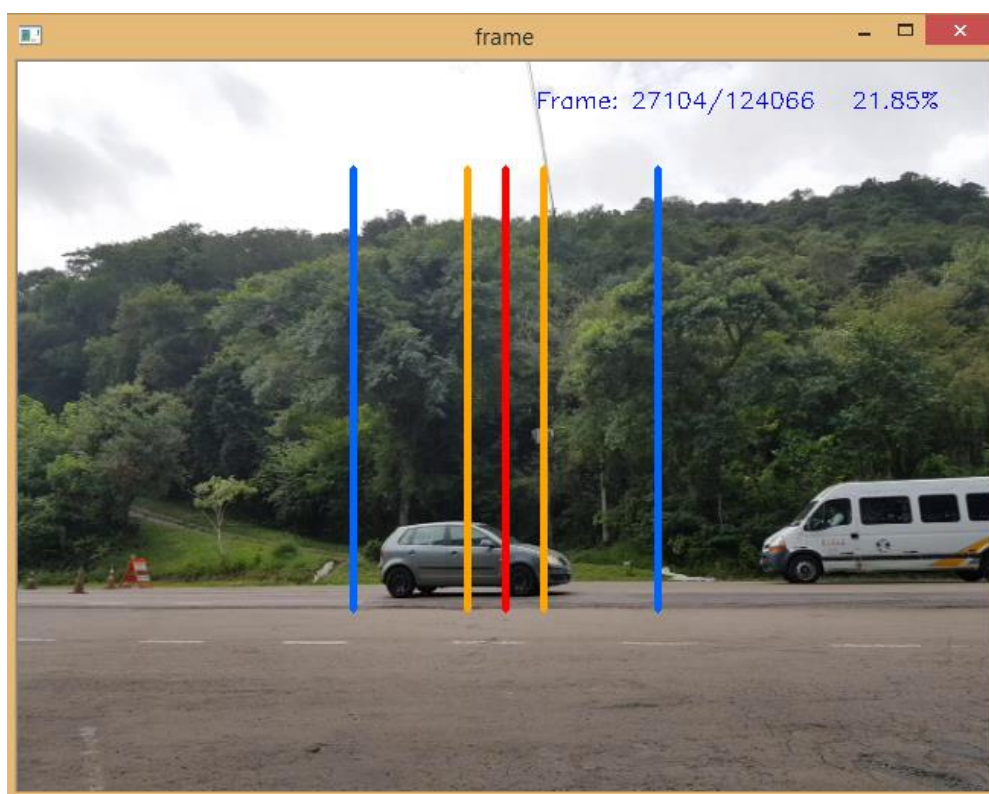
### 3.4.2 Abordagem para quantificação de veículos

Para a realização da contagem de cada tipo de veículo para ambos os sentidos da rodovia determinou-se duas linhas de contagem para carros e duas linhas de contagem para ônibus e caminhões. As linhas de contagem têm a finalidade de, no momento em que o veículo encostar em ambas, identificar o tipo de veículo passante e seu sentido, adicionar um rastreador, e, assim que o objeto deixar de encostar em uma das linhas, realizar a contagem. Além do estabelecimento das linhas de contagem necessitou-se a adição de um rastreador para uma única contagem do objeto.

O rastreador é a classe “tracker” da biblioteca Opencv e tem a finalidade de acompanhar o movimento de objetos ao longo dos frames. Assim é possível identificar o mesmo objeto durante o decorrer do vídeo. A Figura 33 apresenta a disposição de cada conjunto de linhas. A linha vermelha foi utilizada na primeira tentativa de contagens de eixos e será melhor explicada na seção 3.4.3. As linhas laranjas são

responsáveis pela contagem de carros e as linhas azuis pela contagem de ônibus e caminhões. A utilização de duas linhas de contagem para tipos diferentes de veículos tem o objetivo de diminuir o tempo em que o rastreador acompanha cada objeto, pois caso esse tempo seja muito longo, a probabilidade de ocorrer um cruzamento de veículos na imagem é maior, sendo assim mais provável a possibilidade de afetar o rastreamento e, conseqüentemente, a contagem.

Figura 33 - Disposição das linhas de contagem no momento do processamento



Fonte: O Autor.


### 3.4.3 Abordagem para quantificação de eixos

Para a realização da contagem dos diferentes tipos de eixos (ESRS, ESRD, ETD, ETT) duas abordagens foram utilizadas. A primeira utiliza a linha central da imagem para que no momento em que algum objeto estiver passando pelas linhas de contagem verifique se alguma roda está passando sobre ela. Caso esteja passando pelo centro da imagem, a distância da roda identificada para cada uma das outras rodas é calculada e verificada se a distância equivalente ao espaçamento entre as



rodas é de um eixo tandem. Sendo o valor em pixels que representa essa distância fornecida pelo usuário do programa determinado através da marcação entre duas rodas de eixo tandem diretamente na imagem no início da execução do programa. Assim, é possível determinar o tipo de eixo caso todas as rodas que o compõem sejam identificadas em pelo menos um frame enquanto passa sobre a linha central. A Figura 34 ilustra uma situação da utilização dessa abordagem. Conforme mostra a Figura 34 três rodas foram detectadas pela rede neural (marcadas pelo quadrado verde). Com a informação da posição de cada uma dessas rodas é calculada a distância entre a roda passante pela linha central com as demais e verificada se a distância real é menor ou maior que distância máxima estabelecida para rodas de eixos tandem. Logo, nesse exemplo, devido a uma das rodas ter uma distância superior a  $d$ , apenas um ETD é encontrado.

Figura 34 - Modelo do processo de identificação dos tipos de eixos passantes pela linha central da imagem



Fonte: O Autor.

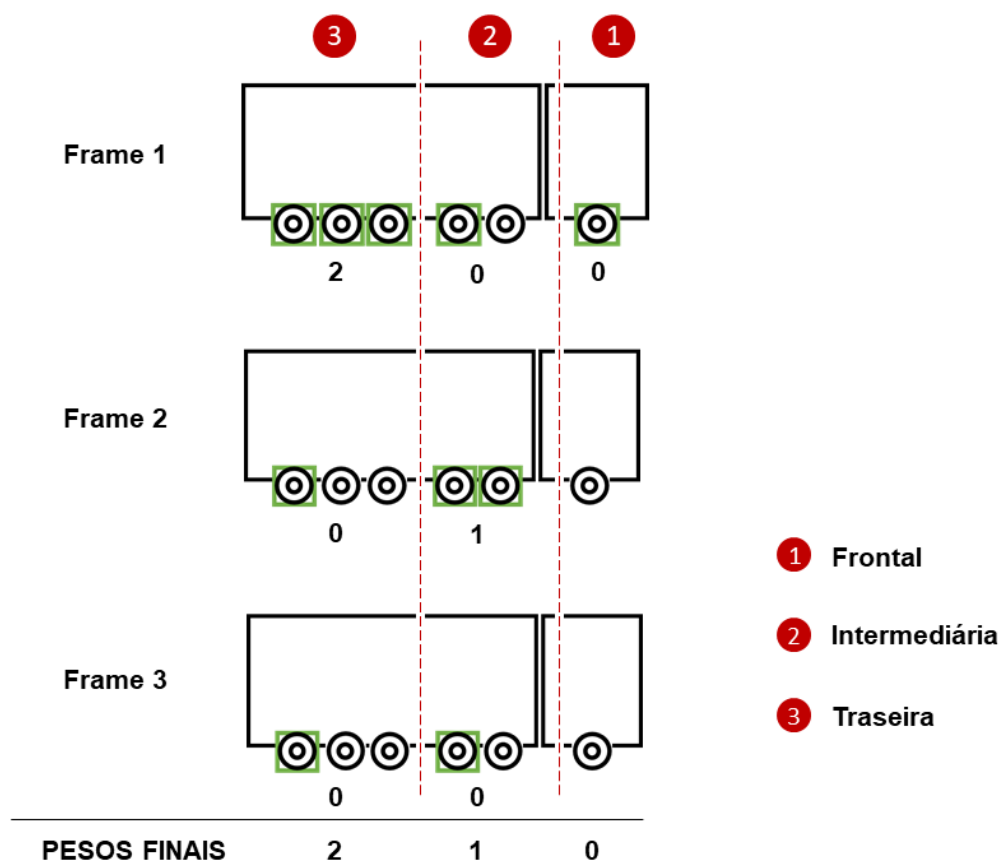
Testou-se pontualmente a precisão na identificação e contagem de eixos através da utilização desse método da linha central, porém, devido a verificação de limitações em vários trechos das gravações, o método não foi testado por um período significativo. Um dos maiores obstáculos foi a não identificação do conjunto de rodas componentes do eixo que passavam pela linha central ao mesmo tempo em nenhum frame. Isso ocasionava em uma contagem e identificação de eixos inferior e diferente a real.

Os dois principais motivos para essa dificuldade encontrada são o desenvolvimento de uma rede neural não eficaz o suficiente para a realização da tarefa e pela variação de luminosidade em alguns momentos das gravações. Conforme mais escuro e difícil visualização a tela, menos rodas eram identificadas. A partir dessas limitações outra abordagem foi elaborada baseando-se em dois fatores fundamentais: a quantidade de eixos identificada pela rede neural no momento em que o automóvel passa pelas linhas de contagem e o tamanho dos veículos.

Para diminuir os erros devido à falta de precisão da rede neural na detecção correta e constante das rodas a abordagem utilizada foi a de coleta de informações da disposição de eixos conforme o veículo passa pelas linhas de contagem. No momento em que o caminhão encostar em ambas as linhas de contagem e receber um rastreador, começa o processo de coleta de informações da disposição de rodas e eixos. Para isso é necessário identificar em cada imagem, quais rodas detectadas pertencem ao caminhão, avaliar seus espaçamentos e a presença de eixos ESRD, ETD e ETT, e verificar em que parte do caminhão cada eixo se encontra: frontal, intermediária ou traseira.

Esse processo é realizado para cada frame em que o veículo ainda possui o rastreador e todas essas informações são passadas para uma matriz que será utilizada como base para contagem no momento em que o veículo deixar alguma das linhas de contagem e for contabilizado. A Figura 35 apresenta um exemplo de uma sequência de três frames de um caminhão com 1 ESRD, 1 ETD e 1 ETT. Em todos os frames, apenas parte das rodas componentes do caminhão foram detectadas, porém, para cada frame, avaliou-se os tipos de eixos que havia em cada parte do caminhão. Para cada tipo de eixo um valor foi relacionado: ESRD, 0; ETD,1; e ETT,2. Assim, no momento da contabilização, priorizou-se os eixos identificados para cada parte conforme aqueles que mais degradam o pavimento, ou seja, aqueles que possuem maior valor relacionado.

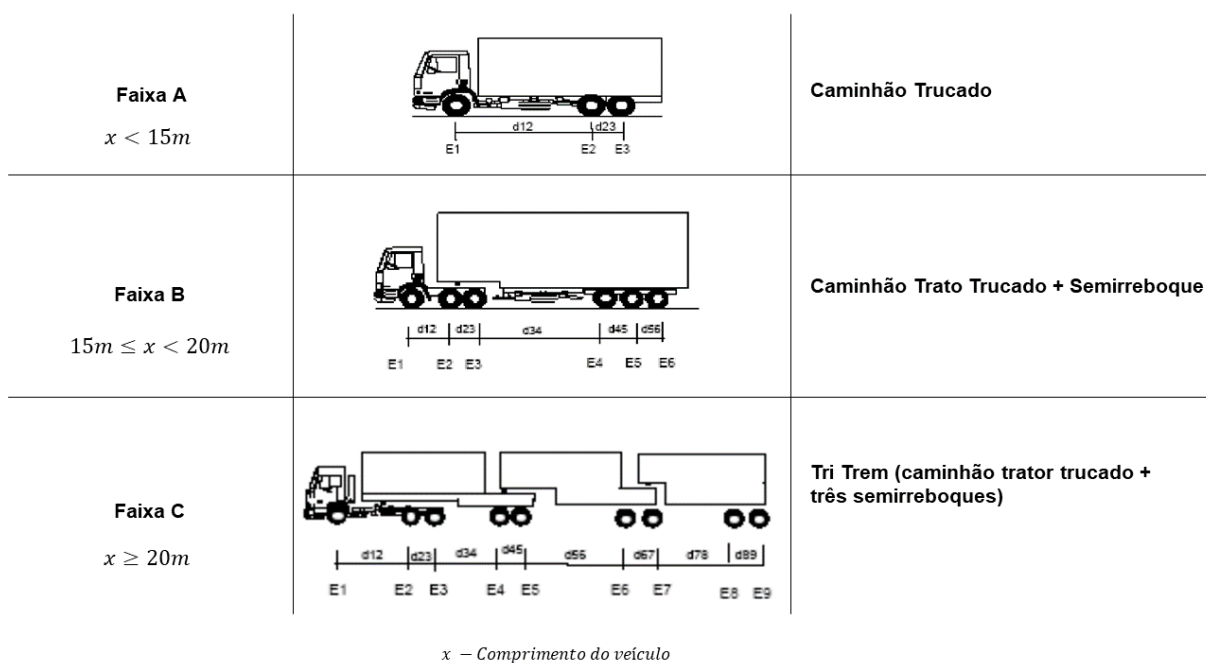
Figura 35 - Modelo de identificação dos tipos de eixos finais para cada parte do veículo



Fonte: O Autor.

Apesar desse método prolongar o tempo de obtenção de informações relacionadas aos eixos e possibilitar a relação com um veículo, sendo mais facilmente feito o discernimento de eixos por sentido, podem ocorrer falhas em casos de baixa efetividade na detecção de rodas por parte da rede neural. Dessa forma, pensou-se como uma boa abordagem definir eixos padrão para cada parte de veículos de tamanhos diferentes. Essa escolha foi feita com base na premissa de que veículos de tamanhos maiores possuem maior quantidade de eixos e tipos de eixos que degradam mais o pavimento. Logo, três faixas de tamanhos de caminhões foram determinadas e três tipos de veículos foram definidos como padrões na contabilização dos eixos. A Figura 36 apresenta os três veículos usados como base:

Figura 36 - Dimensões e caminhões escolhidos para base na identificação dos eixos



Fonte: O Autor.

Caso a obtenção de informações de eixos não seja razoável para uma determinada parte do caminhão, o tamanho do veículo é o fator que auxilia na tomada de decisão. O Quadro 9 apresenta um resumo dos tipos de eixos utilizados como base a partir das faixas e caminhões definidos como padrão:

Quadro 9 - Tipos de eixos utilizados como base para cada faixa

Faixas	Frontal	Intermediária	Traseira
Faixa A	1 ESRS	-	1 ETD
Faixa B	1 ESRS	1 ETD	1 ETT
Faixa C	1 ESRS	2 ETD	2 ETD

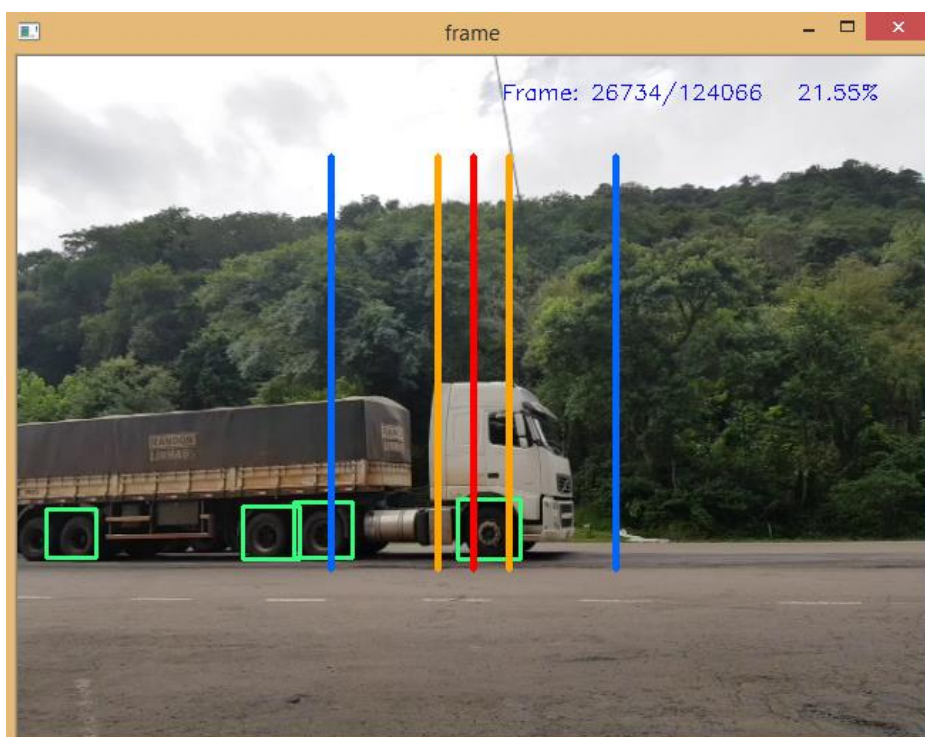
Fonte: O Autor.

Logo, essa abordagem segue as seguintes etapas:

- Identificar todas as rodas presentes na imagem;
- Relacionar cada uma das rodas encontradas a cada um dos objetos identificados (veículos que já possuem um rastreador);
- Verificar os tipos de eixos e sua respectiva zona no objeto: parte frontal, intermediária ou traseiro;
- Realizar essas mesmas etapas de coleta de informação para todos os frames em que o objeto está passando pelas linhas de contagem;
- No momento em que o objeto sair das linhas de contagem, ou seja, quando for efetivamente contabilizado, é avaliado se as quantidades de eixos encontrados para cada zona fazem sentido de acordo com o tamanho do veículo;
- Caso faça sentido, são contabilizados os eixos encontrados pelo modelo treinado, caso não faça sentido são contabilizados os eixos padrão pré-escolhidos para cada uma das três faixas de tamanhos estabelecidas;

A Figura 37 apresenta um caminhão quase alcançando a segunda linha de contagem. Caso todas as rodas identificadas nesse frame também sejam identificadas ao alcançar a segunda linha, 1 ESRS, 1 ESRD e 1 ETD serão identificados.

Figura 37 - Identificação de rodas durante trecho do vídeo teste



Fonte: O Autor.

## 4. RESULTADOS E ANÁLISES

O objetivo desta seção é apresentar, comparar e analisar os dados obtidos no levantamento do tráfego através da contagem manual e programa computacional, identificar limitações e apresentar o sistema de utilização do programa. A comparação dos resultados é feita com base no erro em porcentagem do resultado obtido através do programa com o real para cada um dos tipos de veículos e de eixos. Dessa forma, é possível compreender em qual ponto a contagem está menos precisa e viabilizar estudos mais aprofundados das limitações do programa e sugestões para trabalhos futuros relacionados ao tema. Porém, apesar do erro ser o indicador utilizado para avaliar a efetividade do programa, é importante ressaltar que erros de contagem podem ocorrer de forma que um compense o outro. Um exemplo é o caso de um ônibus ser identificado pela rede neural como um caminhão e um caminhão ser identificado como um ônibus, dessa forma a contagem de cada um dos erros se compensa.

As Tabelas 1 e 2 apresentam os resultados encontrados com a contagem manual, programa computacional e o erro para cada tipo de veículo e eixo no primeiro teste, equivalente a 1h08min de gravação (Polícia Rodoviária Federal, BR-158, Km 319), realizado para cada um dos sentidos.

Tabela 1 - Resultados obtidos no primeiro teste realizado no levantamento de veículos para 1h08min de gravação

Tipo de Veículo	→			←		
	Contagem Manual	Programa Computacional	Erro (%)	Contagem Manual	Programa Computacional	Erro (%)
<b>Carro</b>	179	173	-3,3	234	235	0,4
<b>Ônibus</b>	6	6	0	3	5	66,7
<b>Caminhão</b>	25	25	0	46	46	0
<b>TOTAL</b>	210	204	-2,8	283	286	1,1

Fonte: O Autor.

Tabela 2 - Resultados obtidos no primeiro teste realizado no levantamento de eixos para 1h08min de gravação

Tipo de Eixo	→			←		
	Contagem Manual	Programa Computacional	Erro (%)	Contagem Manual	Programa Computacional	Erro (%)
<b>ESRS</b>	31	31	0	49	51	4,1
<b>ESRD</b>	36	34	-5,6	22	35	59,1
<b>ETD</b>	29	35	20,7	59	83	40,7
<b>ETT</b>	3	5	66,7	27	2	-92,6
<b>TOTAL</b>	99	105	6,1	155	171	10,3

Fonte: O Autor.

A partir da Tabela 1, é possível perceber que o levantamento de veículos obteve resultados satisfatórios. Sendo os erros relacionados a contagem de carros para ambos os sentidos de apenas -3,3% e 0,4% e contagem de ônibus no sentido direita-esquerda, com 66,7%. Apesar do valor do erro ser bastante significativo para ônibus, o valor absoluto da contagem manual é pouco representativo, com apenas 3 veículos. Visto que, devido a posição determinada pela câmera ter a possibilidade de captar cruzamento de veículos, é possível considerar que a abordagem de utilização de rastreadores e linhas de contagem foram efetivos. No entanto, apesar de não ter sido realizada uma análise visual completa do vídeo testado, percebeu-se que em alguns momentos caminhões de grandes dimensões, como bitrem ou tritrem, não estavam sendo corretamente contabilizados, estavam sendo acrescentados mais de um caminhão a contagem devido a serem formados por reboques, sendo assim identificados mais de um caminhão para o mesmo veículo. Isso mostra que, apesar do valor erro para caminhões ser 0,0% para ambos os sentidos, deve-se implementar uma nova abordagem para identificar caminhões de grandes dimensões e formados por reboques.

Avaliando os resultados apresentados na Tabela 2, referente aos eixos, percebe-se que os erros em valores absolutos foram muito superiores em comparação com os resultados referente a veículos. Para o sentido esquerda-direita os erros foram de 0,0%, -5,6%, 20,7% e 66,7% para ESRS, ESRD, ETD e ETT respectivamente. Logo, é possível verificar que os maiores erros estão correlacionados ao número de rodas formadoras dos eixos. Um fator levantado como uma das possíveis causas para



um elevado erro para ETT, é a detecção apenas das rodas externas do eixo, sendo assim identificados como ESRD.

Para os veículos no sentido direita-esquerda o maior erro em valor encontrado também foi referente ao ETT, com 92,6%. Para ESRS, ESRD e ETD os erros também foram superiores aos encontrados em comparação com os que passaram no sentido contrário, com 4,1%, 59,1% e 40,7%. O fato dos erros superiores para cada eixo serem todos referentes ao sentido direita-esquerda pode ter dois motivos principais: sofrerem os efeitos de cruzamentos de veículos, afetando tanto a contagem quanto identificação; e maior distância em relação a câmera, diminuindo a precisão da rede neural na identificação das rodas.

Após a análise desses problemas específicos, priorizou-se a melhoria de dois pontos principais, sendo realizadas duas alterações para melhorar os resultados: a implementação de uma amplitude entre rodas que considere um ETT ao invés de dois ESRD; e uma nova abordagem na contabilização de apenas um caminhão independentemente se são formados por reboques ou não.

Logo, além da detecção de ETT através da proximidade de três rodas em sequência, acrescentou-se que o ETT deve ser detectado no momento em que uma roda estiver entre 1,5 e 2,0 vezes a distância definida como a equivalente entre duas rodas de eixo tandem. Assim, a tendência é que mais ETT possam ser identificados e contabilizados.

Para solucionar o problema na contagem de caminhões formados por reboques, ao invés de um rastreador ser adicionado para cada automóvel passante pelas linhas de contagem, é primeiramente avaliado se, dentro das caixas de movimento, as quais são caixas encontradas no momento em que é detectado alguma alteração de posição de um objeto, há caminhões. Caso haja caminhões o programa irá considerar as dimensões do caminhão como a da caixa de movimento, a qual consegue de uma forma muito mais precisa englobar as dimensões independente se formado por reboques e das dimensões.

Após implementadas essas alterações um segundo teste foi realizado para o mesmo vídeo para, posteriormente, avaliar se as contramedidas trouxeram uma diminuição ou acréscimo ao erro. As Tabelas 3 e 4 apresentam os resultados obtidos:

Tabela 3 - Resultados obtidos no segundo teste realizado no levantamento de veículos 1h08min de gravação

Tipo de Veículo	→			←		
	Contagem Manual	Programa Computacional	Erro (%)	Contagem Manual	Programa Computacional	Erro (%)
<b>Carro</b>	179	178	-0,6	234	228	-2,6
<b>Ônibus</b>	6	6	0,0	3	4	33,3
<b>Caminhão</b>	25	24	-4,0	46	38	-17,4
<b>TOTAL</b>	210	208	-1,0	283	270	-4,5

Fonte: O Autor.

Tabela 4 - Resultados obtidos no segundo teste realizado no levantamento de eixos para 1h08min de gravação

Tipo de Eixo	→			←		
	Contagem Manual	Programa Computacional	Erro (%)	Contagem Manual	Programa Computacional	Erro (%)
<b>ESRS</b>	31	30	-3,2	49	42	-14,3
<b>ESRD</b>	36	16	-55,6	22	13	-40,9
<b>ETD</b>	29	15	-48,3	59	42	-28,8
<b>ETT</b>	3	16	433,33	27	30	11,1
<b>TOTAL</b>	99	77	22,2	155	127	18,0

Fonte: O Autor.

Os resultados obtidos para levantamento de veículos mostram que, com a alteração no modo de contabilização de caminhões, os erros passaram de 0,0% para -4,0% para este tipo de veículo no sentido esquerda-direita e de 0,0% para -17,4% no sentido contrário. Apesar dos erros referentes a caminhões terem aumentado, não necessariamente a alteração tenha sido prejudicial aos resultados, é necessário que uma análise visual ao longo do vídeo seja realizada para ambos os testes e avaliar o nível de compensação de erros. Para ônibus no sentido direita-esquerda o programa se aproximou um veículo do resultado correto, diminuindo 33,3% do erro devido a pequena amostragem desse automóvel durante a gravação. Para ambos os sentidos os demais veículos tiveram pequenas variações.

Observa-se que os erros alteraram significativamente para o levantamento dos eixos comparando os resultados de cada uma das execuções do programa. Os valores que mais se destacam são os erros de ambos os sentidos do ETT e o erro

obtido do ESRD para o sentido esquerda-direita. O ETT ao contrário da primeira execução do programa, foi detectado em mais casos do que o contabilizado manualmente, tendo uma diferença de 13 entre o programa computacional e a contagem manual em valor absoluto no sentido esquerda-direita, equivalentes a 433,3%. Porém, para o sentido contrário o erro absoluto decresceu de 92,6% para 11,1%. Uma das possíveis explicações para a grande discrepância do número de ETT contabilizados pelo programa com o real pode ser a errada interpretação dos ESRD muito próximos ou ESRD que tiveram acidentalmente uma roda a mais detectada, explicando assim, valores inferiores aos reais e um erro de -55,6%.

Após a comparação dos resultados entre o programa antes e depois das alterações da abordagem de contagem de ETT e contabilização de caminhões, foi realizado um teste com 4h de gravação, ou seja, o tempo total gravado. Os resultados obtidos para as 4h de gravação seguem nas Tabelas 5 e 6 abaixo:

Tabela 5 - Resultados obtidos no segundo teste realizado no levantamento de veículos para 4h de gravação

Tipo de Veículo	→			←		
	Contagem Manual	Programa Computacional	Erro (%)	Contagem Manual	Programa Computacional	Erro (%)
<b>Carro</b>	760	763	0,4	844	829	-1,8
<b>Ônibus</b>	11	11	0,0	9	17	88,9
<b>Caminhão</b>	131	138	5,3	240	200	-16,7
<b>TOTAL</b>	902	912	1,1	1093	1046	-4,3

Fonte: O Autor.

Tabela 6 - Resultados obtidos no segundo teste realizado no levantamento de eixos para 4h de gravação

Tipo de Eixo	→			←		
	Contagem Manual	Programa Computacional	Erro (%)	Contagem Manual	Programa Computacional	Erro (%)
<b>ESRS</b>	142	149	4,9	249	217	-12,85
<b>ESRD</b>	87	49	-43,7	93	63	-32,3
<b>ETD</b>	164	144	-12,2	362	243	-32,9
<b>ETT</b>	40	64	60,0	109	128	17,43
<b>TOTAL</b>	433	406	-6,2	813	651	-19,9

Fonte: O Autor.

A partir dos novos resultados obtidos é possível verificar que, para o levantamento de veículos, em geral os erros continuaram relativamente pequenos, com exceção de ônibus e caminhões no sentido direita-esquerda, que atingiram um erro de 88,9% e -16,7% respectivamente. Apesar do grande erro encontrado para ônibus, é importante destacar que mesmo para um tempo de gravação de 4h a amostragem desse tipo de veículo continua muito inferior aos demais automóveis. Os demais veículos para ambos os sentidos permaneceram com erros 0,0% e 5,3% em valores absolutos.

Observa-se que para uma amostragem maior os erros alteraram principalmente para os ETD no sentido esquerda-direta, se aproximando 36,1p.p do valor real, e ETT, que passou de um erro de 433,3% para 60,0%. Erros em valores absolutos para ambos os sentidos e demais eixos tiveram variações bem inferiores. Percebe-se que em comparação com os primeiros testes, eixos tandem foram mais facilmente detectados, sendo os ETD possivelmente confundidos como ETT, considerando que a quantificação de ETD foram abaixo do esperado e de ETT acima.

Após a análise das variações de erros no levantamento de tráfego, deve-se compreender o impacto que isso tem no cálculo do "N", o qual representa o número de repetições de carga de um eixo padrão de 8,2 toneladas a que um pavimento está sujeito ao longo de sua vida de serviço (período de projeto). A Tabela 7 apresenta os valores obtidos do valor de "N" para o método da US Army Corps of Engineers (USACE) e da American Association of State Highway Officials (AASHTO). Os valores para cada um dos métodos foram calculados para a faixa de ambos os sentidos individualmente.

Tabela 7 - Resultados do valor de "N" a partir do método USACE e AASHTO

Métodos	→			←		
	Contagem Manual	Programa Computacional	Erro (%)	Contagem Manual	Programa Computacional	Erro (%)
<b>USACE</b>	$9,52 \times 10^7$	$9,20 \times 10^7$	-3,3	$2,03 \times 10^8$	$1,60 \times 10^8$	-21,1
<b>AASHTO</b>	$2,89 \times 10^7$	$2,47 \times 10^7$	-14,5	$5,26 \times 10^7$	$4,04 \times 10^7$	-23,2

Fonte: O Autor.

Os valores calculados de “N” tiveram os seguintes fatores pré-determinados: Volume Diário Médio (VDM), estimado de acordo com o total de veículos passantes pela faixa em 4h para 24h; Fator de Frota (Fr), relação dos veículos comerciais (caminhões e ônibus) e o total de veículos passantes pela faixa; Período de Projeto (P), 10 anos; Taxa de crescimento (t), 3,0%; Fator de Distribuição (Fd), 1,0, devido a ambos os sentidos obterem apenas uma faixa; Fator de Sentido (Fs), 1,0, pois os valores foram determinados para cada faixa individualmente; Fator Climático Regional (Fr), 1,8, pois a média anual de chuva em Santa Maria é de aproximadamente de 1.800 mm. Para as cargas o valor máximo permitido de cada um dos eixos foi utilizado: ESRS, 6t; ESRD, 10t; ETD, 17t; ETT, 25,5t.

Percebe-se a partir da Tabela 7 que os erros dos valores de “N” foram mais acentuados para a faixa de sentido direita-esquerda e quando o cálculo é realizado através do método da AASHTO. Sendo que para todos os valores, a estimativa do valor de “N” foi abaixo do real. A situação de maior variação em relação ao valor real foi no sentido direita-esquerda com o método da AASHTO, equivalente a -23,2%, e o de menor no sentido contrário utilizando o método da USACE, com -3,3%.

Um dos principais motivos para o sentido direita-esquerda possuir um erro superior ao sentido contrário é o fator de sobreposição de veículos, o qual ocorre no cruzamento de automóveis durante a passagem pelas linhas de contagem. Apesar de ser um erro já esperado, dada a posição da câmera para o projeto, a diferença dos erros foi muito acentuada comparando os valores de “N” para ambos os sentidos.

O fato do método da AASHTO possuir os maiores erros absolutos para ambos os sentidos se deve aos fatores de equivalência de carga serem, para cada eixo e em valor absoluto, inferiores ao da USACE. Assim, resulta em um erro superior para o fator de veículo calculado e, conseqüentemente, para o valor de “N”.

#### 4.1. SISTEMA DE USO

Para que o programa seja utilizado no levantamento de tráfego uma característica de fundamental importância e que pode variar conforme diferentes gravações é o quanto um conjunto de pixels representa em metros na posição de passagem dos veículos. Ter conhecimento desta proporção é fundamental dado que os tipos de eixos são identificados conforme a proximidade entre eles. Dessa forma duas possibilidades foram consideradas: Incluir um campo para inserção da distância em metros entre os limites da imagem na posição de passagem dos veículos, sendo assim possível determinar a relação pixels por metro, determinando o valor em pixels para o tamanho de cada um dos objetos ou distância entre rodas; ou a partir da própria gravação marcar manualmente a distância entre duas rodas que compõem um eixo tandem, verificando diretamente na gravação a distância em pixels a ser utilizada na identificação dos tipos de eixos e também o valor em metros entre os limites da imagem na posição da rodovia a partir de uma premissa de quanto a distância entre os eixos marcados representam em metros.


A abordagem escolhida foi a de marcação manual e a distância considerada entre os eixos igual a 1,8m. Escolheu-se esse valor por ser o valor intermediário entre o mínimo (1,2m) e o máximo (2,4m) da distância de duas rodas formadoras de um eixo tandem. Optou-se por essa abordagem pois, no momento da realização da gravação, a possibilidade da utilização da relação pixel por metro não havia sido levantada, e, para a verificação correta da distância após a realização da filmagem, a posição exata da câmera deveria ser encontrada e seria necessário o auxílio de mais uma pessoa, tornando o processo mais demorado.

Logo, a tela inicial após a inicialização do programa através do Jupyter Notebook é a própria gravação para que seja feita a marcação entre duas rodas formadoras de um eixo tandem. O vídeo passa em velocidade mais acelerada que a original e a primeira ação a ser realizada é a pausa da gravação através do clique do botão esquerdo do mouse quando da passagem de algum veículo que possua algum eixo tandem duplo ou triplo. Após o pause do vídeo, pode-se reiniciar a gravação do ponto pausado com o clique com o botão direito do mouse ou selecionar os dois pontos que distanciam o centro de duas rodas que compõem algum eixo tandem. Após a definição da distância deve-se clicar na tecla "f" para finalizar essa etapa. Assim,

automaticamente o processo de levantamento de veículos inicia e não é necessário mais nenhuma interação do usuário do programa.

É importante destacar que essa abordagem tem influência direta nos resultados dada a influência das dimensões dos caminhões na contabilização dos eixos, sendo assim, uma abordagem não recomendada para trabalhos futuros. A Figura 38 apresenta a marcação entre duas rodas de um caminhão.

Figura 38 - Marcação da distância entre duas rodas de um eixo tandem



Fonte: O Autor.

#### 4.2 LIMITAÇÕES DO PROGRAMA

Erros no levantamento de tráfego através do programa computacional desenvolvido podem ter ocorrido por diferentes fatores. Cada um dos fatores pode afetar tanto a quantificação de cada um dos tipos de veículos, tipos de eixos ou ambos para os dois sentidos da rodovia avaliada. Abaixo segue algumas das situações identificadas nas gravações e condições do programa que dificultam a correta classificação de veículo, eixo e suas respectivas quantificações:

- Cruzamento de veículos de forma que o automóvel da pista mais próxima a câmera sobreponha o da pista mais afastada enquanto um dos veículos está passando pela linha de contagem. Prejudicando diretamente a quantificação de veículos e eixos;
- Caminhões de tamanho muito grande em comparação com a amplitude obtida pela câmera e que sejam formados por reboques (caminhões bitrem/tritrem). Prejudicando tanto a quantificação de caminhões quanto a de eixos;
- A baixa precisão obtida pelo treinamento da rede neural para identificação de rodas, sendo assim, raros os momentos de identificação de todas na mesma imagem e, conseqüentemente, de eixos presente;
- A classificação da rede neural de alguns modelos de caminhões menores e com formato similar ao de carros;
- A proporção de pixels representarem diferentes tamanhos em metro conforme a proximidade em relação a câmera.

Dentre as limitações citadas acima, a de maior relevância percebida a partir dos resultados obtidos e percepções visuais durante o desenvolvimento do programa é a precisão da rede neural treinada para identificação de rodas, por ter influenciado diretamente a formulação de abordagens de quantificação dos tipos eixos. Caso a detecção de rodas fosse mais efetiva, uma abordagem mais simples e que necessitasse menos tempo para desenvolvimento poderia ser utilizada. Sendo a efetividade referente a identificação de todas as rodas presentes nas imagens, ou seja, não necessariamente a se as posições das rodas encontradas estão precisamente posicionadas.



## 5. CONSIDERAÇÕES FINAIS

O Brasil desde as primeiras décadas do século XX busca desenvolver fortemente sua malha rodoviária e o modal rodoviário, e, hoje, é o principal modal de transporte tendo um impactado enorme tanto para o transporte de pessoas como de mercadorias. Dado o grande desenvolvimento das estradas brasileiras e incentivos ao crescimento de veículos, o volume de automóveis cresce gradativamente, dentre eles veículos comerciais, os quais tem impacto direto na qualidade dos pavimentos asfálticos. Devido a esses e outros fatores, aproximadamente 50% das rodovias brasileiras estão com qualidade insatisfatória, gerando custos e insatisfação a seus usuários, sejam pessoas físicas como empresas.

A manutenção das rodovias brasileiras é um desafio tanto pelos baixos recursos alocados para obras de infraestrutura pelos governos quanto a assertividade na compreensão do tráfego para cada localidade do país. Para isso, métodos como contagem manual e por sensores são utilizadas para compreensão dos principais fatores que caracterizam o tráfego e que são fundamentais para o dimensionamento da rodovia: a quantificação de cada um dos principais tipos de veículos e de eixos passantes em cada uma das faixas de uma rodovia. Métodos que apesar de caracterizarem de forma precisa, necessitam de alocação de pessoas, possuem custos elevados e/ou não avaliam o comportamento do tráfego por longos períodos, sendo difícil identificar variações sazonais. Sendo assim, justificável a procura por novas tecnologias que viabilizem o levantamento de tráfego, possibilitando a contratação ou alocação de pessoas em áreas que ocupem atividades menos manuais, diminuição de custos e maior entendimento do tráfego por longos períodos.

O projeto teve o objetivo de analisar a viabilidade do uso da visão computacional, campo da inteligência artificial, no levantamento de tráfego para dimensionamento de pavimentos asfálticos. Nesta seção, serão apresentas as conclusões obtidas com o estudo e sugestões para trabalhos futuros.

## 5.1 CONCLUSÕES

A utilização de visão computacional para o levantamento de tráfego neste projeto obteve resultados significativos na contagem e diferenciação de veículos em ambos os sentidos, porém insatisfatório para o levantamento de eixos. O programa foi executado duas vezes, a primeira para verificar além dos erros obtidos, pontos percebidos visualmente ocorridos durante o processamento e realizar correções de melhoria. Apesar das alterações efetuadas erros significativos foram obtidos novamente.

Conclui-se a partir dos resultados que, a efetividade de uma rede neural na identificação de rodas é fundamental, devido as grandes complicações ocasionadas na identificação de cada um dos tipos de eixos, e tornando a abordagem de identificação complexa e, conseqüentemente, mais suscetível a erros. A obtenção de uma rede neural com capacidade abaixo do esperado na detecção de rodas se deve a motivos como: pequeno volume de imagens utilizadas; pequeno conjunto de imagens utilizado para detecção de rodas com baixa luminosidade; processador e memória da máquina utilizada prolongar o tempo de treinamento da rede neural e também o seu teste; e falta de conhecimento de pré-processamento de imagens para ajuste de características como brilho e contraste, os quais são fatores que influenciam diretamente na efetividade da detecção.

Além disso, percebeu-se a necessidade de uma máquina com um sistema operacional e processadores que viabilizam um desenvolvimento do projeto de forma mais rápida e o teste de diversas outras abordagens para gravações de tempo superiores.

Conclui-se que, apesar de erros significativos obtidos, é necessário que estudos mais aprofundados nessa área sejam realizados para definir sua viabilidade, dadas as diferentes possibilidades de melhoria pensadas e apresentadas ao longo do desenvolvimento do projeto.

## 5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Dadas as conclusões e também pela percepção durante todo o desenvolvimento do projeto, segue abaixo algumas sugestões para trabalhos futuros relacionados ao levantamento de tráfego através da visão computacional:

- Ampliação do conjunto de imagens utilizados para o treinamento da rede neural e seleção de imagens de diferentes luminosidades e tamanhos de rodas;
- Utilização de uma máquina com sistema operacional Linux ou IOS, devido à grande facilidade para encontrar tutoriais para instalação e execução de recursos computacionais e, conseqüentemente, pela praticidade na instalação dos recursos;
- Utilização de uma máquina com processadores superiores a Intel Core i7-4500 CPU 1.8GHz 2.4GHz, possibilitando uma maior agilidade e utilização do tempo de forma mais proveitosa;
- Treinamento de uma rede neural específica de veículos, principalmente para identificação de tipos de caminhões, visto que a rede neural utilizada (YOLO) não possui um bom discernimento entre caminhões com e sem reboque;
- Determinar relação pixels por metro da câmera baseada na distância medida entre os limites da tela na posição da rodovia in loco;
- Testar a utilização de duas câmeras, uma posicionada a uma altura maior em relação a rodovia para diminuir os efeitos da sobreposição dos veículos e possibilitar uma contagem ainda mais precisa e uma posicionada a poucos metros da rodovia, com o objetivo de apenas detectar a quantidade e tipos de eixos.

## REFERÊNCIAS BIBLIOGRÁFICAS

AHIRE, J. **Perceptron and Backpropagation**. 10 fev. 2018. Disponível em <<https://medium.com/@jayeshbahire/perceptron-and-backpropagation-970d752f4e44>>. Último acesso em 22 mai. 2019.

ALVES, G. **Entendendo Redes Convolucionais (CNNs)**. 08 out. 2018. Disponível em <<https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>>. Último acesso em 25 mai. 2019.

ANACONDA. Disponível em <[www.anaconda.com/distribution](http://www.anaconda.com/distribution)>. Último acesso em 05 jun. 2019.

BOSSO, M. **Uso da tecnologia Weight-in-Motion para a caracterização do tráfego rodoviário e do excesso de carga em veículos comerciais**. São Paulo. 2018.

CONFEDERAÇÃO NACIONAL DE TRANSPORTES (CNT). **Anuário CNT do Transporte 2018**. Disponível em <<http://anuariodotransporte.cnt.org.br/2018/>>. Último acesso em 20 mai. 2019.

CONSELHO NACIONAL DE TRÂNSITO (CONTRAN). **Resolução nº 210/06**. 30 nov. 2016.

COPPIN, B. **Inteligência Artificial**. Editora Grupo Editorial Nacional (GEN). Rio de Janeiro, 2017.

DEEP LEARNIG BOOK. **Capítulo 40 – Introdução as Redes Neurais Convolucionais**. Disponível em <<http://deeplearningbook.com.br/introducao-as-redes-neurais-convolucionais/>>. Último acesso em 22 mai. 2019.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTES (DNIT). **Manual de Estudos de Tráfego**. 2006.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTES (DNIT). **Manual de Restauração de Pavimentos Asfálticos**. 2006.

GITHUB. **Tensorflow Models**. Disponível em <[www.github.com/tensorflow/models](http://www.github.com/tensorflow/models)>. Último acesso em 25 mai. 2019.

GITHUB. **Exclusively Dark (ExDark) Image Dataset**. 28 mai. 2018. Disponível em <[www.github.com/cs-chan/Exclusively-Dark-Image-Dataset](http://www.github.com/cs-chan/Exclusively-Dark-Image-Dataset)>. Último acesso em 05 jun. 2019.

GRUBLER, M. **Entendendo o funcionamento de uma Rede Neural Artificial**. Disponível em <<https://medium.com/brasil-ai/entendendo-o-funcionamento-de-uma-rede-neural-artificial-4463fcf44dd0>>. Último acesso em 22 mai. 2019.

HAYKIN, S., **Redes Neurais Princípios e Prática**. Editora bookman 2ª ed. Porto Alegre. 01 dez. 2003.

IMAGENET. Disponível em <<http://www.image-net.org/search?q=truck>>. Último acesso em 10 abr. 2019.

JUPYTER. Disponível em <[www.jupyter.org](http://www.jupyter.org)>. Último acesso em 25 mai. 2019.

LEITE, T. **Redes Neurais, Perceptron Multicamadas e o Algoritmo Backpropagation**. Disponível em <<https://medium.com/ensina-ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8>>. Último acesso em 22 mai. 2019.

LIN, T., MAIRE, M. **Microsoft COCO: Common Objects in Context**. 21 fev. 2015.

MITCHEL, T. **Machine Learning**. Editora McGraw-Hill. 01 mar. 1997

MAIS CELULAR. **Samsung Galaxy S8 SM-G950FD**. Disponível em <https://www.maiscelular.com.br/fichas-tecnicas/samsung/galaxy-s8/sm-g950fd/>. Último acesso em 05 jun. 2019.

NAYAK, S. **Deep Learning based Object Detection using YOLOv3 with OpenCV ( Python / C++ )**. Disponível em <<https://www.learnopencv.com/deep-learning-based-object-detection-using-yolov3-with-opencv-python-c/>>. Último acesso em 12 abr. 2019

OPENCV. Disponível em <[www.opencv.org/about/](http://www.opencv.org/about/)>. Último acesso em 05 jun. 2019

PYTHON. Disponível em <<https://www.python.org/>>. Último acesso em 05 jun. 2019.

STACKOVERFLOW. **The Incredible Growth of Python**. Disponível em <<https://stackoverflow.blog/2017/09/06/incredible-growth-python/>>. Último acesso em 05 jun. 2019.

STANFORD UNIVERSITY. **CS231n: Convolutional Neural Networks for Visual Recognition, Spring 2018**. Disponível em <<http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>>. Último acesso em 25 mai. 2019.

STROSKI, P. **O que são redes neurais convolucionais?**. Disponível em <<http://www.electricalibrary.com/2018/11/20/o-que-sao-redes-neurais-convolucionais/>>. Último acesso em 25 mai. 2019.

REDMOND, J., DIVVALA, S., GIRSHICK, R, FARHADI, A. **You Only Look Once: Unified, Real-Time Object Detection**, Seattle, 2016.

REDMOND, J., FARHADI, A. **YOLOv3: An Incremental Improvement**, Seattle, 2018.

REDMOND, J. **YOLO**. Disponível em <[www.pjreddie.com](http://www.pjreddie.com)>. Último acesso em 05 jun. 2019.

TENSORFLOW. Disponível em <<https://www.tensorflow.org/>>. Último acesso em 05 jun. 2019.

TENSORFLOW. **Object Detection API Tutorial**. Disponível em <<https://tensorflow-object-detection-api-tutorial.readthedocs.io/en/latest/training.html>>. Último acesso em 05 jun. 2019.

TURING, A. **Computing Machinery and Intelligence**. Oxford University Press, Oxford, 1950.

TZUTALIN. **LabelImg**. Disponível em <[www.tzutalin.github.io/labelImg/](http://www.tzutalin.github.io/labelImg/)>. Último acesso em 10 abr. 2019.

### ANEXO A – FICHA DE CONTAGEM VOLUMÉTRICA I

Figura 39 - Ficha de contagem volumétrica I para o levantamento de tráfego

#### CONTAGEM VOLUMÉTRICA

ESTADO

RECÓDIMA

CÓD. PHV

TRECHO

**A**
**B**

POSTO

LOCAL DA CONTAGEM  
MARCO QUILOMÉTRICO

DATA DA CONTAGEM

HORA INÍCIO

HORA TÉRMINO

SENTIDO

A → B	B → A
-------	-------

PERÍODO (ms)

PERÍODO (ms)	VEÍCULOS LEVES			ÔNIBUS			CAMINHÕES										OUTROS		TOTAL			
	Autos	Camionetas	Outros	2C	3C	Outros	4C	3C	2C	3S3	3S2	2S3	2S2	2S1	3S3	2C2	2C3	3C2		3C3	+8 outros	Outros

Fonte: Manual de Estudos de Tráfego, DNIT, 2006.

## ANEXO B – FICHA DE CONTAGEM VOLUMÉTRICA II

Figura 40 - Ficha de contagem volumétrica II para o levantamento de tráfego

**CONTAGEM VOLUMÉTRICA**

ESTADO \_\_\_\_\_

RODovia \_\_\_\_\_

CÓD. FNM/ \_\_\_\_\_

LOCAL DA CONTAGEM  
MARCO QUILOMÉTRICO \_\_\_\_\_

POIsto \_\_\_\_\_

TRECHO \_\_\_\_\_

DEFADACONTAGEM \_\_\_\_\_

HORÁRIO INÍCIO \_\_\_\_\_

HORÁRIO FIM \_\_\_\_\_

SENTIDO \_\_\_\_\_

A \_\_\_\_\_

B \_\_\_\_\_

HORÁRIO		0-1	1-2	2-3	3-4	4-5	5-6	6-7	7-8	8-9	9-10	10-11	11-12	12-13	13-14	14-15	15-16	16-17	17-18	18-19	19-20	20-21	21-22	22-23	23-24	TOTAL
		CARRIOS DE PASSEIO																								
CAMIONETAS																										
OHIBUS	2C																									
	3C																									
C	2C																									
	3C																									
A	4C																									
	251																									
M	252																									
	253																									
I	352																									
	353																									
H	35252																									
	2C2																									
E	2C3																									
	3C2																									
S	3C3																									
	OUTROS																									
TOTAL																										

Fonte: Manual de Estudos de Tráfego, DNIT, 2006.