



**UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TRANSPORTES**

JULIANA DE ABREU E TRÉZ

**CUSTOMIZAÇÃO E APLICAÇÃO DE FERRAMENTA PARA COLETA
AUTOMATIZADA DE DADOS DE TRAVESSIA DE PEDESTRES EM
INTERSEÇÕES SEMAFORIZADAS**

**FORTALEZA
2023**

JULIANA DE ABREU E TRÉZ

CUSTOMIZAÇÃO E APLICAÇÃO DE FERRAMENTA PARA COLETA
AUTOMATIZADA DE DADOS DE TRAVESSIA DE PEDESTRES EM INTERSEÇÕES
SEMAFORIZADAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como requisito para obtenção do título de Mestre em Engenharia de Transportes. Área de concentração: Planejamento e Operação de Sistemas de Transporte.

Orientador: Prof. Ph.D. Manoel Mendonça de Castro Neto.

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

T716c Tréz, Juliana de Abreu e.

Customização e aplicação de ferramenta para coleta automatizada de dados de travessia de pedestres em interseções semaforizadas / Juliana de Abreu e Tréz. – 2023.

111 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, 2023.

Orientação: Prof. Dr. Manoel Mendonça de Castro Neto.

1. Travessia de pedestres. 2. Aceitação de headways. 3. Visão Computacional. I. Título.

CDD 388

JULIANA DE ABREU E TRÉZ

CUSTOMIZAÇÃO E APLICAÇÃO DE FERRAMENTA PARA COLETA
AUTOMATIZADA DE DADOS DE TRAVESSIA DE PEDESTRES EM INTERSEÇÕES
SEMAFORIZADAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como requisito para a obtenção do título de Mestre em Engenharia de Transportes. Área de concentração: Planejamento e Operação de Sistemas de Transporte.

Aprovada em: ____/____/_____.

BANCA EXAMINADORA

Prof. Ph.D. Manoel Mendonça de Castro Neto (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Ph.D. Francisco Moraes de Oliveira Neto
Universidade Federal do Ceará (UFC)

Profª. PhD. Ana Margarita Larrañaga Uriarte
Universidade Federal do Rio Grande do Sul (UFRGS)

A Deus.

Aos meus pais, Julio e Betânia, e meu
irmão, João Gabriel, pelo amor
incondicional.

AGRADECIMENTOS

Ao meu orientador, Prof. Manoel Mendonça de Castro Neto, por acreditar em mim e por toda a compreensão e o apoio durante o processo, mesmo com os obstáculos que se apresentaram ao longo do tempo.

Aos membros da banca de defesa de dissertação, Prof. Francisco Moraes de Oliveira Neto e Profa. Ana Margarita Larrañaga Uriarte, pela disponibilidade e pelas considerações realizadas para melhoria do trabalho.

À Universidade Federal do Ceará, pelo conhecimento e experiência que adquiri na minha trajetória acadêmica.

Ao CTAFOR, pelos dados fornecidos.

Aos meus pais, Maria Betânia de Abreu e Tréz e Julio Cesar Tréz, e ao meu irmão, João Gabriel de Abreu e Tréz, pelo amor, pelo suporte e pela paciência durante toda a minha trajetória de vida dentro e fora do ambiente acadêmico, sobretudo nesse período de mestrado.

Aos meus amigos de longa data Talyson Bandeira, Gledson Mesquita, Yago Titov e Viviane Rodrigues, que me acompanham desde a graduação e que cresceram e amadureceram juntamente comigo ao longo de todos esses anos e todas as fases vividas. Aos meus amigos Robson Monteiro, Iago Avelino, Sávio Cavalcante, Vinícius Barros e Ewerlane Castro, que são parte muito importante da minha história, nos momentos bons e ruins. Às minhas amigas Nah Jereissati, Lara Vasconcelos e Laís Verissimo pelos momentos de leveza e pelo acolhimento de sempre nos momentos de desabafo e ansiedade.

Aos meus colegas de trabalho da Transitar Consultoria, que se tornaram grandes amigos, João Lucas Albuquerque, Nilso Filho, Ivana Feitosa, Giovanna Rebouças, Ellen Cunha, Lucas Sousa, Milene Guimarães, Julia Martini e Wesley Lima, por tornarem meu dia-a-dia muito mais leve e mostrarem que eu não estava no barco sozinha. Ao pessoal da Transitar Consultoria por acreditarem no meu potencial profissional e me darem uma chance, mesmo precisando conciliar o trabalho com o mestrado.

Ao pessoal do grupo de pesquisa, Alessandro Macêdo, Cornélio Sousa e Thiago Passos, pela grande contribuição no desenvolvimento deste trabalho.

A todo mundo que participou, apoiou e comemorou de alguma forma.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

A travessia de pedestres no vermelho é um problema cuja compreensão ainda apresenta lacunas a serem investigadas, devido à complexidade das variáveis envolvidas e suas interrelações, principalmente em interseções de grandes cidades brasileiras. Ferramentas de coleta automatizada podem ser importantes aliadas na modelagem dessas variáveis e interrelações. O objetivo desta dissertação é customizar e aplicar uma ferramenta automatizada para coletar variáveis importantes em estudos de travessias de pedestres em interseções semaforizadas. Para isso, foram traçados três objetivos específicos: 1) definir as variáveis importantes para a compreensão do fenômeno de aceitação de *headways* pelos pedestres; 2) calibrar e validar uma ferramenta de coleta automatizada de variáveis relacionadas ao processo de aceitação de *headways* pelos pedestres; e 3) coletar e explorar dados de variáveis relativas ao processo de aceitação de *headways* em travessias semaforizadas. O vídeo escolhido foi o da Av. Antônio Sales na interseção com a Av. Desembargador Moreira, em Fortaleza. As ferramentas usadas para coleta das variáveis definidas (*headways*, atraso do pedestre, velocidade veicular, tipo de veículo e instante de travessia por faixa) foram YOLOv7 e StrongSORT. Foi realizado um treinamento, que resultou em mAP de validação de 94% e mAP de teste de quase 90%, retornando falsos positivos para caminhões, sendo possível um retreinamento para melhoria dessa classe. Ao todo, 9427 veículos e 723 pedestres foram rastreados; os *headways* mostraram grande amplitude, a velocidade média dos veículos foi de 28 km/h e o atraso médio dos pedestres foi de 18 s. Foi feita uma validação com uma ferramenta de coleta manual (RUBA), e os resultados mostraram que não houve diferenças significativas nas coletas pelos dois métodos dos instantes de passagem dos veículos e de seus *headways*; para as velocidades a média das diferenças foi de -0,9 s, e para as variáveis dos pedestres as médias das diferenças foram de até 0,2 s. Por fim, foram realizadas análises exploratórias de quatro tipos de *headways*: os aceitos, os mínimos aceitos, os aceitos no vermelho e os mínimos aceitos no vermelho, por tipo de veículo e por faixa, pelos pedestres das duas zonas de origem (A e B). Observou-se, nas 4 análises, que as médias dos *headways* aceitos e das velocidades se assemelharam para os pedestres das duas origens, foram aceitos mais *headways* de bicicletas e os pedestres da origem B tiveram o menor atraso.

Palavras-chave: travessia de pedestres, aceitação de *headways*, Visão Computacional

ABSTRACT

Pedestrian crossings on red are an issue that still have gaps to investigate, due to the complexity of the variables involved and their relations, mostly in big urbam centers in Brazil. Automated collection tools can be an important aid on modelling these studies. This M.S. thesis has as main objective to customize and apply an automated collection tool to gather important variables for pedestrian crossings' studies on signalized intersections. To reach this objective, three specific goals were established: 1) definition of the variables for the comprehension of the headways' acceptance phenomenon; 2) calibration and validation of an automated collection tool of variables related to the headway acceptance process; and 3) collection and exploration of results related to variables that are part of the headway acceptance process on signalized intersections. A video of the intersection between Antonio Sales avenue and Desembargador Moreira avenue, in Fortaleza, was chosen. The tools used to collect the variables defined (headway, pedestrian delay, vehicular speed, vehicle type and crossing instant by lane) were YOLOv7 and StrongSORT. A training was conducted, resulting in a validation mAP of 94% and a test map of 90%. The class 'Truck' showed false positives, then a new trainning is recommended to improve the precision of this class. In total, 9427 vehicles and 723 pedestrians were tracked; the headways presented large range, the average speed of the vehicles was 28 km/h and the average pedestrian delay was 18 s. A validation step was made with a manual collection tool (RUBA), and results showed no significative difference between the collection with both methods of vehicle passage times and headways; the mean of differences for the vehicular speeds was -0,9 s and the mean of differences for pedestrian variables was below 0,2 s. Finally, exploratory analyses of four types of headways : accepted, minimum accepted, accepted on red and minimum accepted on red by the pedestrian of both origin zones (A and B), by vehicle type and vehicular lane. The point was made that, for all the four analyses, the mean accepted headways and the mean vehicular speeds were similar for the pedestrians of both origins, most headways from bicycles were accepted, and the pedestrians of origin B had the shortest delay.

Keywords: pedestrian crossings, headway acceptance, Computer Vision

LISTA DE ILUSTRAÇÕES

Figura 1 - Estimação do <i>headway</i> crítico	17
Figura 2 - Resultados do agrupamento de atraso e <i>headways</i> das travessias C12 e C31	25
Figura 3 - Detecção no YOLO	27
Figura 4 - Ilustração da IOU.....	29
Figura 5 - Fluxograma do método	33
Figura 6 - Exemplo de rotulação de objeto no LabelImg	36
Figura 7 - Exemplo de .txt de saída do LabelImg	36
Figura 8 - Arquivos pré-treinados para o YOLOv7 e arquivo escolhido para o treinamento ..	37
Figura 9 - Trecho do arquivo de saída do YOLO.....	38
Figura 10 – Delimitação da área de conflito e das seções de coleta dos instantes de passagem para <i>headways</i> e velocidades veiculares.....	39
Figura 11 – Numeração de referência das faixas veiculares	40
Figura 12 – Delimitação das áreas de origens do pedestre e das seções de coleta dos instantes de passagem dos pedestres em cada faixa	40
Figura 13 - Interface do RUBA com o <i>Ground Truth Annotator</i> (vídeo ilustrativo).....	42
Figura 14 - Exemplo de arquivo de saída .csv do RUBA.....	42
Figura 15 – Referências adotadas na coleta com o RUBA.....	43
Figura 16- Exemplo ilustrativo da aceitação de <i>headways</i> em cada faixa	44
Figura 17 – Imagem da aproximação analisada (Av. Antônio Sales)	46
Figura 18 - Distribuição das classes por contagem de objetos nos bancos de treino, validação e teste, por interseção	49
Figura 19 - Curvas de aprendizagem das métricas de treino e validação.....	50
Figura 20 - Curvas precisão x <i>recall</i> das imagens de teste.....	51
Figura 21 - Exemplo de comparação entre o <i>groundtruth</i> (a) e a identificação do detector (b) em uma imagem de teste	52
Figura 22 - Matriz de Confusão dos objetos nas imagens de teste.....	53
Figura 23 – Vídeo resultante do rastreio e da coleta dos parâmetros	54
Figura 24 - Referências adotadas para registro dos instantes dos pedestres e veículos	54
Figura 25 - Arquivo de saída .csv dos resultados para os veículos	55
Figura 26 - Arquivo de saída .csv dos resultados para os pedestres.....	56
Figura 27 - Distribuição dos veículos rastreados pelo YOLO/StrongSORT, por classe.....	56
Figura 28 - Histograma de frequência absoluta dos <i>headways</i> (em s)	57

Figura 29 - Histograma das velocidades contabilizadas (em km/h)	59
Figura 30 - Histograma dos atrasos contabilizados (em s)	60
Figura 31 - Total de objetos por classe no YOLO e no RUBA	61
Figura 32 - Gráficos dos erros entre os instantes de passagem na seção 1 (a) e entre os instantes de passagem na seção 2 (b) (em s) em relação à velocidade coletada no RUBA	63
Figura 33 - Histogramas das diferenças entre os instantes de passagem na seção 1 (a) e entre os instantes de passagem na seção 2 (b) (em s)	64
Figura 34 - Gráfico dos erros dos <i>headways</i> (em s) em relação à velocidade coletada no RUBA	65
Figura 35 - Histograma das diferenças entre os <i>headways</i> (em s).....	66
Figura 36 - Gráfico dos erros das velocidades em relação à velocidade coletada no RUBA (em km/h).....	67
Figura 37 - Histograma das diferenças entre as velocidades (em km/h)	67
Figura 38 - Histogramas das diferenças dos parâmetros dos pedestres.....	68
Figura 39 - Exemplos de erros encontrados no rastreio (a = oclusão de pedestre; b = oclusão de pedestre e troca de ID de 219 para 271)	70
Figura 40 - Arquivo de saída .csv dos resultados dos <i>headways</i> aceitos pelos pedestres	71
Figura 41 – Histogramas dos <i>headways</i> aceitos (em s), por faixa veicular e por zona de origem do pedestre	73
Figura 42 – <i>Boxplots</i> dos <i>headways</i> aceitos por faixa veicular e por zona de origem do pedestre	74
Figura 43 – Histogramas das velocidades (em km/h) dos veículos de <i>headways</i> aceitos pelos pedestres, por faixa veicular e por zona de origem do pedestre	76
Figura 44 – Relação entre os <i>headways</i> aceitos (em s) e as velocidades veiculares (em km/h), por tipo de veículo, faixa veicular e zona de origem do pedestre	77
Figura 45 – Histogramas dos atrasos (em s) dos pedestres, por zona de origem do pedestre ..	78
Figura 46 – Relação entre os <i>headways</i> aceitos e os atrasos dos pedestres (em s) por tipo de veículo, faixa veicular e zona de origem do pedestre	79
Figura 47 - Histogramas dos <i>headways</i> mínimos aceitos (em s) pelos pedestres, por faixa veicular e por zona de origem do pedestre	81
Figura 48 - <i>Boxplots</i> dos <i>headways</i> mínimos aceitos por faixa veicular e por zona de origem do pedestre	82
Figura 49 - Histogramas de frequência das velocidades (em km/h) dos veículos de <i>headways</i> mínimos aceitos pelos pedestres, por faixa veicular e por zona de origem do pedestre	84

Figura 50 - Relação entre os <i>headways</i> mínimos aceitos (em s) e as velocidades veiculares (em km/h), por tipo de veículo, faixa veicular e zona de origem do pedestre.....	85
Figura 51 - Relação entre os <i>headways</i> mínimos aceitos e os atrasos dos pedestres (em s) por tipo de veículo, faixa veicular e zona de origem do pedestre.....	86
Figura 52 - Histogramas dos <i>headways</i> aceitos no vermelho (em s) pelos pedestres, por faixa veicular e por zona de origem do pedestre	88
Figura 53 - Histogramas das velocidades (em km/h) dos veículos de <i>headways</i> aceitos no vermelho pelos pedestres, por faixa veicular e por zona de origem do pedestre	90
Figura 54 - Relação entre os <i>headways</i> aceitos (em s) e as velocidades veiculares (em km/h), por tipo de veículo, faixa veicular e zona de origem do pedestre	91
Figura 55 – Histogramas dos atrasos (em s) dos pedestres, por origem do pedestre	92
Figura 56 - Relação entre os <i>headways</i> aceitos no vermelho e os atrasos dos pedestres (em s), por tipo de veículo, faixa veicular e zona de origem do pedestre	93
Figura 57 - Histogramas dos <i>headways</i> mínimos aceitos no vermelho (em segundos) pelos pedestres, por faixa veicular e por zona de origem do pedestre	95
Figura 58 - Histogramas das velocidades (em km/h) dos veículos dos <i>headways</i> mínimos aceitos no vermelho pelos pedestres, por faixa veicular e por origem do pedestre.....	97
Figura 59 - Relação entre os <i>headways</i> mínimos aceitos no vermelho (em s) e as velocidades veiculares (em km/h), por tipo de veículo, faixa veicular e origem do pedestre.....	98
Figura 60 - Relação entre os <i>headways</i> mínimos aceitos no vermelho e os atrasos dos pedestres (em s) por tipo de veículo, faixa veicular e origem do pedestre.....	99

LISTA DE TABELAS

Tabela 1 – Detalhes do vídeo escolhido para análise	46
Tabela 2 - Vídeos selecionados para treinamento da ferramenta	47
Tabela 3 – Quantidade de rotulações e distribuição de imagens de treino, validação e teste para cada interseção.....	48
Tabela 4 - Resultados das métricas de teste para um IOU mínimo de 0,5	52
Tabela 5 - IC (95%) dos <i>headways</i> contabilizados (em s), por faixa	57
Tabela 6 - Proporção de cada classe veicular, por faixa.....	58
Tabela 7 - IC (95%) das velocidades contabilizadas (em km/h), total e por classe veicular ...	58
Tabela 8 - IC (95%) dos atrasos contabilizados (em s)	59
Tabela 9 - Matriz de Confusão para os veículos pareados	61
Tabela 10 - IC (95%) da média das diferenças entre os instantes de passagem na seção 1 (em s)	62
Tabela 11 - IC (95%) da média das diferenças entre os instantes de passagem na seção 2 (em s)	62
Tabela 12 - IC (95%) da média das diferenças entre os <i>headways</i> (em s)	65
Tabela 13 - IC (95%) da média das diferenças entre as velocidades (em km/h).....	66
Tabela 14 - IC (95%) da média das diferenças para os pedestres (em s)	68
Tabela 15 - Erros encontrados no rastreio	70
Tabela 16 – IC (95%) dos <i>headways</i> aceitos (em s) pelos pedestres da origem A, por faixa veicular	72
Tabela 17 – IC (95%) dos <i>headways</i> aceitos (em s) pelos pedestres da origem B, por faixa veicular	72
Tabela 18 – Velocidades (em km/h) dos veículos de <i>headways</i> aceitos pelos pedestres da origem A, por tipo de veículo	75
Tabela 19 – Velocidades (em km/h) dos veículos de <i>headways</i> aceitos pelos pedestres da origem B, por tipo de veículo	75
Tabela 20 – Atrasos (em s) dos pedestres, por área de origem	78
Tabela 21 - <i>Headways</i> mínimos aceitos (em s) pelos pedestres da origem A, por faixa veicular	80
Tabela 22 - <i>Headways</i> mínimos aceitos (em s) pelos pedestres da origem B, por faixa veicular	80

Tabela 23 - Velocidades (em km/h) dos veículos dos <i>headways</i> mínimos aceitos pelos pedestres da origem A, por tipo de veículo	83
Tabela 24 - Velocidades (em km/h) dos veículos dos <i>headways</i> mínimos aceitos pelos pedestres da origem B, por tipo de veículo	83
Tabela 25 - <i>Headways</i> aceitos no vermelho (em s) pelos pedestres da origem A, por faixa veicular	87
Tabela 26 - <i>Headways</i> aceitos no vermelho (em s) pelos pedestres da origem B, por faixa veicular	87
Tabela 27 - Velocidades (em km/h) dos veículos dos <i>headways</i> aceitos no vermelho pelos pedestres da origem A, por tipo de veículo	89
Tabela 28 - Velocidades (em km/h) dos veículos dos <i>headways</i> aceitos no vermelho pelos pedestres da origem B, por tipo de veículo	89
Tabela 29 – Atrasos (em s) dos pedestres, por área de origem	91
Tabela 30 - <i>Headways</i> mínimos aceitos no vermelho (em s) pelos pedestres da origem A, por faixa veicular	94
Tabela 31 - <i>Headways</i> mínimos aceitos no vermelho (em s) pelos pedestres da origem B, por faixa veicular	94
Tabela 32 - Velocidades (em km/h) dos veículos dos <i>headways</i> mínimos aceitos no vermelho pelos pedestres da origem A, por tipo de veículo	96
Tabela 33 - Velocidades (em km/h) dos veículos dos <i>headways</i> mínimos aceitos no vermelho pelos pedestres da origem B, por tipo de veículo	96

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	Problemas e questões motivadoras.....	14
1.2	Objetivos	14
1.3	Estrutura da dissertação	15
2	REVISÃO DA LITERATURA.....	16
2.1	Aceitação de <i>headways</i> por pedestres.....	16
2.2	Fatores que influenciam a travessia de pedestres no vermelho.....	18
2.2.1	<i>Atraso</i>	18
2.2.2	<i>Fluxo veicular.....</i>	20
2.2.3	<i>Tipo de veículo</i>	21
2.2.4	<i>Velocidade veicular.....</i>	21
2.2.5	<i>Número de faixas da via.....</i>	22
2.3	Uso da Visão Computacional em estudos de travessias de pedestres	23
2.3.1	<i>Parâmetros coletados.....</i>	23
2.3.2	<i>Ferramentas utilizadas</i>	26
2.3.3	<i>Medidas de desempenho</i>	28
2.3.4	<i>Treinamento</i>	30
2.4	Considerações sobre a Revisão da Literatura	31
3	MÉTODO	33
3.1	Escolha das interseções.....	33
3.2	Desenvolvimento do método de coleta automatizada em vídeo	34
3.2.1	<i>Treinamento e avaliação do algoritmo</i>	35
3.3	Coleta dos dados	38
3.3.1	<i>Comparação com a ferramenta de coleta manual.....</i>	41
3.4	Análise exploratória das variáveis relacionadas à aceitação de <i>headways</i>	44
4	RESULTADOS	46

4.1	Escolha das interseções.....	46
4.2	Desenvolvimento do método de coleta automatizada em vídeo.....	47
4.2.1	<i>Treinamento e avaliação do algoritmo</i>	47
4.3	Coleta de dados	53
4.3.1	<i>Validação da detecção dos objetos</i>	60
4.3.2	<i>Validação dos instantes de passagem e headways veiculares</i>	61
4.3.3	<i>Validação das velocidades veiculares.....</i>	66
4.3.4	<i>Validação dos atrasos dos pedestres.....</i>	68
4.4	Análise exploratória das variáveis relacionadas à aceitação de headways	70
4.4.1	<i>Headways aceitos</i>	71
4.4.2	<i>Headways mínimos aceitos.....</i>	80
4.4.3	<i>Headways aceitos no vermelho dos pedestres.....</i>	86
4.4.4	<i>Headways mínimos aceitos no vermelho dos pedestres.....</i>	93
5	CONCLUSÕES E RECOMENDAÇÕES PARA TRABALHOS FUTUROS	101
	REFERÊNCIAS.....	105

1 INTRODUÇÃO

Travessias de pedestres realizadas no vermelho, ou seja, durante o verde dos veículos, independentemente da existência de um foco semafórico para o pedestre, são um problema frequente e grave de segurança viária no mundo todo. De acordo com a Organização Mundial da Saúde (WHO, 2018), ocorrem em média 1,35 milhões de mortes em acidentes de trânsito por ano, com os pedestres representando 23% delas. Em Fortaleza, o Relatório Anual de Segurança Viária (PMF, 2019) apurou que os atropelamentos representaram quase 12% das ocorrências com vítimas no trânsito, e dentre as vítimas fatais, mais de 40% foram pedestres.

As travessias arriscadas acontecem quando os pedestres aceitam as brechas (intervalos) entre veículos, ou *headways*, que mais se adequam a eles (Onelcin; Alver, 2015). Estudos têm sido realizados para compreensão do que afeta a oferta e a aceitação de tais *headways*, tanto internacionalmente (Marisamynathan; Vedagiri, 2014; Onelcin; Alver, 2015; Zhu *et al.*, 2021) quanto nacionalmente (Bandeira *et al.*, 2021).

De acordo com o *Highway Capacity Manual* – HCM2016 (TRB, 2016), pedestres tendem a obedecer a sinalização quando precisam esperar 10 segundos ou menos para realizar travessia, e se impacientam quando precisam esperar mais de 30 segundos. Esse tipo de situação pode ocasionar um tempo de espera acima do máximo aceitável pelo pedestre, induzindo-o a decidir pelo risco de procurar *headways* e atravessar no semáforo vermelho (Zhu *et al.*, 2021, Rakotoarivelo *et al.*, 2023).

Entretanto, observa-se nos centros urbanos semáforos ociosos, não atuados ou sem botoeiras, com dimensionamento benéfico ao veículo motorizado, ocasionando atrasos desnecessários aos pedestres e diminuindo seu Nível de Serviço, o que pode afetar a operação do tráfego como um todo.

O Nível de Serviço do pedestre é uma importante medida de desempenho baseada em sua percepção de segurança, eficiência e conforto em relação às condições de travessia oferecidas a eles, que incluem a infraestrutura e as características operacionais do tráfego (Marisamynathan; Vedagiri, 2019; Nag; Goswami, 2022), de forma a promover mínimo atraso e máxima segurança (Tiwari *et al.*, 2011).

A compreensão acerca das necessidades dos pedestres é importante para o planejamento e a operação dos transportes, mas na prática otimiza-se a operação do tráfego motorizado e há pouca priorização das dificuldades enfrentadas pelos pedestres (Marisamynathan; Vedagiri, 2019).

Assim, é necessário um melhor entendimento do processo de travessia dos pedestres com base no seu atraso, na velocidade veicular - por tipo de veículo - e nos *headways* por faixa, sobretudo em centros urbanos brasileiros, como Fortaleza.

Dessa forma, o objetivo desta pesquisa é customizar e aplicar uma ferramenta automatizada para coletar variáveis importantes em estudos de travessias de pedestres em interseções semaforizadas.

1.1 Problemas e questões motivadoras

As variáveis pertinentes à aceitação de *headways* no vermelho precisam ser coletadas para entendimento desse fenômeno. Contudo, a coleta de dados de forma manual, seja *in loco* ou por meio de observação em vídeo tem se mostrado um obstáculo, devido ao esforço, ao tempo e aos custos envolvidos, além da baixa confiabilidade e subjetividade relacionadas a quem realiza a coleta (Zaki *et al.*, 2012). Por isso, a utilização de ferramental para coleta automática de dados em vídeo é uma importante aliada na Engenharia de Transportes, mais especificamente na Operação de Tráfego, providenciando extração dos resultados de forma mais rápida e menos trabalhosa (Zaki *et al.*, 2012; Noh *et al.*, 2022). Dessa forma, a principal questão motivadora deste trabalho é: **como coletar as variáveis pertinentes à aceitação dos *headways* de forma automatizada?**

São muitas as variáveis que afetam o processo de aceitação de *headways* pelos pedestres no vermelho, tais como atraso, velocidade, tipo de veículo e número de faixas da via (Zhu *et al.*, 2021; Raoniar; Mauriya, 2022; Nikolaou *et al.*, 2023). Então, a segunda questão motivadora deste trabalho é: **qual a relação entre as variáveis pertinentes ao processo de aceitação de *headways* em interseções semaforizadas?**

Diante do exposto, o problema de pesquisa é a dificuldade de coletar as variáveis envolvidas na modelagem no processo da aceitação de *headways* pelos pedestres em travessias de interseções semaforizadas.

1.2 Objetivos

O objetivo geral desta pesquisa é customizar e aplicar uma ferramenta automatizada para coletar variáveis importantes em estudos de travessias de pedestres em interseções semaforizadas.

Para que este objetivo seja cumprido, será necessário alcançar os seguintes objetivos específicos:

- 1) Definir as variáveis importantes para a compreensão do fenômeno de aceitação de *headways* pelos pedestres;
- 2) Calibrar e validar uma ferramenta de coleta automatizada de variáveis relacionadas ao processo de aceitação de *headways* pelos pedestres;
- 3) Coletar e analisar dados de variáveis relativas ao processo de aceitação de *headways* em travessias semaforizadas.

1.3 Estrutura da dissertação

Esta dissertação de mestrado está dividida em cinco seções. A primeira é a introdução, que traz uma contextualização sobre o tema, as lacunas a serem preenchidas, as questões que motivaram a pesquisa e os objetivos. A segunda engloba a revisão da literatura acerca de conceitos importantes sobre *headways* veiculares, fatores que influenciam a travessia dos pedestres no vermelho e Visão Computacional. A terceira seção consiste na metodologia proposta para se atingir os objetivos da pesquisa, que inclui a escolha das variáveis pertinentes à aceitação de *headways* em travessias semaforizadas, a calibração e a validação da ferramenta, a aplicação da ferramenta e a análise exploratória das variáveis escolhidas, enquanto a quarta seção aborda os resultados obtidos após a aplicação da metodologia, com as discussões pertinentes a cada um. Por fim, a quinta e última seção mostra as conclusões, com as limitações encontradas e sugestões para futuros trabalhos.

2 REVISÃO DA LITERATURA

Para compreensão do tema e com o intuito de guiar o alcance dos objetivos propostos, a presente revisão da literatura é dividida em três tópicos. O primeiro aborda conceitos importantes acerca do processo de aceitação de *headways* em travessias no vermelho, o segundo apresenta fatores que influenciam essas travessias e o terceiro traz aspectos relacionados à Visão Computacional, assim como sua aplicação em estudos de tráfego.

2.1 Aceitação de *headways* por pedestres

Em interseções semaforizadas e não-semaforizadas ou em travessias de meio de quadra, os pedestres, no momento de sua travessia, podem ter à disposição brechas veiculares, ou *headways*, podendo aceitá-los ou não. No caso de interseções semaforizadas, a travessia no vermelho ou no vermelho piscante é considerada ilegal e expõe os pedestres a riscos de colisões com veículos caso aceitem esses *headways* (Dhoke *et al.*, 2021).

O *headway* pode ser adotado como o intervalo de tempo entre a posição do pedestre prestes a atravessar e o veículo que se aproxima, sendo considerado aceito caso o pedestre realize a travessia (Chandra *et al.*, 2014; Marisamynathan; Vedagiri, 2019). Outra forma é abordada no estudo de Koh e Wong (2014), que analisaram aceitação e rejeição de *headways* em dois estágios (entre a calçada inicial e o canteiro central e entre o canteiro central e a calçada final), e consideraram o *headway* aceito como a diferença de tempo entre o veículo que tocou a área de conflito imediatamente antes da travessia do pedestre e o veículo que tocou a área de conflito imediatamente depois.

Onelcin e Alver (2015) estimaram não apenas o *headway* temporal – chamado por eles de “Margem de Segurança” –, mas também o espacial. Os autores dividiram com cones as vias observadas em quatro trechos de 25m, contados a partir da faixa de retenção da interseção, e quando um pedestre aceitava um *headway*, os autores verificavam a que distância estava o veículo que se aproximava no momento da travessia.

No processo de aceitação dos *headways*, um parâmetro essencial a ser analisado é o *headway* crítico, que é o *headway* mínimo aceito pelo pedestre, parâmetro impactante no nível de serviço na travessia (Bandeira, 2019). Dois métodos conhecidos para se estimar o *headway* crítico são os de TRB (2016) e Chandra *et al.* (2014), ambos para travessias não-semaforizadas, já que se assume que não deve haver busca por *headways* em travessias semaforizadas.

O *headway* crítico proposto por TRB (2016), apresentado na Equação 1, depende do comprimento da travessia, e da velocidade média do pedestre e do seu tempo de reação a mudanças semafóricas, com valores sugeridos de 1,1 m/s e 3 s, respectivamente. Esse método é limitado devido a considerar apenas o tempo que o pedestre demora para atravessar (L/S_p), mas já é sabido que outros fatores como idade, gênero, velocidade e fluxo veiculares também influenciam no processo de aceitação de *headways* (Brosseau *et al.*, 2013; Onelcin; Alver, 2015; Song *et al.*, 2019; Afshari *et al.*, 2021, Mukherjee; Mitra, 2022; Raoniar; Mauriya, 2022).

$$t_c = \frac{L}{S_p} + t_s \quad (1)$$

onde:

t_c = *headway* crítico (s);

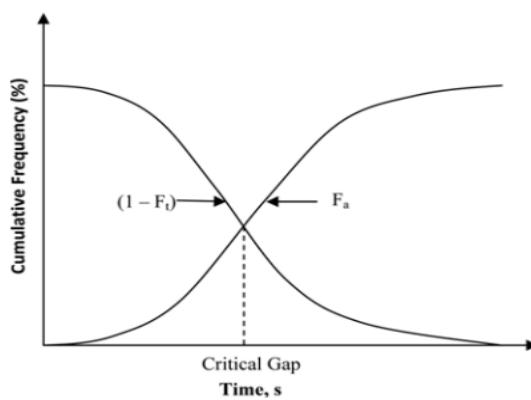
L = comprimento da travessia (m);

S_p = velocidade do pedestre (m/s);

t_s = tempo de folga antes do início e após o final da travessia do pedestre (s).

Chandra *et al.* (2014) estimaram o *headway* crítico como o ponto de interseção entre a curva de distribuição cumulativa dos *headways* aceitos (F_a) e do complemento da curva de distribuição cumulativa dos tempos de travessia ($1 - F_t$), apresentadas na Figura 1, considerando assim o *headway* crítico igual ao tempo que o pedestre leva para realizar travessia.

Figura 1 - Estimação do *headway* crítico



Fonte: Chandra *et al.* (2014)

Os autores aplicaram esse método em 17 locais de 5 cidades da Índia, e constataram que os *headways* críticos dos homens para diferentes larguras de via (média de 10,3 s para 3 faixas e 2 sentidos, 8,6 s para 2 faixas e 2 sentidos e 8,5 s para 2 faixas e 1 sentido) foram

menores que os das mulheres nos mesmos cenários (médias de 11,6 s, 9,0 s e 9,1 s, respectivamente), e que o *headway* crítico aumentou com o avanço da idade (médias de 10,4 s, 8,0 s e 8,1 s para jovens e 15,3 s, 10,4 s e 8,8 s para idosos). Ainda, um maior número de faixas e de sentidos aumentou o *headway* crítico, ao passo de que um maior fluxo veicular o diminui.

Em travessias semaforizadas, Bandeira *et al.* (2021) calibraram o *headway* crítico em duas travessias de meio de quadra na cidade de Fortaleza por meio de microssimulação, usando o atraso dos pedestres como medida-alvo de calibração. Os autores consideraram na simulação que 100% dos pedestres procuravam *headways*, o que superestimou o *headway* crítico para se equiparar o atraso simulado ao encontrado em campo. Essa premissa foi adotada pois a proporção de pedestres que de fato procura *headways* para atravessar no vermelho é um parâmetro extremamente desafiador de se estimar *in loco*, devido à dificuldade de se prever com exatidão o comportamento dos pedestres em travessias.

2.2 Fatores que influenciam a travessia de pedestres no vermelho

A travessia de pedestres no vermelho pode ser influenciada por fatores pessoais (gênero, idade, escolaridade), psicológicos (atitude, percepção ao risco), ambientais (número de pedestres atravessando no vermelho) e relacionados ao tráfego e à via (fluxo veicular, comprimento da faixa de pedestres, duração do vermelho) (Afshari *et al.*, 2021).

Neste trabalho, será investigado o processo de travessia no vermelho em interseções baseado no atraso dos pedestres e nos *headways* veiculares, então os fatores destacados na revisão que será mostrada a seguir foram o atraso dos pedestres, o fluxo veicular, o tipo de veículo, a velocidade veicular e o número de faixas da via.

2.2.1 Atraso

O atraso é definido como a diferença de tempo entre o momento em que o pedestre chega na interseção para atravessá-la e o momento em que ele inicia sua travessia na faixa de pedestres (Zhu *et al.*, 2021).

Em teoria, todos os pedestres que chegam no vermelho piscante ou no vermelho devem esperar o começo do verde do próximo ciclo para atravessar a interseção, mas na prática eles acabam decidindo por atravessar no vermelho por conta de longos atrasos (Zhao, Liu; 2017), tendência endossada por TRB (2016), que afirma que um atraso superior a 30 s começa a gerar desconforto para o pedestre. Seguindo essa premissa, Rakotoarivelo *et al.* (2023)

adotaram a hipótese de que cada pedestre tem um tempo aceitável máximo de espera (*Accepted Waiting Time*, ou AWT), e que pode haver comportamento de risco caso o pedestre espere mais do que esse tempo. Outra questão relacionada a longos tempos de espera é sua influência na aceitação de *headways* menores (Onelcin; Alver, 2015).

O atraso foi apontado como relevante para a travessia no vermelho na maioria dos trabalhos lidos, apresentando relação com o tempo semafórico, pois maiores tempos de vermelho para o pedestre aumentam sua propensão de procurar *headways* veiculares (Guo *et al.*, 2011; Brosseau *et al.*, 2013; Marisamynathan; Vedagiri, 2014; Dommes *et al.*, 2015; Zhang *et al.*, 2016; Song *et al.*, 2019; Ma *et al.*, 2020; Afshari *et al.*, 2021; Bendak *et al.*, 2021; Dhoke *et al.*, 2021; Karimpour *et al.*, 2021; Wu *et al.*, 2021; Zhu *et al.*, 2021; Raoniar; Mauriya, 2022; Alomari *et al.*, 2023; Rakotoarivelo *et al.*, 2023).

É interessante detalhar três desses trabalhos. O primeiro é o de Guo *et al.* (2011), que analisaram a relação direta do atraso do pedestre com a violação semafórica por meio de uma metodologia *Hazard-based*, que consiste em uma série de equações matemáticas que retornam uma taxa de risco (*hazard rate*) de um determinado evento acontecer a cada unidade de tempo. O estudo foi feito em uma amostra de 7 interseções na China, e percebeu-se que 10% dos pedestres observados atravessaram com até 3 s de espera, ou seja, assim que chegaram na calçada. O tempo de espera médio foi de 17 s e aproximadamente 50% dos pedestres atravessaram no vermelho somente após 50 s de espera. Os autores também conseguiram detectar que homens esperaram menos tempo, assim como os pedestres em áreas comerciais e residenciais; já os idosos e os pedestres que transitavam em áreas educacionais realizaram travessia depois de um tempo mais longo.

Posteriormente, Brosseau *et al.* (2013) observaram 13 interseções no Canadá, classificando-as com tempo de espera curto (40 a 45 s de vermelho), médio (46 a 55 s de vermelho) e longo (acima de 55 s de vermelho). Verificou-se que as interseções com tempo de espera longo apresentaram maiores chances de travessias irregulares por parte dos pedestres.

Por fim, na Índia, Raoniar e Mauriya (2022) realizaram estudo em 3 interseções semafORIZADAS, separando o tempo de espera até o verde para os pedestres em 3 categorias: de 0 a 20 s, de 21 a 40 s e acima de 40 s. Uma amostra de 2360 pedestres foi coletada e observou-se por meio de modelos de regressão logística que o tempo de espera e o tamanho do ciclo semafórico influenciaram significativamente na travessia no vermelho, pois a probabilidade desse tipo de travessia em tempos de espera até o verde de 21 a 40 s e acima de 40 s aumentou 18,3% e 21,4% em relação a uma espera pelo verde de até 20 s. Assim como Brosseau *et al.* (2013), os autores concluíram que tempos de vermelho muito longos podem ocasionar tempos

de espera que não atendem às expectativas do pedestre, aumentando sua tendência de colocar sua segurança em risco e atravessar irregularmente, aspecto também destacado por Alomari *et al.* (2023) em estudos mais recentes na Jordânia.

2.2.2 Fluxo veicular

O fluxo veicular foi apontado como um fator de influência em travessias no vermelho nos estudos de Duduta *et al.* (2014), Dommes *et al.* (2015), Diependaele (2018), Song *et al.* (2019), Ma *et al.* (2020), Afshari *et al.* (2021), Zhu *et al.* (2021), Mukherjee e Mitra (2022) e Raoniar e Maurya (2022), e, em todos eles, maiores volumes veiculares diminuem a probabilidade de aceitação de *headways* por parte dos pedestres.

Diependaele (2018), na Bélgica, verificou uma influência positiva do tráfego de veículos na obediência do semáforo por parte dos pedestres, sendo maior quanto maior o fluxo veicular e quanto mais complexo estiver o tráfego no momento (formação de filas, mudanças de faixa etc.). Foi observado que a frequência de travessia reduziu de 24% para 17% entre o 25º e o 75º percentil do número total de veículos. A porcentagem de travessia no vermelho foi maior fora dos horários de pico, mas especificamente em torno de 10h, 14h e 18h, com uma média de 22%, diminuindo para 20% nos horários de 8h, 12h e 16h30, quando havia maior fluxo veicular.

Ma *et al.* (2020), em uma amostra de 3 interseções semaforizadas na China, classificaram o fluxo veicular das interseções estudadas em três categorias: baixo (menor que 300 ucp/h/faixa), médio (entre 250 e 550 ucp/h/faixa) e alto (maior que 500 ucp/h/faixa). Inferiu-se que 40% dos pedestres que realizaram travessia no vermelho o fizeram quando o volume de veículos era médio, e quando esse volume era alto a proporção de travessias no vermelho diminuiu para 30%.

Afshari *et al.* (2021) estudaram as travessias no vermelho em 6 interseções e utilizaram regressão logística para identificar os fatores que mais influenciam a travessia no vermelho no Irã, calculando os *odds ratio* para quantificar o quanto as variáveis independentes afetam a variável dependente. Foi constatado que o aumento de um veículo por faixa por minuto no volume do tráfego diminuiu em 9,5% as chances de travessia dos pedestres no vermelho.

Ocasionalmente, um maior volume de tráfego diminui o tamanho e a frequência dos *headways* aceitáveis, reduzindo a tendência a travessias arriscadas (Dommes *et al.*, 2015, Raoniar; Mauriya, 2022), mas pode haver oferta satisfatória de *headways* mesmo com fluxo veicular muito intenso, como mostrado em Duduta *et al.* (2014). Demandas veiculares altas

podem gerar filas, que podem aumentar a incidência de travessias no vermelho. Por isso, para compreender o processo de aceitação de *headways* é essencial analisar o padrão de chegada dos veículos, ou seja, a distribuição dos *headways* veiculares.

2.2.3 Tipo de veículo

A decisão de travessia dos pedestres é influenciada pelo tipo de veículo que se dirige à interseção, pois a probabilidade de aceitar *headways* aumenta com a diminuição do tamanho do veículo (Marisamynathan; Vedagiri, 2014).

Zhu *et al.* (2021), que avaliaram 6 interseções semaforizadas em Hong Kong, inferiram por meio de um modelo de regressão logística que, aumentando 1% no volume de veículos pesados trafegando na via, a chance de travessia no vermelho ficou 0,48% menor, pois a chance de lesões graves é maior quando há conflitos envolvendo veículos pesados (ônibus e caminhões). Além disso, concluíram que sinais de alerta indicando a presença de veículos pesados poderiam colaborar com o aumento da autopreservação dos pedestres para atravessar no vermelho.

Onelcin e Alver (2015) que, como salientado anteriormente, estudaram o *headway* espacial, verificaram que nenhum pedestre atravessou a via quando havia um ônibus ou caminhão a menos de 25 m de distância, aumentando a quantidade de pedestres atravessando no semáforo vermelho se havia um veículo pesado a 50m de distância ou mais.

O trabalho de Koh e Wong (2014) em Cingapura mostrou que, proporcionalmente à quantidade de cada tipo de veículo, o maior número de *headways* rejeitados foi o referente aos veículos pesados (HGVs), sendo 29 rejeitadas em 44 observações, ou 66% do total.

2.2.4 Velocidade veicular

A velocidade veicular foi encontrada como importante para a decisão dos pedestres de atravessar a via nos estudos de Kadali e Vedagiri (2013), Liu e Tung (2014), Onelcin e Alver (2017), Kumar e Ghosh (2022), Mukherjee e Mitra (2022) e Nikolaou *et al.* (2023).

Liu e Tung (2014) entrevistaram 32 pedestres acerca sua percepção de risco em travessias com veículos a 40 km/h, 60 km/h e 80 km/h. A análise apontou que a decisão de realizar travessias dependeu da distância entre o veículo e o pedestre, que diminuiu mais rapidamente com o aumento da velocidade dos veículos, consequentemente reduzindo as travessias arriscadas.

Onelcin e Alver (2017) estudaram 6 travessias semaforizadas na Turquia com limites de velocidade de 30 km/h e 50 km/h e observaram que menos *headways* foram aceitos quando os veículos estavam trafegando a mais de 30km/h em comparação à proporção de travessias no vermelho a velocidades menores que 30 km/h. Os resultados de Onelcin e Alver (2017) reforçam o apontado por Kadali e Vedagiri (2013), que concluíram que os pedestres tendem a exigir *headways* maiores com o aumento da velocidade veicular numa tentativa de aumentar sua segurança na travessia.

Kumar e Ghosh (2022) e Mukherjee e Mitra (2022), cujos estudos foram realizados em travessias semaforizadas na Índia, também apontam importância da velocidade veicular na travessia dos pedestres. No primeiro, os autores analisaram potenciais conflitos entre pedestres e veículos em 12 interseções com o auxílio de modelos de regressão, e inferiram que a severidade desses conflitos é significativamente afetada pela velocidade veicular, aumentando as chances de severidade alta com velocidades veiculares altas durante o vermelho. No segundo, no qual foram estudadas 55 interseções por meio de dados históricos, aplicação de questionários e observação das travessias, os resultados apontaram que o aumento em 10 km/h na velocidade veicular diminuiu em 10% as chances de travessias no vermelho.

2.2.5 Número de faixas da via

O número de faixas da via atua de forma inversamente proporcional no comportamento dos pedestres na travessia, ou seja, quanto mais faixas a via apresenta, menor a chance de travessias no vermelho (Diependaele, 2018; Song *et al.*, 2019; Bendak *et al.*, 2021; Zhu *et al.*, 2021; Kumar; Ghosh, 2022).

Serão destacados a seguir os trabalhos de Diependaele (2018), Bendak *et al.* (2021) e Zhu *et al.* (2021). No trabalho de Diependaele (2018), no qual foram observadas em campo 72 interseções semaforizadas, as travessias nas vias com uma faixa por sentido mostraram 25% de travessias no vermelho, e nas com 2 e 3 faixas, essa proporção diminuiu para 15% e 10%.

Nos Emirados Árabes, Bendak *et al.* (2021) examinaram 10 travessias semaforizadas de sentido duplo e notou-se que houve 13,9% de travessias no vermelho nas vias de 2 faixas, 19% nas de 3 faixas e 0% nas de 4 faixas. Ainda, inferiram que quanto maior o número de faixas, maior é a velocidade do pedestre na travessia.

Finalmente, Zhu *et al.* (2021) encontraram em seu estudo que o aumento no número de faixas está significativamente correlacionado com a diminuição de frequência de travessias no vermelho com um nível de confiança de 1%.

Marisamynathan e Vedagiri (2019) e Hashemi *et al.* (2022) complementam que os pedestres visualizam com mais facilidade o tamanho do *headway* veicular na faixa mais próxima de sua calçada e decidem atravessar no vermelho, enquanto a identificação do tamanho do *headway* veicular nas faixas mais distantes é dificultado. Portanto, um número de faixas maior pode obrigar o pedestre a avaliar *headways* a uma distância maior, o que pode diminuir as chances de sua travessia e consequentemente aumentar seu atraso.

2.3 Uso da Visão Computacional em estudos de travessias de pedestres

A Visão Computacional pode ser uma importante aliada nas análises de travessias de pedestres por possibilitar uma coleta rápida, automatizada e precisa dos parâmetros necessários, como o tamanho de todos os *headways* disponíveis a partir do momento em que o pedestre inicia sua espera na interseção e do *headway* aceito quando ele realiza sua travessia, uma tarefa complexa se realizada de forma manual. Tal método também facilita a obtenção de parâmetros como a velocidade de caminhada, a trajetória e o atraso dos pedestres, entre outros, abrindo possibilidades para estudos variados acerca do comportamento dos pedestres em seu deslocamento.

Nesta seção, serão explicados os principais parâmetros coletados com o auxílio da Visão Computacional na interação entre veículos e pedestres, assim como as principais ferramentas utilizadas, conceitos importantes, métricas para validação do método e a importância do treinamento para melhoria do modelo.

2.3.1 Parâmetros coletados

Diversos trabalhos realizaram coleta de dados relacionados aos pedestres e à sua interação com veículos em travessias por meio da Visão Computacional, (Zaki *et al.*, 2012; Khan; Bandini, 2014; Sayed *et al.*, 2016; Ibadov *et al.*, 2017; Zhang *et al.*, 2020; Alver *et al.*, 2021; Ansarnia *et al.*, 2022; Noh *et al.*, 2022; Kolluri; Das, 2023).

Um exemplo é o trabalho de Sayed *et al.* (2016), que mostrou aplicações da coleta de dados de pedestres usando Visão Computacional. Uma delas analisou violações temporais e espaciais dos pedestres em suas travessias em um vídeo de 45 minutos de uma interseção no Canadá. A violação espacial foi obtida definindo a faixa de pedestres como área de travessia correta e demarcando manualmente as trajetórias dentro dessa área (*ground truth*), e comparando com as trajetórias de travessia detectadas pelo modelo, e os pedestres detectados

em trajetórias de travessia fora da faixa foram considerados violadores. Já a violação temporal foi coletada como a detecção do momento em que cada pedestre atravessou e a comparação com o semáforo no momento dessa travessia, e se o semáforo estivesse verde para os veículos, o pedestre era classificado como violador. Além disso, todos os pedestres que apareceram no vídeo foram contabilizados e classificados manualmente para verificação da qualidade da identificação pelo modelo.

A coleta manual identificou 450 pedestres, com 108 classificados como violadores espaciais e 11 como violadores temporais. Já o modelo rastreou 376 pedestres, dos quais 97 foram classificados como violadores espaciais, com uma taxa de 84,5% de verdadeiros positivos (aqueles que foram identificados como violadores espaciais e de fato eram) e 9,3% de falsos positivos (aqueles que foram identificados como violadores espaciais mas não o eram). Os autores observaram que apenas 11 pedestres foram perdidos pelo modelo em comparação com a coleta manual, ou seja, considerados falsos negativos, perda esta que foi ocasionada pelo fato de eles terem realizado a mesma trajetória a uma velocidade parecida e não terem sido reconhecidos como objetos distintos pela ferramenta, fenômeno chamado por eles de *over-grouping*. Para a violação temporal, o modelo rastreou todos os 11 pedestres corretamente, mostrando uma taxa de acerto de 100%.

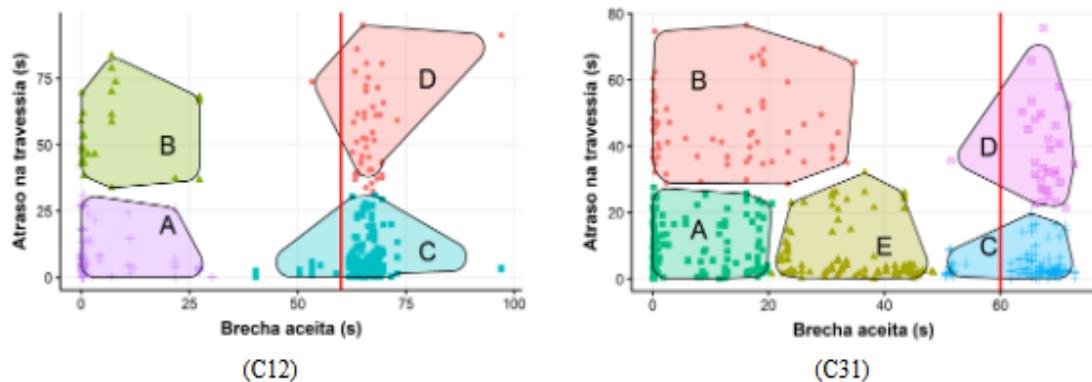
A Visão Computacional também foi usada por Zhang *et al.* (2020) na observação de travessias no vermelho associadas a indicadores de segurança viária, como o *Post-Encroachment Time* (PET), definido pela diferença de tempo entre o momento em que o primeiro veículo ou pedestre deixa a potencial área de colisão e o segundo chega até ela, tendo um valor limite de 6 s. Analisou-se as filmagens de uma faixa de pedestres em uma interseção de uma universidade na Flórida, com um volume veicular de 200 veic/h, e 122 pedestres foram rastreados durante as horas de pico da tarde. O modelo apresentou uma acurácia de 91,6% na faixa de pedestres analisada, e observou-se que, dos 122 pedestres, 43 atravessaram no vermelho, aproximadamente um terço do total. Desses 43 pedestres, 23 apresentaram um PET menor do que o limite de 6 s, o que indica que eles se colocaram em potencial situação de conflito. Pode-se comparar com o número de pedestres que apresentaram PET menor que 6 s dentre os que esperaram o verde para atravessar, que foram apenas 11 de um total de 79.

Pode-se também coletar parâmetros como velocidade de travessia, aceitação e rejeição de *headways* e *headway* crítico, como visto em Alver *et al.* (2021), em duas travessias de meio de quadra em Izmir, na Turquia. Foi possível rastrear 498 pedestres por processamento de imagem em 1h de coleta, das 17h às 18h. Comparando a utilização do algoritmo com a coleta de dados manual, houve uma diferença de 4,83% na contagem de pedestres em uma travessia e

2,66% na outra, retornando uma taxa de detecção bem-sucedida de mais de 95%. Em relação à velocidade dos pedestres, houve diferença de 4% entre a coleta manual e a automatizada, com valores médios em torno de 1 a 1,2 m/s, e para a brecha crítica houve diferença de 3,8%, com média de 5,3 s pelo algoritmo e 5,1 s pela coleta manual.

Nacionalmente, Castro Jr. *et al.* (2021) usaram algoritmos de Visão Computacional em vídeos de travessias semaforizadas de Fortaleza para estimar os atrasos dos pedestres e seus *headways* aceitos. Os atrasos foram comparados com os do TRB (2016) e investigou-se a relação entre o atraso e o tamanho do *headway* aceito, por meio de gráficos de dispersão e do método de agrupamento *k-means*. A Figura 2 mostra os resultados do agrupamento para duas das travessias, C12 e C31.

Figura 2 - Resultados do agrupamento de atraso e *headways* das travessias C12 e C31



Fonte: Castro Jr. *et al.* (2021)

Analisando a relação entre *headways* aceitos e atraso mostradas na Figura, os autores inferiram que os pedestres dos grupos A e B foram considerados os mais críticos, aceitando *headways* menores que 20 s e 40 s nas interseções C12 e C31, respectivamente, com o grupo A apresentando menores atrasos que o grupo B. Na interseção com menor proporção dos pedestres críticos (C12), foi observado um fluxo veicular 35% maior e um tempo de verde para os pedestres 12% menor do que na com mais pedestres críticos (C35), além de um menor atraso, o que sinaliza a relação entre menores tempos de verde e ciclo semafórico e atraso menor. Dessa forma, concluiu-se que o fluxo veicular e o tempo de verde influenciaram a aceitação de *headways*.

O estudo de Castro Jr. *et al.* (2021) apresenta problemas relacionados à coleta do atraso, considerado no estudo como a diferença de tempo entre o momento em que o pedestre apareceu no vídeo e o momento em que ele iniciou a travessia, portanto superestimando o atraso. Outro desafio apontado pelos autores foi a quantidade de erros na detecção e no rastreio,

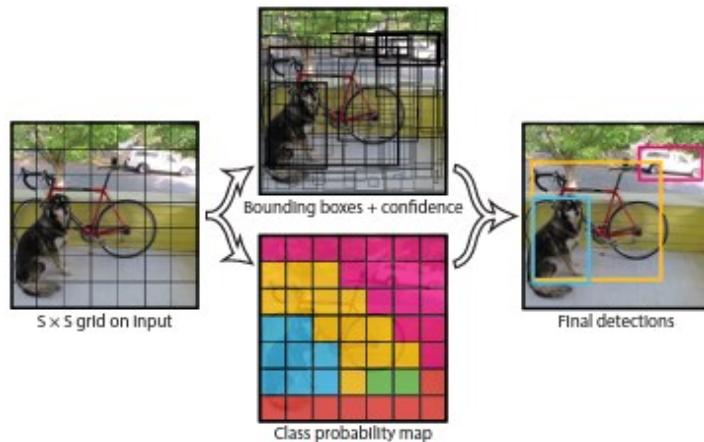
principalmente quando havia aglomeração de pedestres na travessia. Este trabalho procura solucionar esses problemas, estimando o atraso a partir do instante do início da espera dos pedestres, e melhorando a precisão do ferramental, para investigar de forma mais confiável a relação do atraso com os *headways* aceitos.

2.3.2 Ferramentas utilizadas

A principal ferramenta de detecção encontrada na literatura, por ser relativamente simples, eficiente, leve computacionalmente e de fácil customização, foi a chamada *You Only Look Once*, ou YOLO (Asha; Narashimadham, 2018; Lin; Sun, 2018; Bathija; Sharma, 2019; Zhang *et al.*, 2020; Al-qaness *et al.*, 2021; Alver *et al.*, 2021; Kolluri; Das, 2023), nas versões v3 (Redmon; Farhadi, 2018), v4 (Bochkovskiy *et al.*, 2020) e v5 (Ultralytics, 2020). Até o fechamento desta dissertação, a versão mais atualizada é a v8 (Ultralytics, 2023), que traz melhorias relacionadas à performance, flexibilidade e eficiência do modelo em suas detecções, sem prejudicar a velocidade do processamento.

O YOLO é um algoritmo que tem um esqueleto de Rede Neural Convolucional (CNN) como uma de suas partes, que consiste em um conjunto de neurônios que apresentam pesos de aprendizado e funções de ativação, responsáveis por passar as informações pela rede e providenciar uma resposta de saída, localizando e classificando objetos (Bathija; Sharma, 2019). Ele funciona dividindo as imagens de entrada em blocos de dimensões iguais e verifica em cada bloco se há objetos, por meio da localização de seus centroides. Se o YOLO detectou um objeto naquele bloco, é desenhada uma caixa delimitadora (*bounding box*) em volta dele e é calculado um valor de confiança que combina a probabilidade de a *bounding box* realmente ter aquele objeto e o valor de previsão de sua classe; se esse valor de confiança for maior do que o limite mínimo (*threshold*), o objeto é considerado como detectado (Asha; Narashimadham, 2018; Redmon; Farhadi, 2018; Bochkovskiy *et al.*, 2020; Al-qaness *et al.*, 2021). Na Figura 3 é exibida uma ilustração de como funciona a detecção.

Figura 3 - Detecção no YOLO



Fonte: Redmon *et al.* (2016)

O arquivo de saída do YOLO é composto por uma lista de todos os objetos detectados com sua classe, seu valor de confiança e as coordenadas da *bounding box*, que podem ser as coordenadas x e y do ponto superior esquerdo, altura e largura (Leal-Taixé *et al.*, 2015).

Há outros sistemas de detecção de objetos que podem ser utilizados, como R-CNN, Fast R-CNN, Faster R-CNN e Mask R-CNN, mas o YOLO é vantajoso devido à sua rapidez, já que realiza o processamento da imagem apenas uma vez e gera todas as *bounding boxes* existentes ao mesmo tempo, sendo uma ótima opção quando se tem uma necessidade de detecção em tempo real sem perder muito da precisão (Bathija; Sharma, 2019).

Para o rastreio dos objetos, foram encontradas menções relacionadas ao uso do algoritmo *Simple Online and Realtime Tracking*, ou SORT (Bewley *et al.*, 2016) e a seu sucessor, *Simple Online and Realtime Tracking with a Deep Association Metric*, ou DeepSORT (Wojke *et al.*, 2017) nos trabalhos de Bathija e Sharma (2019), Zhang *et al.* (2020) e Alver *et al.* (2021). De acordo com Bewley *et al.* (2016), o SORT é um rastreador de múltiplos objetos (MOT) muito utilizado por sua velocidade e acurácia, com o objetivo de associar detecções dos objetos de interesse ao longo de *frames* consecutivos de um vídeo e extrair seus movimentos.

Assim que um objeto aparece, o SORT recebe os dados resultantes da detecção (confiança, *bounding box* e classe) referentes a ele, associa a um classificador numérico (ID) e faz uma estimativa do movimento daquele objeto no *frame* seguinte, baseado em sua localização nos *frames* anterior e atual. Caso o objeto não seja mais identificado por um número de *frames* configurado previamente, entende-se que ele saiu da imagem e seu ID é removido.

Esse processo é desafiador para o algoritmo, pois os objetos-alvo podem sofrer oclusão e desaparecer e reaparecer depois de alguns *frames*, o que os faz receber novos IDs,

além de ocorrer possíveis similaridades entre objetos, variações na iluminação, mudanças na escala, movimentos abruptos ou deformação de objetos e do plano de fundo. Entretanto, essa abordagem é considerada um progresso no rastreio por detecção (Bewley *et al.*, 2016; Bathija; Sharma, 2019).

O DeepSORT (Wojke *et al.*, 2017) é uma versão melhorada do SORT, permitindo o rastreio de objetos após períodos de oclusão mais longos, reduzindo a mudança de identificação em 45%. Em 2022, foi lançado o StrongSORT (Du *et al.*, 2023), que propõe menos perdas, maior confiabilidade e maior estabilidade no rastreio e menos ruídos na detecção.

2.3.3 Medidas de desempenho

Segundo Padilla *et al.* (2020), a medida de desempenho mais comum para verificar se o detector está prevendo e classificando corretamente os objetos em uma imagem é a *Average Precision* (AP), obtida por classe e calculada pela área abaixo da curva composta por duas métricas: precisão e revocação, ou *recall*, e quanto mais alto esse valor, melhor a previsão do modelo para aquela classe. Maiores detalhes sobre a curva precisão x revocação e como construí-la são encontrados em seu artigo.

Como é definida uma AP para cada classe e um detector pode ser usado em objetos de várias classes, pode-se calcular uma média aritmética entre todas as APs, ou *Mean Average Precision* (mAP), que traduz o desempenho geral do detector (Al-qaness *et al.*, 2021).

A precisão, representada matematicamente pela Equação 2, é definida pela razão entre o número de objetos de uma classe que o detector previu corretamente (verdadeiro positivo) e todos os objetos previstos pelo detector como daquela classe, podendo haver detecções incorretas de pedaços do plano de fundo ou objetos de outras classes, os chamados falsos positivos. Já a revocação, ou *recall*, mostrada na Equação 3, é a razão entre todos o número de objetos de uma classe previstos corretamente e todos os objetos identificados manualmente (*ground truth*), nesse caso havendo possibilidade de o detector incorretamente desconsiderar uma *bounding box* que deveria ser considerada, o chamado falso negativo (Bathija; Sharma, 2019; Padilla *et al.*, 2020).

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (2)$$

$$\text{Revocação} = \frac{VP}{VP + FN} \quad (3)$$

Onde:

VP = verdadeiros positivos;

FP = falsos positivos;

FN = falsos negativos.

Outra medida de desempenho importante é a chamada *Intersection Over Union* (IOU), ilustrada na Figura 4, que de acordo com Padilla *et al.* (2020) é a área de sobreposição entre a *bounding box* prevista pelo modelo e a *bounding box* inserida manualmente dividida pela união entre elas. A IOU encontrada para cada objeto é comparada com um valor limite mínimo, normalmente de 50% (Al-qaness *et al.*, 2021), e se seu valor for maior que o limite, a detecção é considerada correta; caso contrário, considera-se que a detecção não corresponde ao mesmo objeto porque de fato não são os mesmos ou por erro na estimativa.

Figura 4 - Ilustração da IOU

$$IOU = \frac{\text{area of overlap}}{\text{area of union}} = \frac{\text{[Diagrama de sobreposição]}}{\text{[Diagrama de união]}}$$

Fonte: Padilla *et al.* (2020)

Foram encontrados resultados de precisão e revocação altos nos trabalhos de Asha e Narashimadham (2018), que realizaram contagem de veículos usando câmeras portáteis em 4 pontos de uma rodovia, e de Zhang *et al.* (2020), que estudaram as travessias de pedestres no vermelho do ponto de vista da segurança viária em uma travessia. Ambos utilizaram o YOLO e apresentaram precisão e revocação acima de 90%.

Para o mAP e o IOU, Ansarnia *et al.* (2022), utilizando um algoritmo de classificação chamado FCHarDNet, encontraram valores de 84% e 78%, respectivamente. Uma possível causa para esses resultados foi o fato de que foram escolhidos vídeos filmados de cima, o que dificulta uma identificação mais precisa dos objetos. Usando o YOLO, Zhang *et al.* (2020) obtiveram um mAP de 93,8% e Al-qaness *et al.* (2021) apresentaram IOUs médios de 89%, 86% e 81% em vídeos filmados com céu limpo, com névoa e à noite, o que mostra a influência da luminosidade e da visibilidade para um bom desempenho do detector.

2.3.4 Treinamento

Quando se usa uma ferramenta de detecção e rastreio, ela usualmente está pré-configurada em um modo padrão, para certas classes e perspectivas de objetos em imagens de bancos de dados já existentes, como discutido em tópicos anteriores, o que pode não ser adequado para a situação a ser estudada pelo usuário, gerando medidas de desempenho baixas e resultados insatisfatórios. Assim, é preciso treiná-la para que seja possível utilizá-la em imagens que refletem as situações do estudo em questão, no intuito de se alcançar resultados melhores na detecção.

O treinamento pode ser realizado com imagens rotuladas disponíveis nos bancos de imagens ou com um conjunto de imagens criado de forma customizada, como fizeram Bathija e Sharma (2019) e Ansarnia *et al.* (2022), que selecionaram as imagens pertinentes a seu estudo, e criaram manualmente as *bounding boxes* para cada objeto, separando-os em classes, com o software LabelImg.

É importante se atentar a alguns detalhes quanto ao treinamento de uma ferramenta de detecção. O primeiro deles é a separação das imagens em três grupos: treino, validação e teste. As imagens de treino são as usadas para o aprendizado da ferramenta, as de validação para a avaliação e eventual melhoria dos parâmetros e diminuição do erro durante o treinamento, e as de teste para a avaliação final do desempenho do modelo após o ajuste de seus parâmetros (Genc; Tunc, 2019).

A separação das imagens para treino, validação e teste é realizada de forma aleatória estratificada, e normalmente é usada uma proporção de 70%/15%/15% (Genc; Tunc, 2019), mas foram encontradas proporções diferentes na literatura, como em Zhang *et al.* (2020), que usaram 75% para treino/validação e 25% para teste, e Ansarnia *et al.* (2022), que separaram suas imagens apenas em treino (75%) e validação (25%), sem banco de teste, então é possível inferir que a aplicação depende do tamanho e da variedade da amostra.

Outro aspecto importante é apontado por Al-qaness *et al.* (2021), que dissertam sobre a diferença entre treinar um algoritmo do zero ou usar uma rede previamente treinada, o chamado *transfer learning*. Segundo os autores, quando um treinamento é iniciado do zero, ele requer um maior tempo de processamento e um maior banco de imagens; já no *transfer learning*, os pesos já estão previamente treinados, então o processamento é mais rápido. Para o treinamento do YOLO, por exemplo, são necessárias cerca de 300 imagens por classe de objetos quando se utiliza pesos já treinados, contra as 2000 necessárias quando o treinamento é feito do zero. Os autores também comentam que, em alguns casos, a acurácia da classificação é maior

quando se utiliza um peso pré-treinado do que quando o algoritmo realiza seu aprendizado do zero.

Um exemplo de como o treinamento pode melhorar a qualidade de um detector é o trabalho de Ansarnia *et al.* (2022). Antes do treinamento com um banco de imagens customizado para as classes carro, pessoa, bicicleta, estrada, vegetação e calçada, foram obtidos um mAP de 84% e um IOU médio de 76%, como apresentado no tópico anterior, e após o treinamento, o mAP aumentou para 86% e o IOU médio para 79,5%.

2.4 Considerações sobre a Revisão da Literatura

A aceitação de *headways* no vermelho em interseções semaforizadas é um importante processo para compreensão do comportamento dos pedestres nas travessias. O *headway* é adotado de formas diferentes na literatura, podendo ser o intervalo de tempo entre o pedestre prestes a atravessar e o veículo que se aproxima, o intervalo de tempo entre os veículos que passaram pela faixa de pedestres antes e depois da travessia do pedestre, ou a distância entre o pedestre e o veículo no momento da travessia. O *headway* mínimo aceito pelo pedestre é chamado de *headway* crítico, sendo um parâmetro impactante no nível de serviço da travessia.

Ainda, de acordo com a revisão da literatura, há fatores que influenciam a travessia de pedestres no vermelho, como o atraso, o fluxo veicular, o tipo de veículo, a velocidade veicular e o número de faixas da via. O atraso dos pedestres é diretamente proporcional à probabilidade de travessia no vermelho, pois maiores tempos de vermelho aumentam as chances de o pedestre procurar por *headways*. Já o fluxo veicular se mostra relevante pois quanto maior a quantidade de veículos na via, menor a tendência de aceitação de *headways*. Em relação ao tipo de veículo, a presença de veículos maiores tende a inibir a travessia dos pedestres no vermelho. A velocidade veicular, assim como o fluxo e o tipo de veículo, se comporta de forma inversamente proporcional à probabilidade de travessia no vermelho, pois quanto maior a velocidade veicular, menor o número de *headways* aceitos. Por fim, um maior número de faixas na via diminui as chances de travessia no vermelho.

A coleta dessas variáveis pode ser realizada por meio de Visão Computacional, por ser uma forma mais rápida e precisa do que a coleta manual, de acordo com os trabalhos pesquisados. A principal ferramenta de detecção encontrada na literatura é a YOLO (*You Only Look Once*), por sua simplicidade e eficiência. Para o rastreio, um algoritmo amplamente utilizado é o SORT (*Simple Online and Realtime Tracking*), juntamente com seus sucessores, DeepSORT e StrongSORT, os quais apresentam elevada velocidade e acurácia. As principais

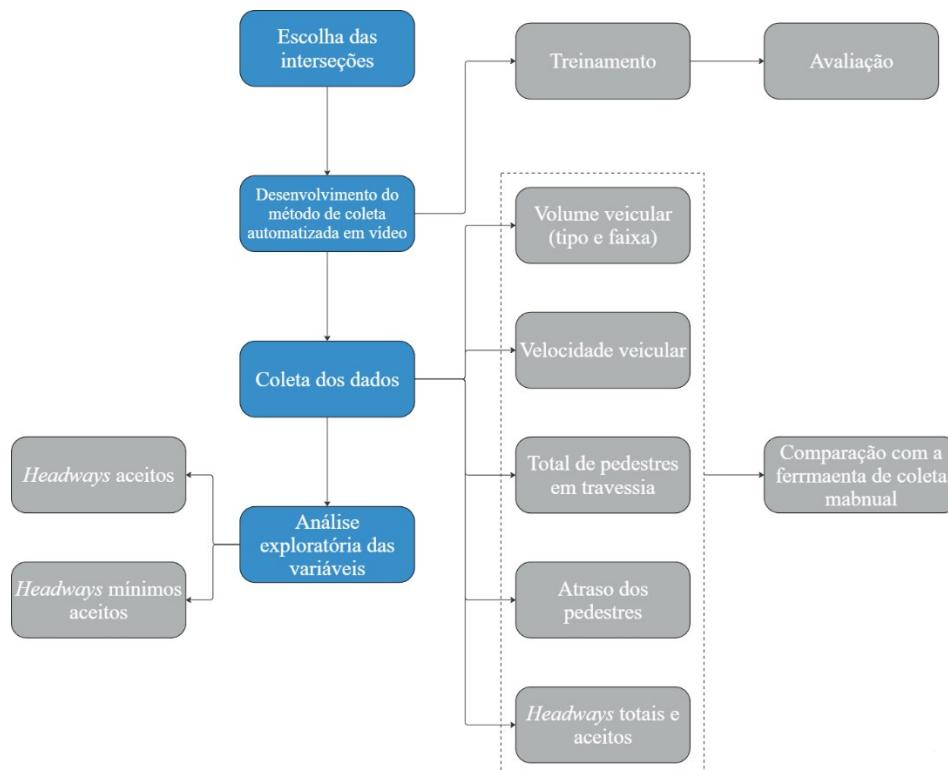
medidas de desempenho para verificação da qualidade do detector são a AP (*Average Precision*), a mAP (*Mean Average Precision*), a precisão (*Precision*), a revocação (*Recall*) e a IOU (*Intersection Over Union*).

A depender dos resultados das medidas de desempenho, é possível melhorar a detecção e possibilitar sua utilização em imagens mais específicas relacionadas ao estudo, por meio de um treinamento. No treinamento, divide-se o banco de imagens em 3 grupos (treino, validação e teste), para o aprendizado e aperfeiçoamento da ferramenta e para avaliação final após o ajuste dos parâmetros. É recomendado utilizar uma rede previamente treinada ao invés de treiná-la do zero, o que é chamado de chamado *transfer learning*, por apresentar um menor tempo de processamento e necessitar de menos imagens.

3 MÉTODO

Para atingir os objetivos propostos neste trabalho, propõe-se um método dividido nas seguintes etapas: 1) escolha das interseções; 2) desenvolvimento do método de coleta automatizada em vídeo; 3) coleta dos dados; e 4) análise exploratória das variáveis relacionadas à aceitação dos *headways*. Na Figura 5, é exibido um fluxograma mostrando as etapas e subetapas referentes ao método.

Figura 5 - Fluxograma do método



Fonte: elaborada pela autora

3.1 Escolha das interseções

Definiu-se como objeto de estudo as interseções semafORIZADAS da cidade de Fortaleza que possibilitam a análise do fenômeno das travessias dos pedestres no vermelho, ou seja, no verde para os veículos. As observações foram feitas em vídeos de câmeras de videomonitoramento posicionadas nas interseções em dias típicos e durante o dia, cedidos pelo Controle de Tráfego em Área de Fortaleza (CTAFOR) devido à disponibilidade dos dados e à possibilidade de coletar as variáveis a serem analisadas, então foi realizada uma escolha das filmagens mais adequadas para aplicação da ferramenta de acordo com alguns critérios.

O primeiro critério foi o número de faixas das vias, que precisavam ser duas ou três em um sentido, por serem vias típicas em Fortaleza. O segundo foi um fluxo veicular suficiente para possibilitar a formação de *headways* a serem aceitos pelos pedestres, e o último foi o posicionamento da câmera nas filmagens, pois era necessário observar os veículos passando pela faixa de retenção do semáforo e os pedestres aguardando a travessia nas duas calçadas e posteriormente atravessando na faixa. Não foram escolhidas travessias que conflitavam com veículos nas conversões, para focar na aceitação de *headways* na via principal.

3.2 Desenvolvimento do método de coleta automatizada em vídeo

A extração dos dados referentes às classes e às posições dos veículos e dos pedestres nos vídeos, usados para cálculo dos atrasos dos pedestres e dos *headways*, foi realizada com base no trabalho de Castro Jr. *et al.* (2021), que utilizaram técnicas de visão computacional para estudar a relação entre os atrasos dos pedestres e *headways* aceitos em interseções de Fortaleza e compararam os resultados com o *Highway Capacity Manual* (TRB, 2016). Os autores desenvolveram um código contendo o algoritmo de detecção e classificação de objetos YOLOv4 (Bochkovskiy *et al.*, 2020), utilizando o banco de dados COCO (Lin *et al.*, 2015), e o algoritmo de rastreio de objetos DeepSORT (Wojke *et al.*, 2017). Esse código foi adaptado a partir do disponibilizado gratuitamente no *Github* por *theAIGuysCode* (2020) e implantado no *Google Colab*, uma ferramenta *online* da *Google* que disponibiliza um ambiente de programação na linguagem *Python* em nuvem. O *Google Colab* possibilita o uso de GPUs (*Graphics Processing Units*, aceleradores de processamento gráfico) ou TPUs (*Tensor Processing Units*, aceleradores de tarefas de aprendizagem profunda) que possuem maior poder computacional comparado a CPUs (*Central Processing Units*, processadores de computadores comuns), recurso importante visto os custos de processamento consideravelmente mais elevados das Redes Neurais Convolucionais Profundas.

No trabalho de Castro Jr. *et al.* (2021) as classes detectadas foram carros e veículos leves em geral (*car*), motocicletas (*motorbike*), ônibus (*bus*), caminhões (*truck*), pedestres (*person*) e bicicletas (*bicycle*) e as coordenadas rastreadas da *bounding box* foram os pontos x e y do vértice superior esquerdo e os pontos x e y do vértice inferior direito, a uma taxa de captura de 10 *frames* por segundo (fps), ou seja, cada frame corresponde a 0,1 s.

A presente dissertação traz uma evolução do trabalho de Castro Jr. *et al*, pois a nova ferramenta coleta os *headways* por faixa, as velocidades veiculares, e o atraso de forma mais precisa, já que o atraso começa a ser contabilizado a partir do momento que o pedestre entra na

área de espera e finaliza quando ele sai dessa zona, e não quando ele aparece e desaparece no vídeo. Além disso, o instante de passagem do pedestre no centro de cada faixa é também coletado. Ademais, a versão do YOLO usada foi a v7 (Wang *et al.*, 2022), que é mais atualizada e apresenta melhorias relacionadas à velocidade do processamento e à precisão na classificação dos objetos em comparação com o YOLOv4, e usou-se o algoritmo de rastreio StrongSORT (Du *et al.*, 2023), por ser mais confiável e mais estável do que o DeepSORT. Outras diferenças são as coordenadas da *bounding box* rastreadas, que neste trabalho foram as coordenadas x e y do vértice superior esquerdo, a largura e a altura da *box*, e a taxa de captura, de 20 fps.

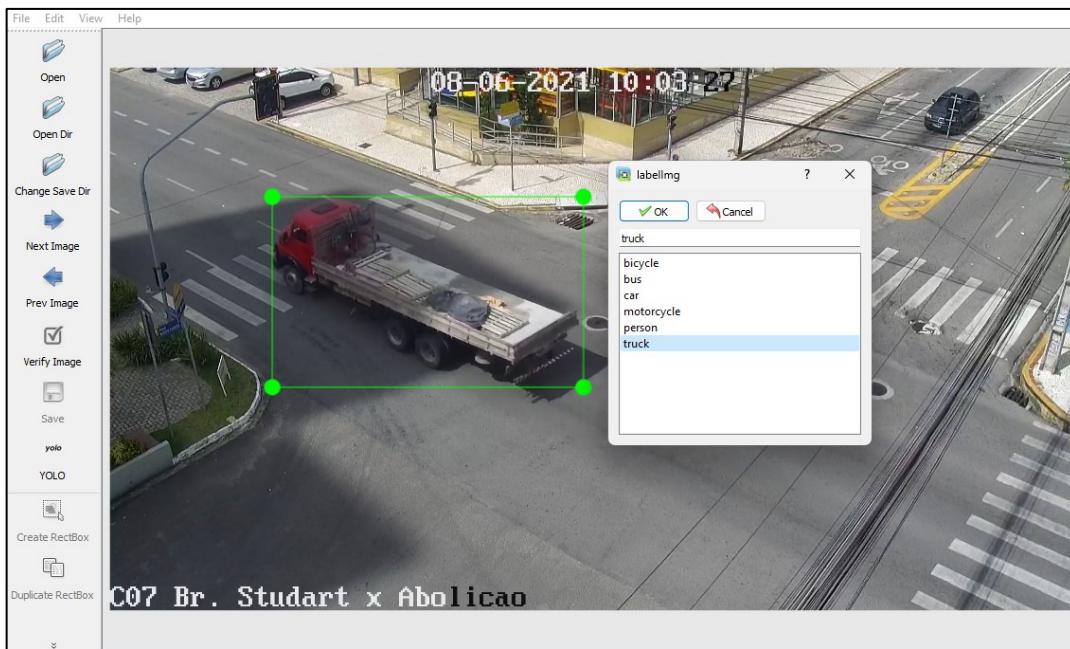
3.2.1 Treinamento e avaliação do algoritmo

Antes de aplicar a detecção em vídeo, foi realizado um treinamento do YOLOv7, pois ele foi desenvolvido e treinado com base em um banco de imagens padrão, e é importante customizar esse banco de dados com imagens que refletem as situações do estudo em questão, no intuito de se alcançar resultados melhores na detecção.

Primeiramente, foram selecionados os vídeos para os bancos de treino e validação e os exclusivamente para a etapa de teste. A escolha foi feita com base em características observadas nos vídeos, como luminosidade, sombras, chuva, pista molhada, perspectivas dos objetos, tamanho da cena e resolução do vídeo. Esses vídeos também foram escolhidos a partir dos disponibilizados pelo CTAFOR, com o intuito de deixar o modelo robusto para diferentes cenários. Como o treinamento é realizado em imagens geradas a partir dos vídeos, a cada 20 segundos de vídeo foi extraído um *frame* usando a ferramenta de linha de comando *FFmpeg*, gerando então 3 imagens por minuto.

Em seguida, as imagens foram rotuladas com o software *LabelImg*. As classes dos objetos rotuladas foram: *bicycle* (bicicleta), *bus* (ônibus), *car* (carro), *motorcycle* (motocicleta), *person* (pedestre) e *truck* (caminhão). Na Figura 6, é mostrada a rotulação e classificação dos objetos no *LabelImg*.

Figura 6 - Exemplo de rotulação de objeto no LabelImg



Fonte: elaborada pela autora

Foram priorizadas as imagens com presença de ônibus, caminhões, bicicletas e pedestres, evitando-se rotular aquelas com apenas carros e/ou motos, por normalmente serem as classes com maior quantidade de objetos nas interseções de Fortaleza, e momentos seguidos de semáforo fechado, pois objetos repetidos prejudicam o entendimento do modelo. Cada imagem rotulada gerou um .txt com as classes, no formato YOLO (0 = *bicycle*; 1 = *bus*; 2 = *car*; 3 = *motorcycle*; 4 = *pedestrian*; 5 = *truck*), e com as coordenadas de todos os objetos contidos na imagem, como exemplificado na Figura 7.

Figura 7 - Exemplo de .txt de saída do LabelImg

 A screenshot of a terminal window titled 'studartVSabolicao_08jun21_0900a1'. The window has a menu bar with 'Arquivo', 'Editar', and 'Exibir'. The main area contains a text file with the following content:


```
5 0.327865 0.412037 0.321354 0.348148
2 0.614062 0.440741 0.139583 0.157407
4 0.585417 0.199537 0.018750 0.086111
2 0.874740 0.080093 0.063021 0.095370
```

Fonte: elaborada pela autora

Após esse processo, as imagens dos vídeos reservados para teste foram alocadas no grupo de teste e as imagens dos vídeos reservados para treino e validação foram separadas nesses dois grupos, de forma aleatória estratificada. Os dados de treino são utilizados pelo

detector para melhorá-lo de acordo com o interesse do estudo, ou seja, para ensiná-lo como identificar e classificar adequadamente os objetos presentes nas imagens. É recomendado ter um banco de imagens de treino diversificado, com ângulos e iluminações diferentes para que o algoritmo não fique limitado a apenas uma circunstância, o que reforça a necessidade inicial de ter escolhido vídeos nas mais diversas condições.

O *framework* utilizado para o treinamento (<https://github.com/nelioasousa>) foi adaptado do código para *Google Colab* disponibilizado no *GitHub* de *WongKinYiu* (2022), que é a implementação do artigo de *Wang et al.* (2022). Os arquivos de entrada usados no *framework* foram as imagens rotuladas em .jpg e seus respectivos arquivos de rótulos, no formato .txt. Foi feito o *download* do arquivo pré-treinado do YOLOv7 a ser utilizado, cuja finalidade é ajudar a reduzir o tempo do treinamento do detector e a melhorar sua precisão. Há 7 versões de arquivos pré-treinados para o YOLOv7, que mostram diferentes qualidades, resultados e requisitos mínimos de sistema para possibilitar o uso do modelo, conforme Figura 8. A versão escolhida foi a YOLOv7-w6, por ser a primeira a fornecer imagens de teste com dimensões maiores (1280 *pixels*), o que aumenta a qualidade da detecção, e por ter um tempo de processamento menor do que as versões superiores sem grandes perdas nas métricas de teste, o que exige memória e GPU menores.

Finalmente, configurou-se os parâmetros do treinamento para 1250 iterações, e, após esse processo, foi iniciado o treinamento com o banco de dados de treino e validação.

Figura 8 - Arquivos pré-treinados para o YOLOv7 e arquivo escolhido para o treinamento

Model	Test Size	AP^{test}	AP_{50}^{test}	AP_{75}^{test}	batch 1 fps	batch 32 average time
YOLOv7	640	51.4%	69.7%	55.9%	161 <i>fps</i>	2.8 <i>ms</i>
YOLOv7-X	640	53.1%	71.2%	57.8%	114 <i>fps</i>	4.3 <i>ms</i>
YOLOv7-W6	1280	54.9%	72.6%	60.1%	84 <i>fps</i>	7.6 <i>ms</i>
YOLOv7-E6	1280	56.0%	73.5%	61.2%	56 <i>fps</i>	12.3 <i>ms</i>
YOLOv7-D6	1280	56.6%	74.0%	61.8%	44 <i>fps</i>	15.0 <i>ms</i>
YOLOv7-E6E	1280	56.8%	74.4%	62.1%	36 <i>fps</i>	18.7 <i>ms</i>

Fonte: elaborada pela autora

O treinamento gerou pesos, salvos a cada 125 iterações no formato *.weights*, que são os arquivos que permitem o algoritmo de detecção e rastreio realizar sua tarefa, então um modelo bem treinado gera resultados mais precisos.

As medidas de desempenho para definir qual dos pesos era o mais adequado foram dois tipos de mAP de validação, o primeiro para um IOU mínimo de 0,5 (mAP@0,5) e o segundo para valores de IOU entre 0,5 e 0,95 (mAP@0,5:0,95), que deveriam ser os maiores possíveis.

Finalizado o treinamento e escolhida a melhor combinação de pesos, foi feita a avaliação do algoritmo com o banco de imagens de teste, por meio da AP por classe e a mAP para um IOU mínimo de 0,5, e da Matriz de Confusão, que serve para comparar a classificação dos objetos feita manualmente (*groundtruth*) e a classificação prevista pelo detector.

3.3 Coleta dos dados

A etapa seguinte à avaliação das métricas foi a aplicação da ferramenta de detecção em vídeo. O arquivo de saída foi um arquivo .txt, parcialmente apresentado na Figura 9, onde foi salva a trajetória de todos os objetos rastreados ao longo de cada *frame* do vídeo e apresentou, nesta ordem, o *frame* no qual o objeto foi detectado (1), seu ID (2), sua classe (3), suas coordenadas (x;y) do ponto esquerdo superior da *bounding box* desenhada pelo detector, em *pixels* (4 e 5), a largura (6) e a altura (7) da *bounding box*, também em *pixels*, e o valor de confiança (8), que varia entre 0 e 1. Esses parâmetros são importantes para obtenção das medidas de desempenhos relativas aos pedestres e aos veículos, explicadas em mais detalhes posteriormente.

Figura 9 - Trecho do arquivo de saída do YOLO

1	2	3	4	5	6	7	8
7	1	2	550	0	158	141	0.98
7	2	2	726	20	129	140	0.98
7	3	0	706	360	84	124	0.96
7	4	2	784	0	112	52	0.96
7	5	3	379	31	65	111	0.96
7	6	1	410	0	174	53	0.96

Fonte: elaborada pela autora

Os dados obtidos da detecção e do rastreio pelo algoritmo YOLOv7/StrongSORT foram trabalhados em *scripts* no *Google Colab*. Desses dados, extraiu-se o volume total, por faixa e por tipo, dos veículos que passaram pela interseção, a velocidade dos veículos, o total

de pedestres que realizaram travessia por área de espera (ou origem), o atraso desses pedestres e os *headways* veiculares totais e aceitos por eles.

Delimitou-se no código as áreas e seções de interesse de pedestres e veículos para registro de instantes temporais essenciais para cálculo dos parâmetros de acordo com as coordenadas dos seus vértices em *pixels*, todas esboçadas na Figura 10, na Figura 11 e na Figura 12. Assim, foram determinadas a área de conflito entre pedestres e veículos (área vermelha correspondente à faixa de pedestres – Figura 10), a seção de referência adotada para coleta dos instantes de passagem dos veículos (seção 1 – Figura 10), as seções de referência da coleta das velocidades veiculares (seção 1 e seção 2 – Figura 10), a ordem numérica considerada para as faixas veiculares, as regiões de referência em cada faixa para detecção dos instantes de passagem do pedestre no processo de sua travessia (retângulos amarelos na região central de cada faixa – Figura 12) e as áreas de espera para os pedestres nas calçadas dos dois lados da via (origem A e origem B – Figura 12).

Figura 10 - Delimitação da área de conflito e das seções de coleta dos instantes de passagem para *headways* e velocidades veiculares



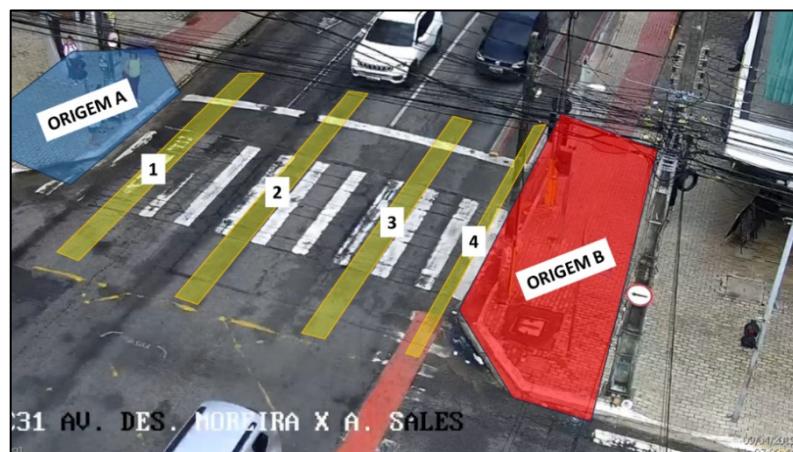
Fonte: elaborada pela autora

Figura 11 - Numeração de referência das faixas veiculares



Fonte: elaborada pela autora

Figura 12 - Delimitação das áreas de origens do pedestre e das seções de coleta dos instantes de passagem dos pedestres em cada faixa



Fonte: elaborada pela autora

Como resultado da aplicação do código, para os veículos, foram adquiridos os IDs, as classes, as faixas de tráfego correspondentes, os instantes de passagem na seção 1, em segundos, os *headways* por faixa (diferença de tempo entre o instante de passagem dos para-choques de dois veículos consecutivos na seção 1), em segundos, e as velocidades (razão entre a distância entre a seção 1 e a seção 2 dividida pela diferença do instante de passagem em cada uma delas, multiplicada por 3,6), em km/h, de todos os veículos que passaram pela interseção. O total de veículos na interseção, tanto de maneira geral quanto por classe e por faixa, foi contabilizado pela contagem dos veículos registrados na área de conflito.

Houve problemas na obtenção das velocidades de alguns veículos, por conta de dificuldades na coleta adequada das trajetórias, tornando suas velocidades inválidas para análise (marcadas como “-1”). Contornou-se esses problemas para as bicicletas, com base na

velocidade média das que tiveram suas velocidades corretamente extraídas e considerando essa velocidade média como padrão para as bicicletas que tiveram sua velocidade registrada como inválida, pois foi adotada a premissa de que as bicicletas apresentam baixa variabilidade na sua velocidade. Para as outras classes, entretanto, houve descarte dos veículos cuja velocidade não foi obtida, reduzindo o tamanho da amostra total.

No caso dos pedestres, foram registrados os IDs, as áreas de espera correspondentes (origem A ou B), os instantes de entrada na área de espera (início da espera) e saída da área de espera (fim da espera e início da travessia), em segundos, os atrasos (diferença entre os instantes de fim e início da espera), em segundos, e os instantes de entrada na região referente a cada faixa de tráfego, em segundos. O total de pedestres foi contabilizado pela contagem dos pedestres registrados em cada origem.

Alguns pedestres não tiveram rastreados seus instantes de passagem por todas as faixas veiculares, então foi necessário realizar uma interpolação para estimativa desses instantes. Primeiramente, calculou-se todas as diferenças dos tempos de passagem entre as faixas para os pedestres corretamente rastreados e em seguida as médias dessas diferenças. Calculadas as médias, o valor estimado para a faixa não contabilizada foi adotado como a soma entre o instante de passagem da faixa anterior e a média do tempo de passagem entre as faixas, para os pedestres que iniciaram a travessia a partir da origem A, e a subtração entre o instante de passagem da faixa anterior e a média do tempo de passagem entre as faixas, para os pedestres que iniciaram a travessia a partir da origem B.

Foi realizada uma análise estatística, por faixa e tipo de veículo, dos *headways*, das velocidades veiculares e dos atrasos dos pedestres por meio de estimativas de médias, desvios-padrão e histogramas. Os Intervalos de Confiança foram os de t-Student com 95% de confiança.

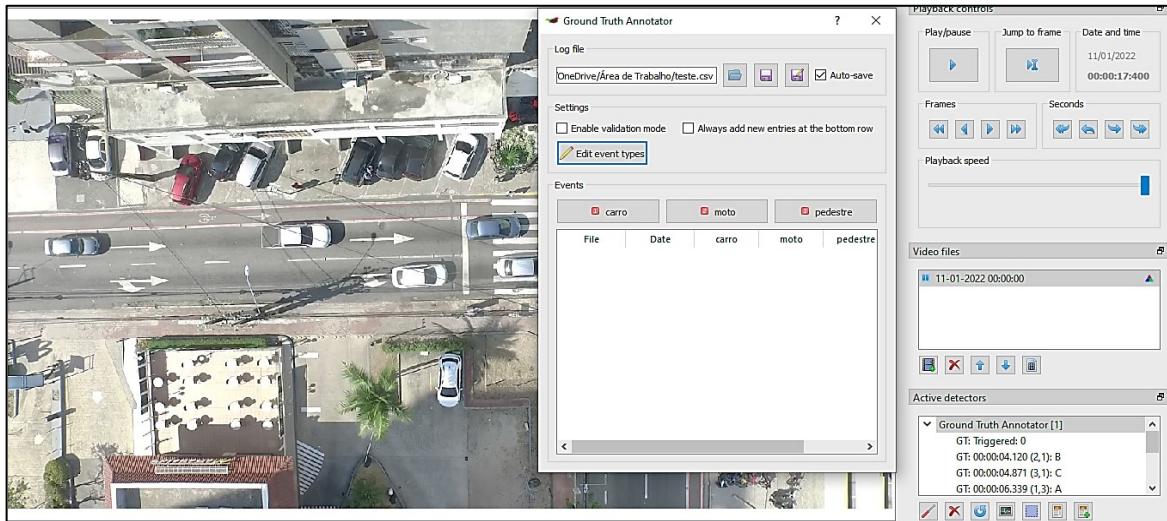
3.3.1 Comparação com a ferramenta de coleta manual

Para verificar a detecção do YOLO (como será chamada a ferramenta de Visão Computacional neste trabalho), realizou-se uma coleta manual nos 10 primeiros minutos de vídeo para comparação e validação dos resultados do volume de veículos e de pedestres, dos *headways* veiculares, dos *headways* aceitos, das velocidades veiculares e dos atrasos dos pedestres obtidos pelo método automatizado no mesmo intervalo de tempo.

Usou-se o *software Road User Behaviour Analysis* (RUBA), desenvolvido por Tonning *et al.* (2017), que dispõe de uma ferramenta chamada *Ground Truth Annotator*, cuja interface é apresentada na Figura 13, onde se utiliza as teclas do teclado para marcação manual

de tempos, sendo possível configurar a função de até seis teclas diferentes. O RUBA permite pausar, avançar, retroceder e ajustar a velocidade do vídeo (*Playback Speed*) para ajudar na coleta dos dados.

Figura 13 - Interface do RUBA com o *Ground Truth Annotator* (vídeo ilustrativo)



Fonte: elaborada pela autora

O arquivo de saída é um .csv que registra o nome do arquivo de vídeo, a data da coleta e os instantes do vídeo que foi apertada a tecla correspondente a cada categoria. No exemplo da Figura 14, configurou-se as teclas para coletar os tempos de carro, moto e pedestre.

Figura 14 - Exemplo de arquivo de saída .csv do RUBA

File	Date	carro	moto	pedestre
DJI_0525.MOV	2022 01 11	00:00:02.936	00:00:04.120	00:00:04.871
DJI_0525.MOV	2022 01 11	00:00:03.586	00:00:07.440	
DJI_0525.MOV	2022 01 11	00:00:06.339		
DJI_0525.MOV	2022 01 11	00:00:06.923		

Fonte: elaborada pela autora

No presente trabalho, os veículos foram coletados a uma média de 12 fps por tipo (carro, motocicleta, bicicleta, ônibus/caminhão) e faixa (direita, meio, esquerda e ciclofaixa), e seus tempos foram registrados no momento que seus para-choques passaram pela seção 1 pela seção 2, para cálculo de seus *headways* e velocidades. Importante salientar que, para fins de comparação entre as duas ferramentas, realizou-se o rastreio com o YOLO na amostra de 10 minutos de vídeo adotando as mesmas seções consideradas no RUBA ao invés das referências usadas na coleta de dados, para aumentar a distância percorrida e o tempo gasto pelos veículos, com o intuito de diminuir erros na coleta.

Para os pedestres, a 12 fps, coletou-se os instantes em que eles entravam nas origens e os instantes de sua saída dessas mesmas origens para início de sua travessia. Todas as referências usadas para coleta dos parâmetros com o RUBA estão esboçadas na Figura 15.

Figura 15 - Referências adotadas na coleta com o RUBA



Fonte: elaborada pela autora

Depois da coleta com as duas ferramentas, foi feito um pareamento dos resultados por meio de comparação entre os instantes de passagem na seção 1 e na seção 2 para os veículos e entre os instantes de chegada nas origens A e B para os pedestres. Também se considerou as classes “bus” (ônibus) e “truck” (caminhão) como apenas uma no YOLO para equiparar as análises com o RUBA.

Na amostra de veículos pareados, comparou-se as classes apontadas manualmente na visualização dos vídeos no RUBA com as previstas automaticamente pelo YOLO, para verificação dos acertos e erros de classificação. Além disso, calculou-se as diferenças entre os instantes de chegada na seção 1 e na seção 2, as velocidades veiculares e os *headways* para os veículos pareados, e as diferenças entre os atrasos, os instantes de chegada e saída das origens A e B, todos na ordem de subtração YOLO – RUBA.

O passo seguinte foi, por tipo de veículo, o cálculo das médias, dos desvios-padrão e análise dos Intervalos de Confiança das médias das diferenças dos instantes de passagem na seção 1, instantes de passagem na seção 2, velocidades e *headways*. Para os pedestres, foram analisados os Intervalos de confiança das médias das diferenças dos instantes de início e fim de espera e atrasos. Para veículos e pedestres, foram elaborados gráficos de dispersão, para verificação das diferenças em relação às velocidades e atrasos coletados pelo RUBA, e

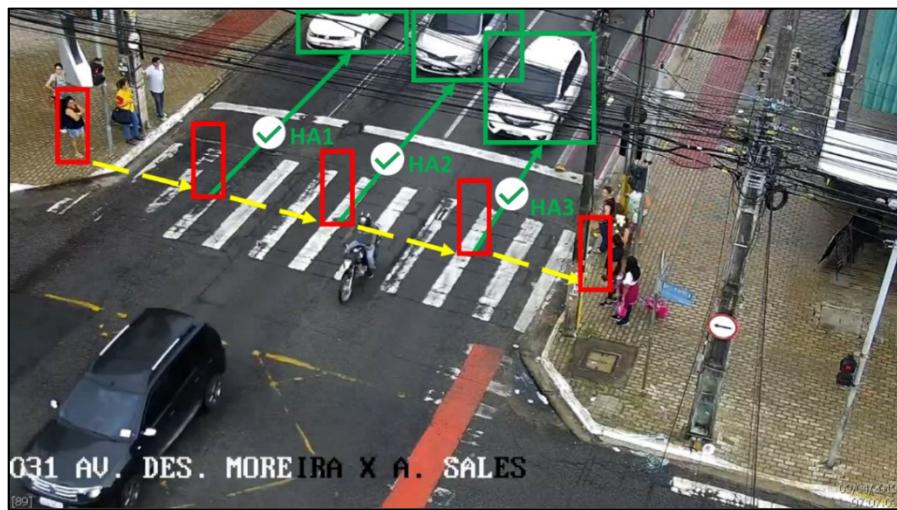
histogramas de frequência. Usou-se os Intervalos de Confiança t-Student para amostras pareadas com 95% de confiança.

Por fim, foi realizada uma avaliação de todos os motivos que causaram possíveis erros de detecção e rastreio por meio da visualização dos vídeos, para pontuar quais os problemas mais recorrentes e quais as classes foram mais suscetíveis a esses erros, no intuito de direcionar sua resolução. Esses problemas foram quantificados, categorizados e organizados em uma tabela, e imagens de alguns casos foram retiradas dos vídeos para melhor entendimento.

3.4 Análise exploratória das variáveis relacionadas à aceitação de *headways*

A partir da aplicação da ferramenta automatizada e aquisição dos *headways* de todos os veículos contabilizados na interseção, foi possível descobrir os *headways* aceitos pelos pedestres. Os *headways* foram considerados aceitos no instante em que os pedestres entraram na região delimitada em cada faixa de tráfego (como exemplificado na Figura 12), independentemente do sentido da travessia, totalizando um *headway* aceito por faixa, como ilustrado no exemplo da Figura 16, na qual a pedestre é representada por um retângulo vermelho ao longo da travessia em cada faixa oposta.

Figura 16 - Exemplo ilustrativo da aceitação de *headways* em cada faixa



Fonte: elaborada pela autora

Os *headways* aceitos foram computados como o tempo entre a passagem do pedestre no centro da faixa de tráfego e a passagem do veículo por este ponto, e foram relacionados com as informações pertinentes a cada pedestre (área de origem, instantes de início e fim de espera, atraso e instantes de passagem nas faixas) e a cada veículo (classe, faixa e

velocidade). Foram considerados para a análise apenas os *headways* aceitos de no máximo 10 segundos, na premissa de que apenas valores menores que esse representam algum tipo de avaliação na aceitação do *headway* pelo pedestre em seu processo de decisão de travessia.

Dentre os *headways* aceitos, foram extraídos os *headways* mínimos aceitos para cada pedestre, juntamente com a classe, a faixa e a velocidade do veículo associado a esse *headway*, e a área de origem do pedestre, os instantes de início de espera, de fim de espera e atraso, totalizando assim uma observação por pedestre. Decidiu-se realizar essa análise porque o *headway* mínimo aceito é a referência do veículo que está mais próximo ao pedestre, determinante para a aceitação dos outros *headways* nas outras faixas.

Após verificação dos *headways* aceitos e dos *headways* mínimos aceitos em todos os momentos de travessia, a última etapa foi a análise apenas com aqueles que atravessaram nos períodos de foco semafórico vermelho para os pedestres, para de fato analisar a influência do atraso, dos tipos de veículo e das velocidades veiculares na aceitação dos *headways* nesse tipo de situação. Para isso, foram cronometrados alguns intervalos de tempo nos quais o semáforo para pedestres estava vermelho, com o cuidado de selecionar intervalos ao longo de todo o vídeo, e filtrou-se os pedestres que atravessaram a via nesses períodos. Da mesma forma, foram obtidos os *headways* aceitos por pedestre, um por faixa veicular, e o menor deles definido como o *headway* mínimo aceito.

Em suma, as análises serão feitas para os seguintes tipos de *headway*:

- *Headway* aceito;
- *Headway* mínimo aceito;
- *Headway* aceito no vermelho dos pedestres; e
- *Headway* mínimo aceito no vermelho dos pedestres.

Em seguida, para cada tipo de *headway*, foram realizadas análises exploratórias das variáveis. Essas análises contemplaram o cálculo de Intervalos de Confiança bicaudal t-Student com 95% de confiança, pois as médias e os desvios-padrão populacionais são desconhecidos (DEVORE, 2006) e a elaboração de histogramas e *boxplots* para análises do padrão dos *headways* aceitos, *headways* mínimos aceitos e velocidades veiculares, e dos atrasos dos pedestres. Para explorar a relação entre o atraso dos pedestres e a aceitação dos *headways*, foram desenvolvidos gráficos de dispersão que relacionaram os *headways* aceitos pelo pedestre com seus atrasos e as velocidades dos veículos referentes a esses *headways* aceitos.

4 RESULTADOS

4.1 Escolha das interseções

Após análise dos vídeos disponibilizados pelo CTAFOR, foi escolhido um para a aplicação da ferramenta, que é o da interseção entre as avenidas Antônio Sales e Desembargador Moreira, no qual é mostrada a aproximação da Av. Antônio Sales. Esse vídeo foi escolhido pois a aproximação apresenta o número de faixas desejado e um fluxo veicular razoável, além de o posicionamento da câmera possibilitar a visualização da faixa de retenção e dos pedestres aguardando travessia. Os detalhes da filmagem são mostrados na Tabela 1 e uma imagem da aproximação é apresentada na Figura 17.

Tabela 1 - Detalhes do vídeo escolhido para análise

Interseção	Aproximação analisada	Data	Horário	Duração
Av. Ant. Sales x Av. Des. Moreira	Av. Ant. Sales (O-L)	09/04/2019	07h às 12h	5h

N = norte; S = sul; L = leste; O = oeste.

Fonte: elaborada pela autora

Figura 17 - Imagem da aproximação analisada (Av. Antônio Sales)



Fonte: CTAFOR

A aproximação da Av. Antônio Sales apresenta duas faixas de tráfego misto e uma faixa exclusiva para ônibus com largura aproximada de 3 m cada, uma ciclofaixa de sentido único, uma área para motos (*motobox*), uma travessia de cerca de 10,5 m e um semáforo para pedestres sem boteira. Nota-se embarque e desembarque de veículos em estabelecimentos próximos à interseção, além de fluxo intenso de veículos e pedestres, devido à predominância do uso comercial do solo. A velocidade regulamentada na época da filmagem era de 60 km/h, mas no momento de elaboração desta dissertação a velocidade regulamentada é de 50 km/h.

4.2 Desenvolvimento do método de coleta automatizada em vídeo

4.2.1 Treinamento e avaliação do algoritmo

Para o treinamento, foram selecionados vídeos em oito interseções diferentes, seis deles para treino e validação, e dois para teste e avaliação das métricas pós-treinamento, incluindo o da Av. Antônio Sales. Os vídeos selecionados, o banco de dados de destino e a duração dos vídeos são exibidos na Tabela 2.

Tabela 2 - Vídeos selecionados para treinamento da ferramenta

Número	Interseção	Banco de dados	Duração dos vídeos
1	Av. Ant. Sales x Av. Des. Moreira	Treino/Validação	5h
2	Av. Tristão Gonçalves x R. Gen. Clarindo de Queiroz	Treino/Validação	1h
3	Av. Aguanambi x R. Soriano Albuquerque	Treino/Validação	3h
4	Av. Barão de Studart x Av. Ant. Sales	Treino/Validação	3h
5	Av. Luciano Carneiro x Av. Borges de Melo	Treino/Validação	3h
6	Av. Barão de Studart x Av. Abolição	Treino/Validação	4h
7	Av. Pontes Vieira x Av. Visc. Do Rio Branco	Teste	2h
8	Av. Pontes Vieira x Av. Barão de Studart	Teste	2h

Fonte: elaborada pela autora

A uma taxa de 3 imagens por minuto, foram extraídas 900 imagens da interseção 1, 540 imagens da interseção 2, 720 imagens das interseções 3 a 5, 360

imagens das interseções 7 e 8. Na Tabela 3 são detalhados o total de imagens rotuladas e o número de imagens alocadas para treino, validação e teste, por interseção. Foram rotuladas 1516 imagens no total, das quais 191 (12,6%) correspondem aos vídeos reservados para teste (interseções 7 e 8), e das 1325 restantes, 1140 (75,2%) foram alocadas para o grupo de treino e 185 (12,2%) para o grupo de validação, valores próximos das proporções sugeridas na literatura, de 70% para treino, 15% para validação e 15% para teste (GENC; TUNC, 2019).

Percebe-se um balanceamento das interseções no total de imagens rotuladas e no número de imagens de treino, validação e teste, um aspecto importante para que o modelo não se adeque apenas a uma situação e fique abaixo do ideal em outros cenários. As exceções são as interseções 4 e 6, com mais de 300 imagens rotuladas e mais de 260 imagens de treino, pois há presença de ônibus, caminhões, bicicletas e pedestres em uma variedade maior de imagens.

Tabela 3 - Quantidade de rotulações e distribuição de imagens de treino, validação e teste para cada interseção

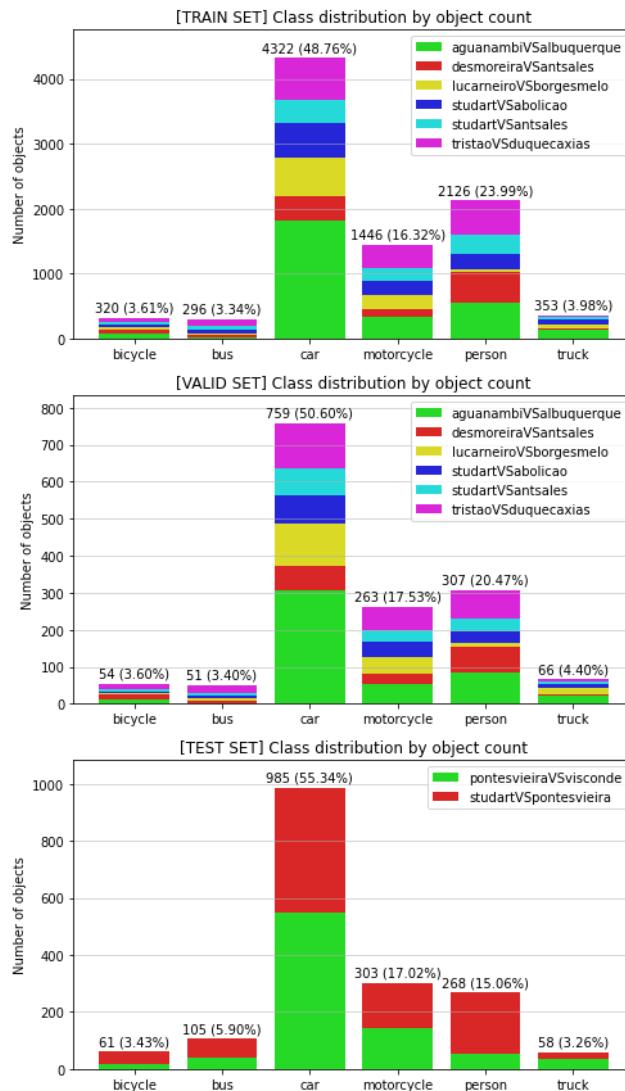
Número	Interseção	Total de imagens rotuladas	Nº de imagens de treino	Nº de imagens de validação	Nº de imagens de teste
1	Av. Ant. Sales x Av. Des. Moreira	188	159	29	-
2	Av. Tristão Gonçalves x R. Gen. Clarindo de Queiroz	161	138	23	-
3	Av. Aguanambi x R. Soriano Albuquerque	177	152	25	-
4	Av. Barão de Studart x Av. Ant. Sales	301	261	40	-
5	Av. Luciano Carneiro x Av. Borges de Melo	182	156	26	-
6	Av. Barão de Studart x Av. Abolição	316	274	42	-
7	Av. Pontes Vieira x Av. Visc. do Rio Branco	85	-	-	85
8	Av. Pontes Vieira x Av. Barão de Studart	106	-	-	106
Total		1516	1140	185	191

Fonte: elaborada pela autora

Obteve-se também a distribuição das classes nos bancos de treino, validação e teste nas interseções, por quantidade de objetos. É possível perceber na Figura 18 que a classe “car” é a mais expressiva, correspondendo a cerca de metade de todos os objetos rotulados, com a interseção da Av. Aguanambi com a R. Soriano Albuquerque mostrando maior quantidade desse objeto em comparação às outras, seguido por “person”, com uma média de 20% e

“motorcycle”, com cerca de 17%. Por outro lado, as classes “bicycle”, “bus” e “truck” foram as menos rotuladas, representando menos de 5% do total. No entanto, seria necessário um banco de imagens muito maior para que sua amostra aumentasse, pois observa-se pouca quantidade desses objetos em comparação com carros, pedestres e motocicletas.

Figura 18 - Distribuição das classes por contagem de objetos nos bancos de treino, validação e teste, por interseção



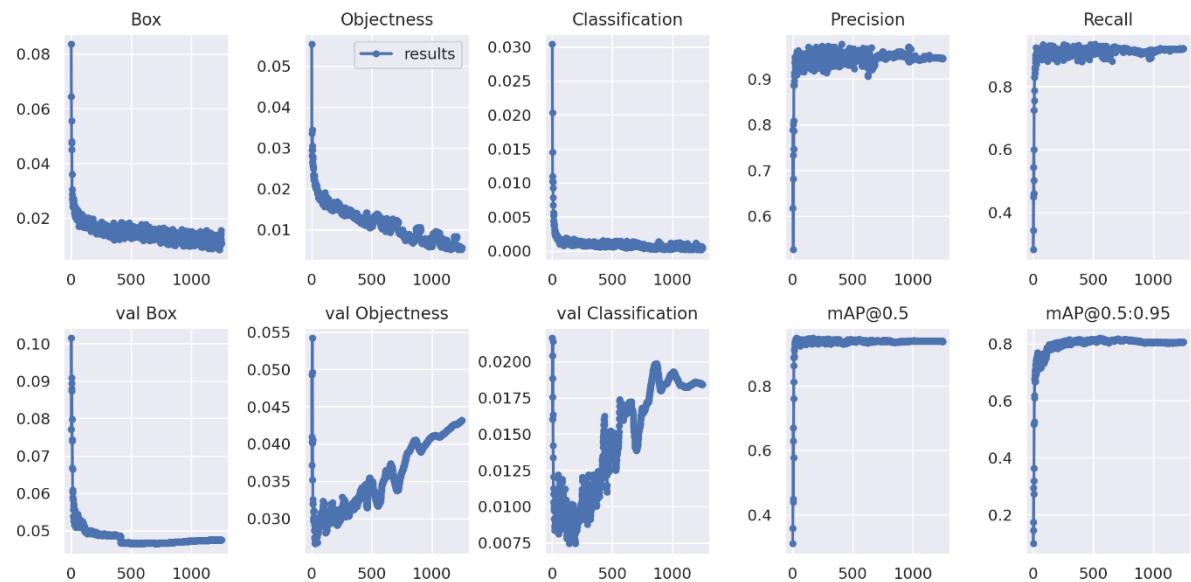
Fonte: elaborada pela autora

Após o final do treinamento, realizado com 1250 iterações, foram geradas as curvas de aprendizagem das métricas de treino e validação, mostradas na Figura 19. As três curvas superiores à esquerda correspondem à LOSS de treino (*Box*, *Objectness* e *Classification*), que mostram valores entre 0 e 0,02 e um comportamento com tendência à estabilização. A LOSS consiste em uma função de perda com uma série de variáveis e equações (*LOSS function*) que serve para verificar o nível de aprendizado do algoritmo e os erros cometidos, alterando-se os

parâmetros do modelo para que esses erros sejam os mínimos possíveis. É interessante que a LOSS retorne resultados abaixo de 0,05 para bancos de dados mais simples e 3 para bancos de dados complexos (Bochkovskiy *et al.*, 2020).

Nota-se também que o mAP de validação para um IOU de 0,5 (mAP@0,5) manteve-se próximo a 0,9 durante o processo de treinamento e o mAP de validação para IOU entre 0,5 e 0,95 (mAP@0,5:0,95) manteve-se próximo a 0,8, resultados satisfatórios considerando o tamanho da amostra e o número de épocas. Por fim, as curvas de Precisão e *Recall* mostraram comportamento de oscilação até a 500^a iteração, chegando a aproximadamente 0,95 e 0,88, respectivamente, valores considerados altos.

Figura 19 - Curvas de aprendizagem das métricas de treino e validação



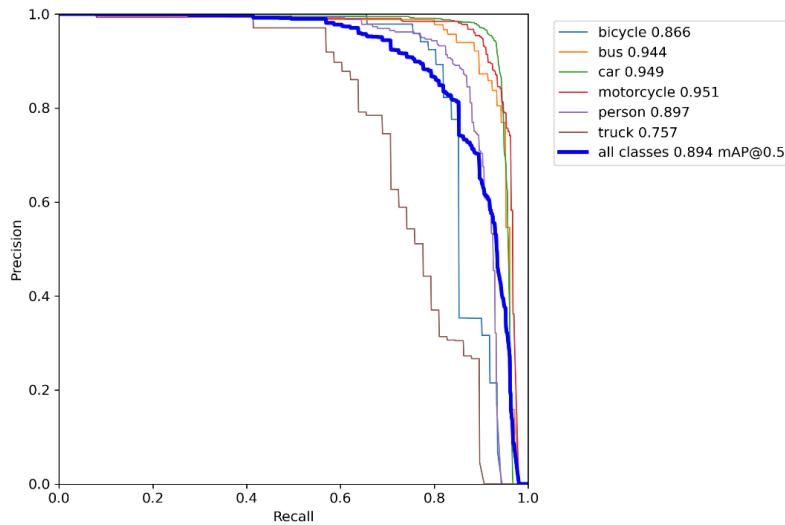
Fonte: elaborada pela autora

Por fim, analisando os resultados do treinamento por época, o peso que retornou os maiores valores de mAP de validação, sendo o escolhido para implementação no modelo, foi o da época de número 555, com um mAP@0,5 de 94,4% e um mAP@0,5:0,95 de 81,6%, uma precisão de 95,2% e um *recall* de 92,2%.

Na Figura 20 é ilustrada a curva de precisão x *recall* das 191 imagens de teste, para cada classe e total. É possível verificar que o mAP obtido foi de quase 90%, com AP em torno de 95% para as classes “bus”, “car” e “motorcycle”, que mostram áreas sob as curvas próximas do ideal, com precisão e *recall* próximos a 1. As classes “bicycle” e “person” também mostraram AP relativamente elevada, de 86,6% e 89,7%, respectivamente, e a classe “truck” apresentou o menor valor dentre as classes, de 75,7%, apesar de ser um valor razoável, e a curva

mais destoante em comparação com a curva média. Esse resultado pode ter acontecido pelo tamanho da amostra de caminhões nas imagens de teste e por erros do modelo na detecção dessa classe. Todavia, os resultados em geral indicam que, com base nas imagens de teste, o treinamento realizado foi satisfatório.

Figura 20 - Curvas precisão x *recall* das imagens de teste



Fonte: elaborada pela autora

A Tabela 4 detalha o número de *bounding boxes* previstas pelo modelo automatizado por classe nas imagens de teste, da precisão, do *recall*, da AP por classe e do mAP, para um IOU mínimo de 0,5. Os resultados mostram que a baixa AP para caminhões, vista na Figura 20, pode ser reflexo da sua baixa precisão (0,511), influenciada possivelmente por uma quantidade elevada de falsos positivos, ou seja, detecções incorretas do modelo.

A classe “Bicicleta” mostrou o menor *recall* (0,754), mas sua AP não foi prejudicada, visto que a precisão foi quase perfeita, e as classes “Ônibus” e “Pessoa” mostraram valores satisfatórios de precisão e *recall*, refletindo em APs altas. Já as classes “Carro” e “Motocicleta” apresentam os maiores valores de precisão e *recall*, o que confirma suas APs elevadas e suas curvas próximas do ideal discutidas na Figura 20.

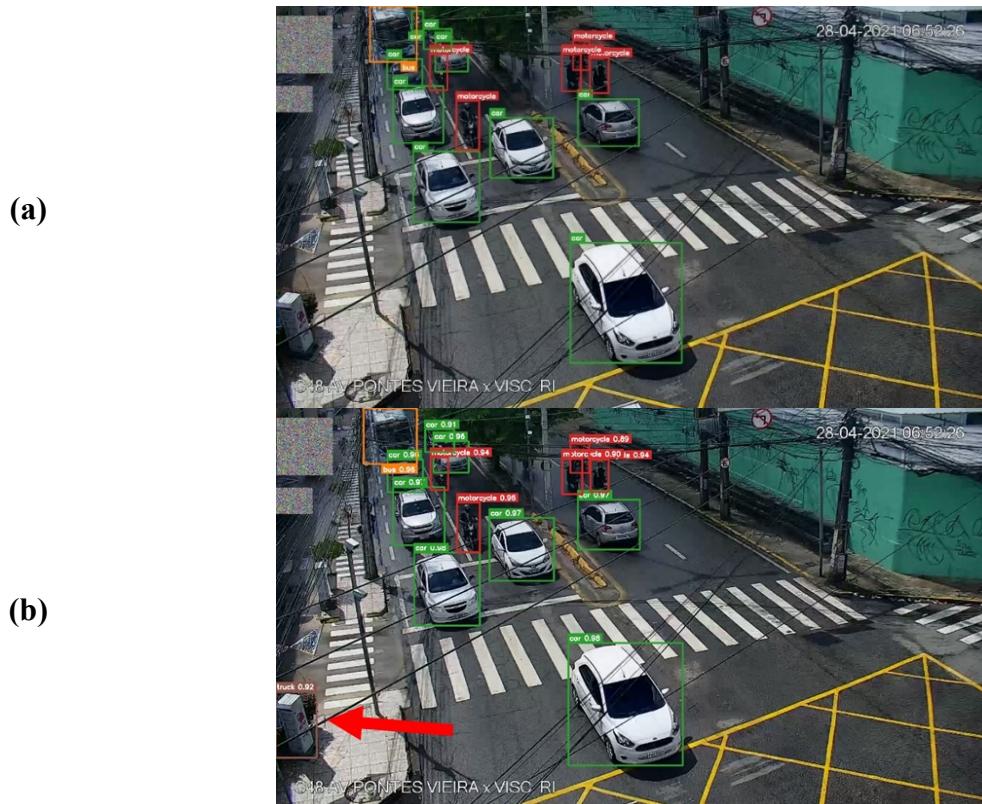
Contudo, o desbalanceamento entre as classes é um fator a ser considerado, visto que o número de carros nas imagens de teste representa mais de 50% do total, enquanto caminhões e bicicletas somados representam menos de 10%, fator que pode ter pesado nos resultados das métricas. Pode-se aumentar a amostra dessas classes com novas imagens e retreinar o modelo, o que aumentaria a sua precisão, principalmente para os caminhões.

Tabela 4 - Resultados das métricas de teste para um IOU mínimo de 0,5

Classe	Bounding boxes previstas	Precisão	Recall	AP (%)
Carro	985	0,983	0,872	94,9
Motocicleta	303	0,98	0,861	95,1
Pessoa	268	0,946	0,792	89,7
Ônibus	105	0,975	0,819	94,4
Caminhão	58	0,511	0,776	75,7
Bicicleta	61	0,964	0,754	86,6
Total	1780	0,893	0,812	-
mAP (%)	-	-	-	89,6

Fonte: elaborada pela autora

Um exemplo de detecção incorreta de caminhões (falso positivo) é mostrado na Figura 21, na qual a imagem de cima (a) é a classificação realizada manualmente (*groundtruth*) e a de baixo (b) é a identificação feita pelo detector. Percebe-se que um objeto do canto inferior esquerdo foi classificado pelo detector como caminhão (*truck*), diminuindo sua precisão, situação que pode ter se repetido em outros objetos ou veículos classificados erroneamente como caminhões.

Figura 21 - Exemplo de comparação entre o *groundtruth* (a) e a identificação do detector (b) em uma imagem de teste

Fonte: elaborada pela autora

Segundo a Matriz de Confusão da Figura 22 gerada a partir das imagens de teste, observa-se que carros, ônibus, motocicletas e pessoas tiveram as maiores proporções de acertos entre a classificação manual e a previsão do modelo, de 91%, 95%, 90% e 89%, seguidos pelas bicicletas, com 85%. Os caminhões mostram a menor proporção de acertos, de 70%, além de 17% deles terem sido detectados erroneamente como carros, e 10% não detectados. Importante destacar, apesar de serem baixos valores, 7% das bicicletas classificadas como pessoas e 2% classificadas como motocicletas, além de 3% das motocicletas classificadas como bicicletas, o que é esperado, devido a semelhanças nos tamanhos e formas dessas três classes à distância.

Figura 22 - Matriz de Confusão dos objetos nas imagens de teste

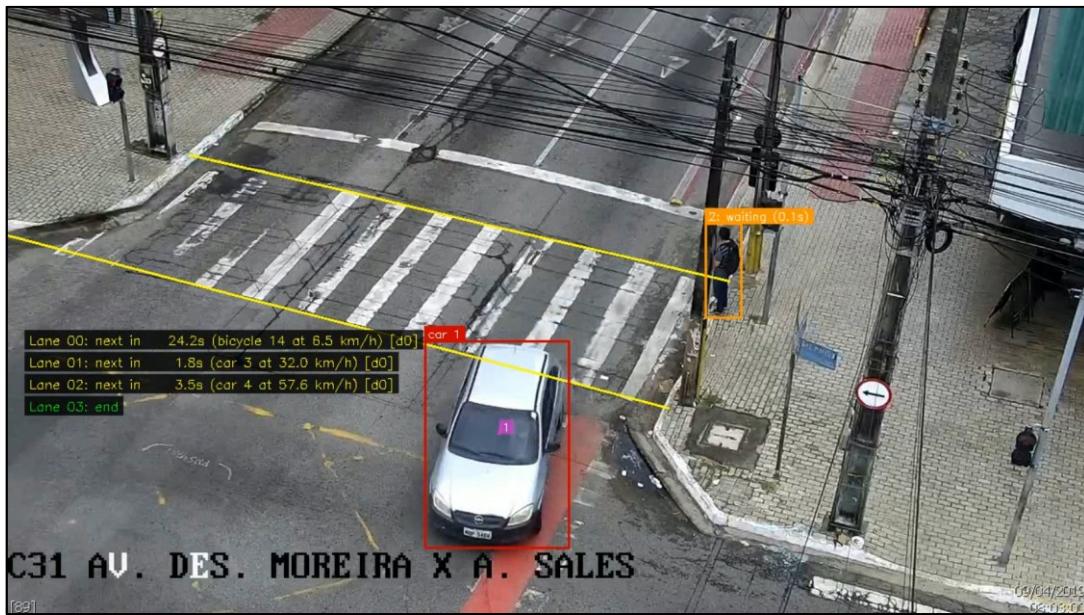


Fonte: elaborada pela autora

4.3 Coleta de dados

Na Figura 23, é mostrado um *frame* do vídeo resultante (trecho disponível em: <https://drive.google.com/file/d/1yzgDILMRzhMH88HqaciX4O3rtObA3uOd/view>) após rastreio e coleta dos parâmetros, no qual cada veículo tem sua velocidade calculada e recebe um ID e uma cor de acordo com sua classe, e cada pedestre recebe uma *bounding box* com uma ID e um *status*, que pode ser “*waiting*” quando entra na área de espera, “*crossing*” quando sai da área de espera e inicia a travessia, “*crossed*” quando finaliza a travessia, ou “*invalid*” quando não foi possível rastreá-lo corretamente.

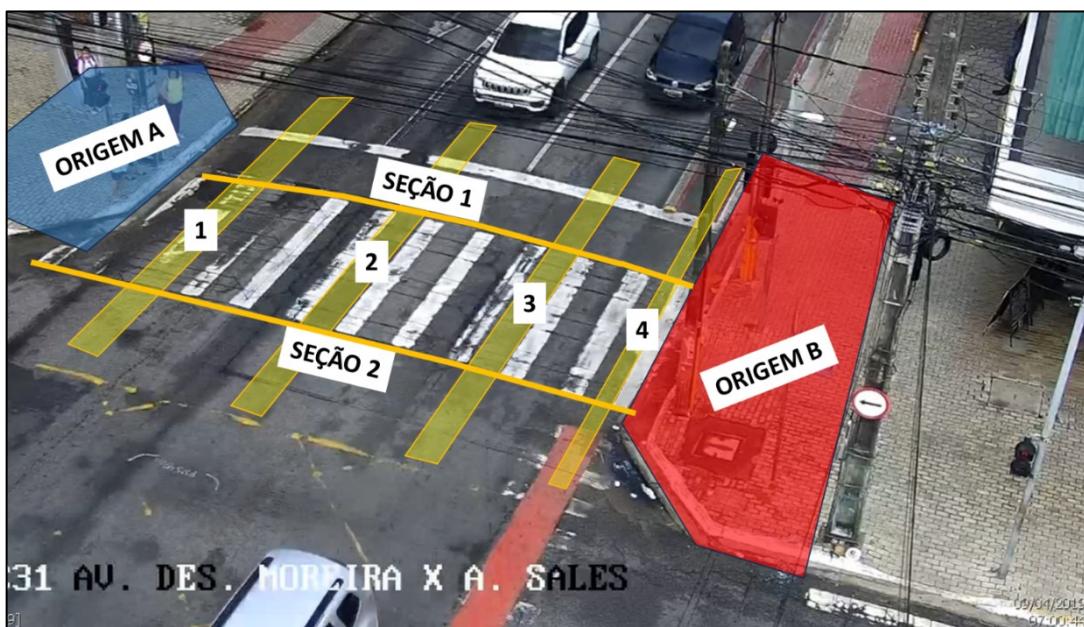
Figura 23 - Vídeo resultante do rastreio e da coleta dos parâmetros



Fonte: elaborada pela autora

Na Figura 24, são relembradas as referências adotadas para registro dos instantes referentes aos veículos e aos pedestres, para compreensão das nomenclaturas utilizadas na coleta dos dados.

Figura 24 - Referências adotadas para registro dos instantes dos pedestres e veículos



Fonte: elaborada pela autora

Um trecho do arquivo resultante da aplicação do código para obtenção dos *headways* e velocidades é mostrado na Figura 25. As colunas presentes nesse arquivo são:

“*track_id*” (ID do veículo), “*class_name*” (classe veicular, podendo ser carro, motocicleta, ônibus, caminhão ou bicicleta), “*lane*” (faixa na qual o veículo foi registrado, sendo de 1 a 4), “*direction*” (variável de controle para filtragem apenas dos veículos que passaram pela área de interesse, retornando o valor 0, enquanto veículos que não passaram pela área de interesse retornaram valor negativo), “*instante_passagem*” (instante de passagem do veículo na seção 1, em segundos), “*velocidade*” (velocidade veicular, em km/h) e “*headway_yolo*” (*headway* veicular, em segundos, sendo atribuído o valor NA ao primeiro veículo de cada faixa).

Figura 25 - Arquivo de saída .csv dos resultados para os veículos

<i>track_id</i>	<i>class_name</i>	<i>lane</i>	<i>direction</i>	<i>instante_passagem</i>	<i>velocidade</i>	<i>headway_yolo</i>
5	motorcycle	1	0	3,93	14,8	NA
6	bus	1	0	9,03	10,9	5,1
17	car	1	0	14,11	17,5	5,08
25	car	1	0	16,78	21,6	2,67
32	car	1	0	20,69	21,1	3,91
36	bus	1	0	24,03	22,4	3,34
42	car	1	0	29,12	26,2	5,09
45	motorcycle	1	0	30,18	30,9	1,06
69	car	1	0	54,78	19,6	24,6
101	bus	1	0	132,77	10,7	77,99
107	bus	1	0	139,68	20,8	6,91
113	car	1	0	143,76	15,6	4,08

Fonte: elaborada pela autora

Para os pedestres, um trecho do arquivo de saída é apresentado na Figura 26. Nele, as colunas presentes são: “*track_id*” (ID do pedestre que realizou travessia), “*direction*” (de onde o pedestre iniciou sua travessia, sendo 0 a origem A e 1 a origem B, e valores negativos categorizando pedestres que não passaram pela área de interesse), “*start_waiting*” (instante de início da espera do pedestre, quando ele entra na área de origem, em segundos), “*stop_waiting*” (instante de final da espera, quando ele sai da área de origem e inicia a travessia, em segundos), “*waiting_time*” (atraso, em segundos) e “*lane_crossing_x*” (instante de passagem dos pedestres pela região central das faixas veiculares 1, 2, 3 e 4, em segundos). Os instantes de passagem pelas faixas se apresentam em ordem crescente para os pedestres da área esquerda e em ordem decrescente para os pedestres da área direita, pois estes iniciam a travessia a partir da faixa 4.

Após o cálculo das diferenças dos tempos de passagem entre as faixas para os pedestres corretamente rastreados, as médias das diferenças foram de 2,6 s entre as faixas 1 e 2, 2,3 s entre as faixas 2 e 3 e 1,8 s entre as faixas 3 e 4, possibilitando a interpolação para estimativa dos instantes de passagem dos pedestres não rastreados em todas as faixas veiculares.

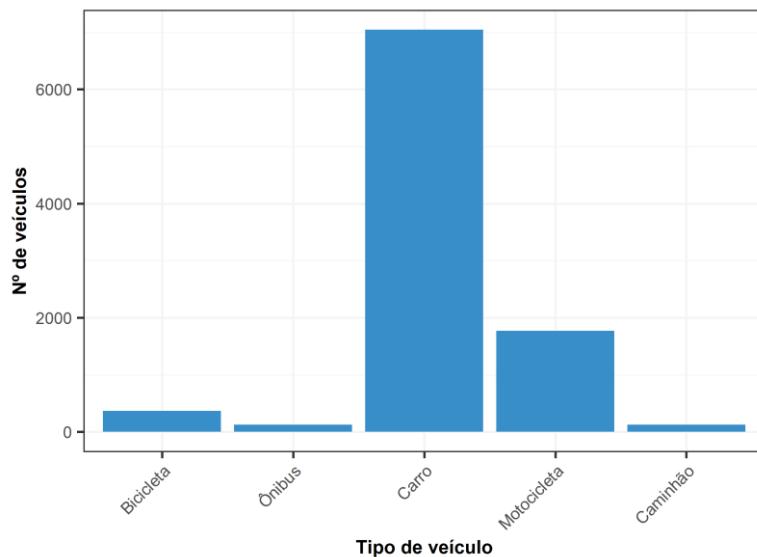
Figura 26 - Arquivo de saída .csv dos resultados para os pedestres

track_id	direction	start_waiting	stop_waiting	waiting_time	lane_crossing_01	lane_crossing_02	lane_crossing_03	lane_crossing_04
20	0	13,85	70,85	57	72,12	74,81	77,12	79,12
21	0	14,1	71,35	57,25	72,31	75,26	77,76	79,71
26	0	16,6	72,31	55,71	72,95	74,8	77,04	78,92
28	0	18,1	71,5	53,4	72,66	75,38	77,92	79,89
102	0	102,5	103,16	0,66	104,35	106,69	108,71	110,49
192	0	224,02	230,4	6,38	230,91	232,88	234,8	237,04
193	0	215,1	216,07	0,97	216,68	219,3	221,37	222,88
318	0	377,7	454,17	76,47	455,02	458,65	462,32	464,75
320	0	378,25	456,54	78,29	457,46	460,93	463,17	464,95
331	0	391,85	454,44	62,59	455,39	458,81	461,3	463,43
334	0	395,65	456,37	60,72	457,07	459,82	462,92	465,15
446	0	476,65	479,11	2,46	479,94	482,37	484,45	486,13

Fonte: elaborada pela autora

No vídeo da Av. Antônio Sales, 9427 veículos e 723 pedestres tiveram rastreados seus instantes de entrada nas respectivas áreas delimitadas, sendo os considerados para prosseguimento da análise. Por classe de veículos, foram detectados 366 bicicletas, 125 ônibus, 7044 carros, 1767 motocicletas e 125 caminhões, como mostrado na Figura 27.

Figura 27 - Distribuição dos veículos rastreados pelo YOLO/StrongSORT, por classe



Fonte: elaborada pela autora

A média, o desvio-padrão e os Intervalos de Confiança t-student a 95% dos *headways* veiculares por faixa estão detalhados na Tabela 5. Os *headways* calculados tiveram os menores valores de média, desvio-padrão e Intervalos de Confiança nas faixas 2 e 3, onde ocorreram os maiores fluxos veiculares. A faixa 1 é a faixa de ônibus, então o fluxo contabilizado foi apenas de veículos autorizados a trafegarem nessa faixa e de veículos que realizaram conversão à direita apresentando, portanto, cerca de um terço do volume das faixas

2 e 3, e um *headway* médio maior. A faixa 4, que corresponde à ciclofaixa, mostra fluxo cerca de dez vezes menor do que as faixas 2 e 3, o que indica menor frequência de bicicletas na interseção, resultando em *headways* com média elevada.

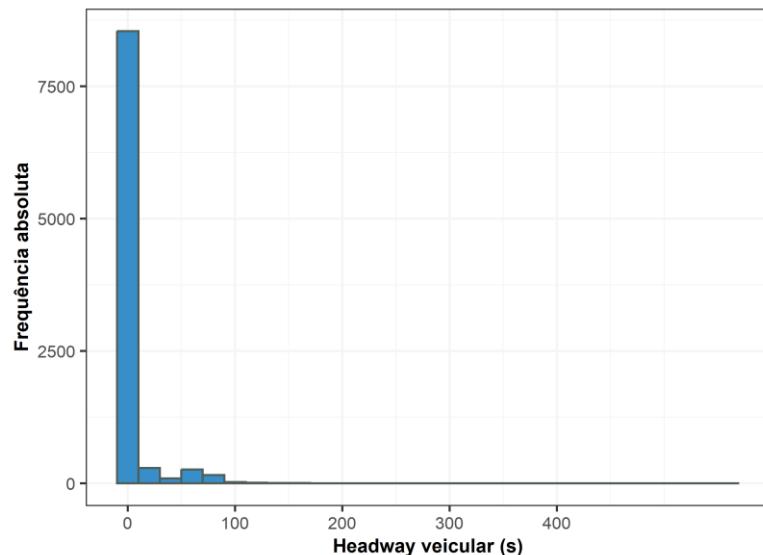
Tabela 5 - IC (95%) dos *headways* contabilizados (em s), por faixa

Faixa	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
1	1260	14	23	[13; 16]
2	3910	5	12	[4; 5]
3	3893	5	12	[4; 5]
4	360	50	73	[42; 57]

Fonte: elaborada pela autora

De acordo com o histograma da Figura 28, os *headways* contabilizados na interseção têm grande amplitude, chegando a quase 600 s, o que pode sugerir um grande intervalo de tempo sem passagem de veículos em alguma faixa. Entretanto, praticamente 100% dos *headways* chegam a no máximo 100 s, com a imensa maioria chegando a até 10 s.

Figura 28 - Histograma de frequência absoluta dos *headways* (em s)



Fonte: elaborada pela autora

Também foi possível investigar a proporção das classes veiculares para cada faixa, como observado na Tabela 6. Como esperado, as maiores proporções nas 3 faixas veiculares são de carros, seguido por motos. Além disso, é maior a incidência de ônibus na faixa 1, que são praticamente ausentes nas outras faixas, assim como é esperada maior proporção de bicicletas na faixa 4 (ciclofaixa). Foram registrados 1,7% de carros (6) e 3,3% de motocicletas

(12) na faixa 4, situações que foram verificadas no vídeo e são justificados pela saída dos 6 carros do estacionamento e posterior registro na ciclofaixa, pela passagem de 10 motocicletas pela ciclofaixa e pela classificação de 2 bicicletas como motocicletas.

Tabela 6 - Proporção de cada classe veicular, por faixa

Classe/Faixa	1	2	3	4
Bicicleta	1,5%	-	0,1%	95,0%
Ônibus	9,2%	0,2%	-	-
Carro	74,9%	80,4%	75,8%	1,7%
Motocicleta	14,0%	17,6%	22,8%	3,3%
Caminhão	0,5%	1,8%	1,3%	-

Fonte: elaborada pela autora

Em relação às velocidades veiculares, cujos resultados para as médias, desvios-padrão e Intervalos de Confiança, total e por classe (em km/h), estão exibidos na Tabela 7. A distância entre a seção 1 e a seção 2 para cálculo dessa variável é de 4,0 m. Houve problemas na obtenção das velocidades de 128 veículos (1,4% do total), sendo 99 deles bicicletas, 13 carros, 15 motocicletas e 1 caminhão. A velocidade padronizada para as 99 bicicletas, calculada com base na velocidade média das observações válidas, foi de 13 km/h, e o restante dos veículos (0,3% do total) foi descartado para a análise, reduzindo a amostra de 9427 para 9398 veículos.

Observa-se na interseção uma velocidade média de 28 km/h e desvio-padrão de 10 km/h. A maior velocidade registrada foi a das motocicletas, em seguida a dos carros, com as bicicletas apresentando velocidade bem menor do que as registradas pelos veículos motorizados, o que é coerente com o observado nas vias em geral.

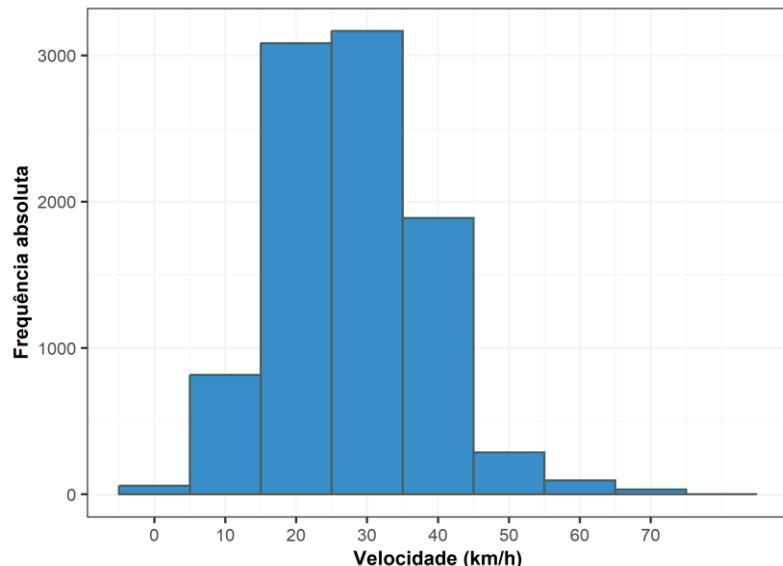
Tabela 7 - IC (95%) das velocidades contabilizadas (em km/h), total e por classe veicular

Classe	N	Média (km/h)	Desvio-padrão (km/h)	IC (95%) (km/h)
Bicicleta	366	13	6	[12; 14]
Ônibus	125	22	8	[21; 24]
Carro	7031	29	9	[28; 29]
Motocicleta	1752	30	12	[30; 31]
Caminhão	124	28	8	[27; 29]
Todas as classes	9398	28	10	[28; 28]

Fonte: elaborada pela autora

O histograma da Figura 29 mostra que cerca de 64% dos veículos que passaram pela interseção no período do vídeo atingiram velocidades entre 15 km/h e 35 km/h, e menos de 10% trafega a velocidades superiores a 50km/h, com um máximo de 75 km/h.

Figura 29 - Histograma das velocidades contabilizadas (em km/h)



Fonte: elaborada pela autora

Por fim, para os pedestres, os parâmetros calculados para o atraso são mostrados na Tabela 8, sendo 18 s de média, 23 s de desvio-padrão e 2 s de erro, também indicando dispersão dos dados, explicada pela variabilidade nos atrasos coletados.

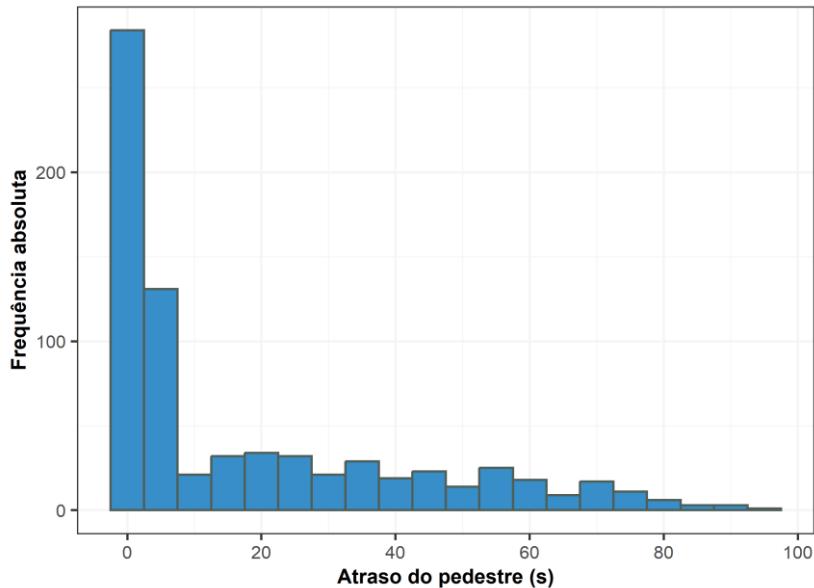
Tabela 8 - IC (95%) dos atrasos contabilizados (em s)

Classe	N	Média (s)	Desvio Padrão (s)	IC (95%) (s)
Pedestre	723	18	23	[16; 20]

Fonte: elaborado pela autora

O histograma da Figura 30 sobre a distribuição de frequência absoluta dos atrasos dos pedestres que realizaram travessia indica predominância de atrasos de até 7,5 s, com elevada variabilidade dos dados, pois há registros de atrasos de até 100 s.

Figura 30 - Histograma dos atrasos contabilizados (em s)

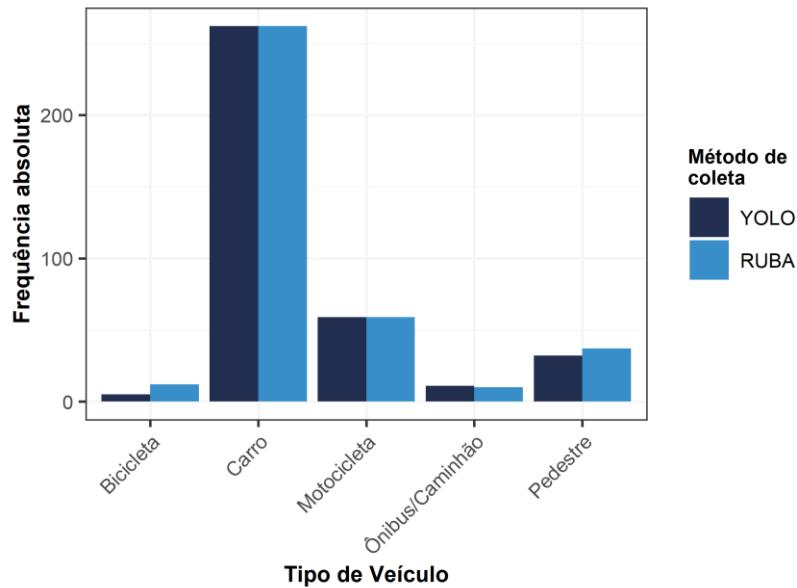


Fonte: elaborada pela autora

4.3.1 Validação da detecção dos objetos

Em relação à comparação entre as ferramentas (YOLO e RUBA), a contagem manual de objetos por meio do RUBA nos 10 minutos iniciais do vídeo da aproximação da Av. Antônio Sales resultou em 343 veículos e 37 pedestres, enquanto no YOLO, nesse mesmo período, foram contabilizados 337 veículos e 32 pedestres, sendo 1,7 % e 13,5 % a menos que no RUBA. Essa diferença entre as contagens ocorreu devido a problemas de detecção no YOLO por conta de ruídos na imagem, oclusões por conta de postes, placas e fios, aglomerações de veículos em momentos de semáforo fechado e de pedestres nas áreas de travessia etc. Na Figura 31 são apresentados os objetos por classe nas duas ferramentas, apontando que, em relação ao RUBA, não houve diferença no YOLO para os carros e as motocicletas, e houve diferenças de -58 % para bicicletas. O YOLO classificou erroneamente um objeto que não é veículo (caçamba de carro) como caminhão, desconsiderado no restante das análises.

Figura 31 - Total de objetos por classe no YOLO e no RUBA



Fonte: elaborado pela autora

Em relação ao pareamento entre os objetos contabilizados por YOLO e RUBA, foram formados 336 pares de veículos e 29 pares de pedestres na aproximação da Av. Antônio Sales, com todos os veículos corretamente classificados pelo YOLO, como mostrado na Matriz de Confusão da Tabela 9.

Tabela 9 - Matriz de Confusão para os veículos pareados

		YOLO			
		Carro	Motocicleta	Ô/C	Bicicleta
R U B A	Carro	262	0	0	0
	Motocicleta	0	59	0	0
	Ô/C	0	0	10	0
	Bicicleta	0	0	0	5
		262	59	10	5

Fonte: elaborada pela autora

4.3.2 Validação dos instantes de passagem e headways veiculares

Os Intervalos de Confiança 95% t-Student das médias das diferenças entre os instantes de passagem na seção 1 (início da faixa de retenção) e na seção 2 (final da faixa de pedestres) dos 336 veículos pareados são exibidos na Tabela 10 e na Tabela 11, respectivamente, valores arredondados para uma casa decimal. Com exceção da classe “Ônibus/Caminhão”, as médias das diferenças de todas as classes em ambas as passagens foram

de 0,0 s, sinalizando que não há diferença nos tempos coletados pelos dois métodos. Os ICs mostram uma forte tendência de que as médias obtidas pelas duas abordagens são similares, pois os limites superior e inferior em quase todos os cenários e em ambos os instantes de passagem foram de 0,0 s, e nas classes “Ônibus/Caminhão” e “Motocicleta” os limites superiores foram de apenas 0,1 s em suas passagens na seção 2.

Tabela 10 - IC (95%) da média das diferenças entre os instantes de passagem na seção 1 (em s)

Tipo de veículo	N	Média (s)	Desvio Padrão (s)	IC (95%) (s)
Bicicleta	5	0,0	0,0	[0,0; 0,0]
Carro	262	0,0	0,1	[0,0; 0,0]
Motocicleta	59	0,0	0,1	[0,0; 0,0]
Ônibus/Caminhão	10	0,0	0,0	[0,0; 0,0]
Todos os veículos	336	0,0	0,1	[0,0; 0,0]

Fonte: elaborada pela autora

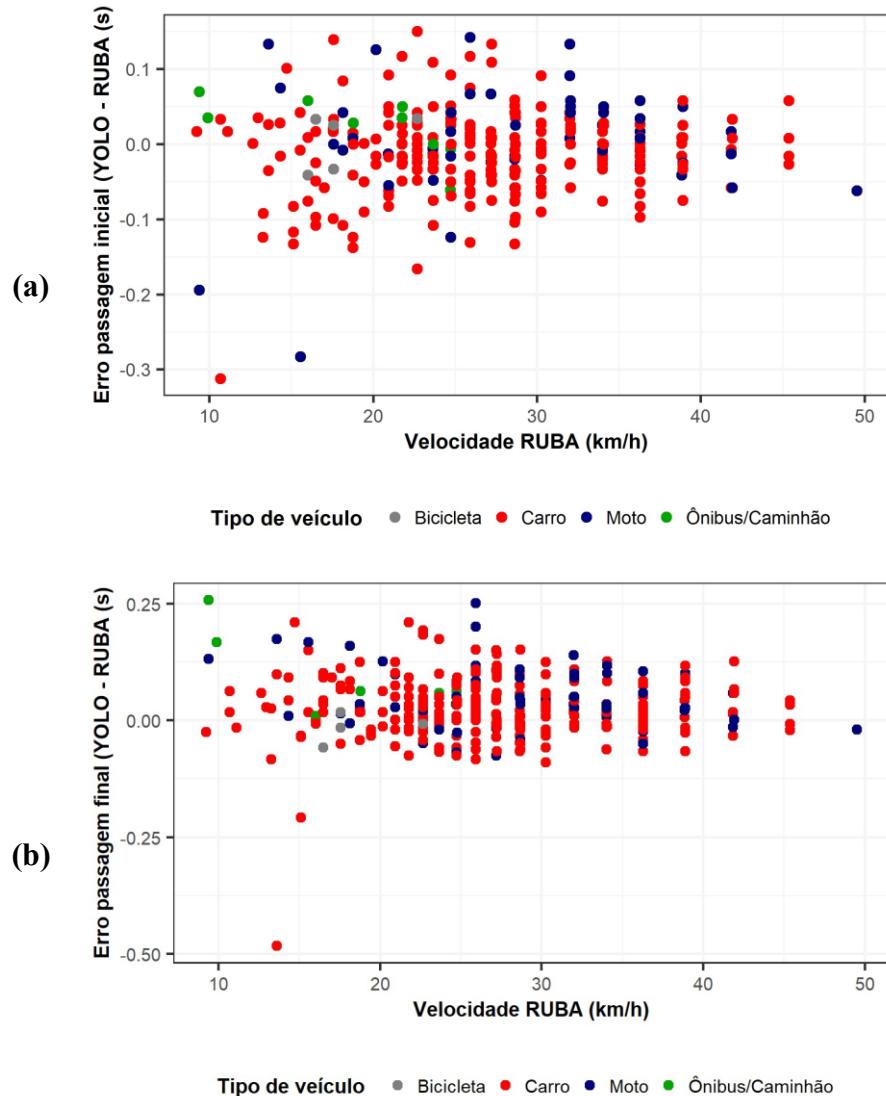
Tabela 11 - IC (95%) da média das diferenças entre os instantes de passagem na seção 2 (em s)

Tipo de veículo	N	Média (s)	Desvio Padrão (s)	IC (95%) (s)
Bicicleta	5	0,0	0,0	[0,0; 0,0]
Carro	262	0,0	0,1	[0,0; 0,0]
Motocicleta	59	0,0	0,1	[0,0; 0,1]
Ônibus/Caminhão	10	0,1	0,1	[0,0; 0,1]
Todos os veículos	336	0,0	0,1	[0,0; 0,0]

Fonte: elaborada pela autora

Na Figura 32 são mostrados os gráficos de dispersão das diferenças (erros) entre os instantes de passagem na seção 1 (Figura 32a) e entre os instantes na seção 2 (Figura 32b) coletados pelos dois métodos (em segundos), considerando sua relação com as velocidades coletadas pelo RUBA. Os resultados dos dois gráficos mostram que, para todas as classes, grande parte dos erros está entre -0,1 s e +0,1 s. Nota-se também pontos isolados com valores discrepantes nos dois gráficos, mas essas diferenças chegam a um valor máximo de -0,5 s.

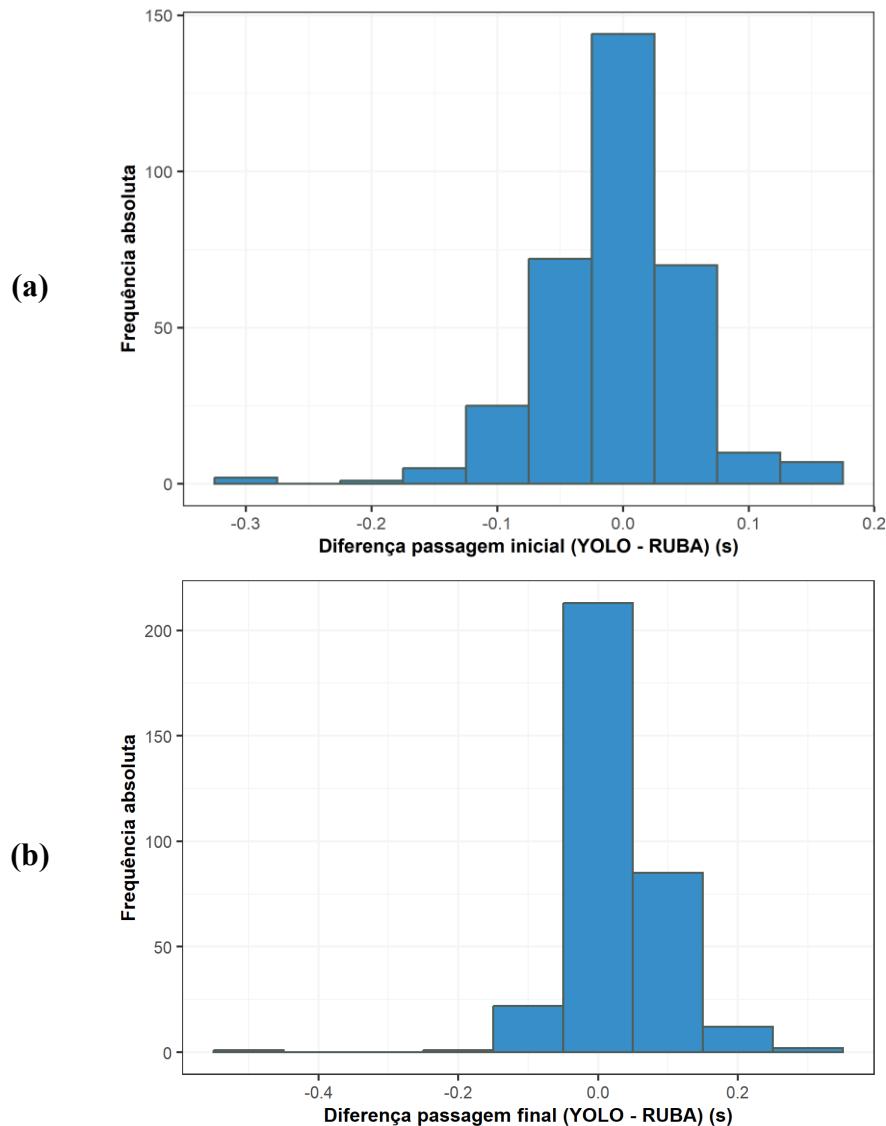
Figura 32 - Gráficos dos erros entre os instantes de passagem na seção 1 (a) e entre os instantes de passagem na seção 2 (b) (em s) em relação à velocidade coletada no RUBA



Fonte: elaborada pela autora

Os histogramas das diferenças entre os instantes de passagem na seção 1 (a) e entre os instantes de passagem na seção 2 (b), na Figura 33, mostram uma centralidade dos resultados em torno da média (0 s), variando sobretudo entre -0,1 s e +0,1 s, com discrepâncias isoladas.

Figura 33 - Histogramas das diferenças entre os instantes de passagem na seção 1 (a) e entre os instantes de passagem na seção 2 (b) (em s)



Fonte: elaborada pela autora

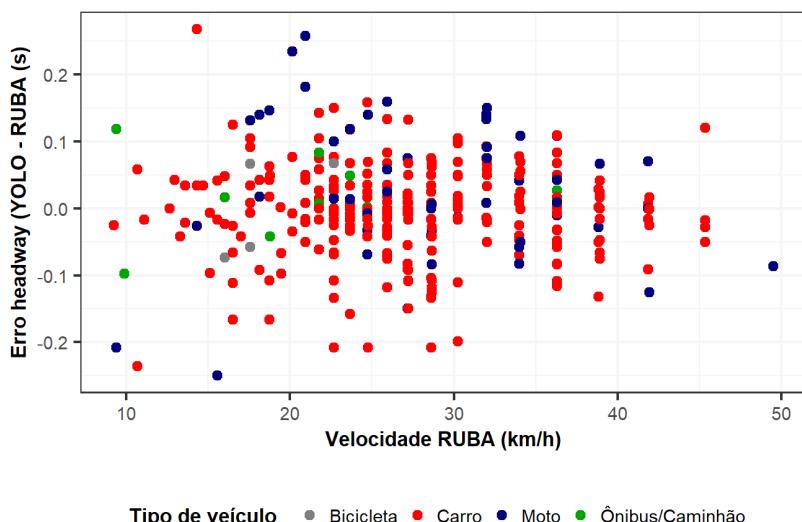
Das 336 observações de veículos pareados, todas tiveram seus *headways* considerados para análise das médias das diferenças, cujos resultados dos Intervalos de Confiança são exibidos na Tabela 12. A média dos *headways* por classe e para todas as classes foi de 0,0 s (aproximando-se para uma casa decimal), mostrando que não houve diferença na coleta pelos dois métodos. Os desvios-padrão também foram similares, de 0,1 s, e o Intervalo de Confiança com maior amplitude ocorreu na classe “Bicicleta”, sendo necessária uma coleta mais robusta para confirmar essa tendência, pois a amostra é relativamente pequena.

Tabela 12 - IC (95%) da média das diferenças entre os *headways* (em s)

Tipo de veículo	N	Média (s)	Desvio Padrão (s)	IC (95%) (s)
Bicicleta	5	0,0	0,1	[-0,1; 0,1]
Carro	262	0,0	0,1	[0,0; 0,0]
Motocicleta	58	0,0	0,1	[0,0; 0,0]
Ônibus/Caminhão	10	0,0	0,1	[0,0; 0,1]
Todos os veículos	335	0,0	0,1	[0,0, 0,0]

Fonte: elaborada pela autora

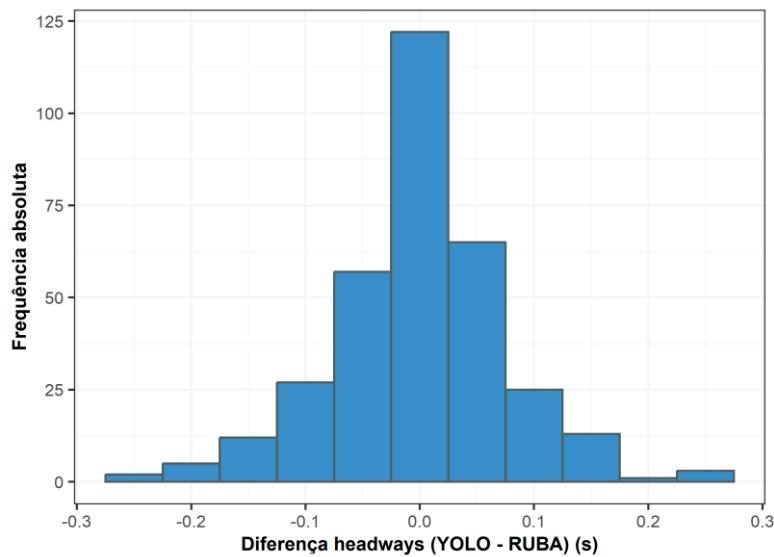
A Figura 34, que ilustra o gráfico de dispersão dos erros entre os *headways* (em segundos) considerando sua relação com as velocidades coletadas pelo RUBA, mostra que a maioria dos valores se concentra entre -0,1 e +0,1 s, com poucas observações chegando a -0,2 s e +0,2 s. Isso se deve provavelmente a diferenças na coleta dos instantes de chegada no início da faixa de retenção, pois o *headway* veicular é calculado a partir desse parâmetro. Um exemplo é o carro cuja velocidade é 10 km/h e cujo erro é -0,25 s, que aparece com o maior erro (-0,3 s) no gráfico dos erros dos instantes de chegada na seção 1, na Figura 32a.

Figura 34 - Gráfico dos erros dos *headways* (em s) em relação à velocidade coletada no RUBA

Fonte: elaborada pela autora

O histograma das diferenças entre os *headways* coletados pelos dois métodos, na Figura 35, reforça a centralidade dos dados, pois o histograma é simétrico e 75% das amostras apresenta diferenças entre -0,08 s e +0,08 s, e as diferenças máximas entre os *headways* chegam a apenas -0,3 s e +0,3 s.

Figura 35 - Histograma das diferenças entre os *headways* (em s)



Fonte: elaborada pela autora

4.3.3 Validação das velocidades veiculares

A análise de médias, desvios-padrão e Intervalos de Confiança a 95% para as diferenças das velocidades veiculares é resumida na Tabela 13. A distância entre a seção 1 e a seção 2 tem 6,3 m de comprimento, com base no *Google Earth*. As médias das diferenças para carros, motocicletas, ônibus/caminhões e para as classes em conjunto foram negativas e pequenas, sinalizando que as velocidades coletadas pelo RUBA foram maiores em relação ao YOLO, ao passo que a média das diferenças das bicicletas foi positiva. É importante lembrar que o cálculo das velocidades nas duas ferramentas depende de dois instantes de tempo, e uma pequena diferença pode aumentar significativamente a diferença entre as velocidades.

Tabela 13 - IC (95%) da média das diferenças entre as velocidades (em km/h)

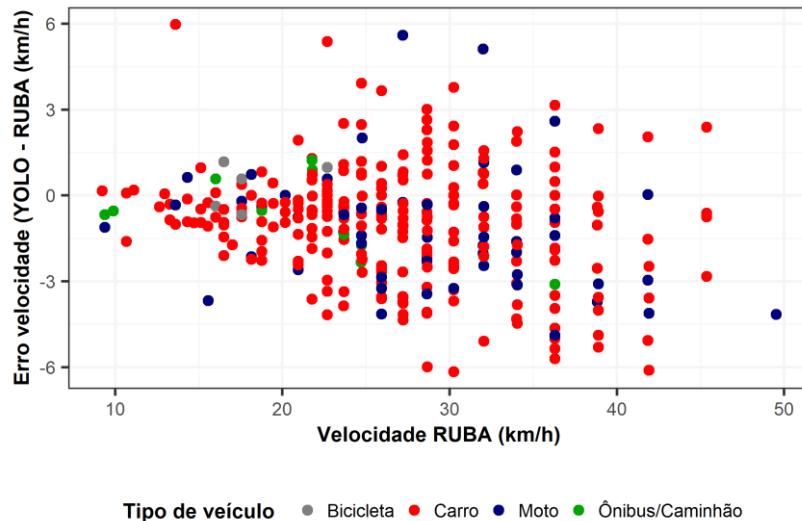
Tipo de veículo	N	Média (km/h)	Desvio Padrão (km/h)	IC (95%) (km/h)
Bicicleta	5	0,3	0,8	[-0,7; 1,4]
Carro	262	-0,9	2,0	[-1,1; -0,7]
Motocicleta	59	-1,0	2,2	[-1,6; -0,4]
Ônibus/Caminhão	10	-0,8	1,4	[-1,8; 0,2]
Todos os veículos	336	-0,9	2,0	[-1,1; -0,7]

Fonte: elaborada pela autora

Para o gráfico de dispersão dos erros entre as velocidades (em km/h) considerando sua relação com as velocidades coletadas pelo RUBA, na Figura 36, é sugerido que a dispersão

dos erros aumenta com a velocidade, o que pode ser investigado em trabalhos futuros, com testes estatísticos de homoscedasticidade. Os erros apresentados no gráfico podem ser considerados baixos, pois correspondem a cerca de $\pm 1,6$ m/s de diferença.

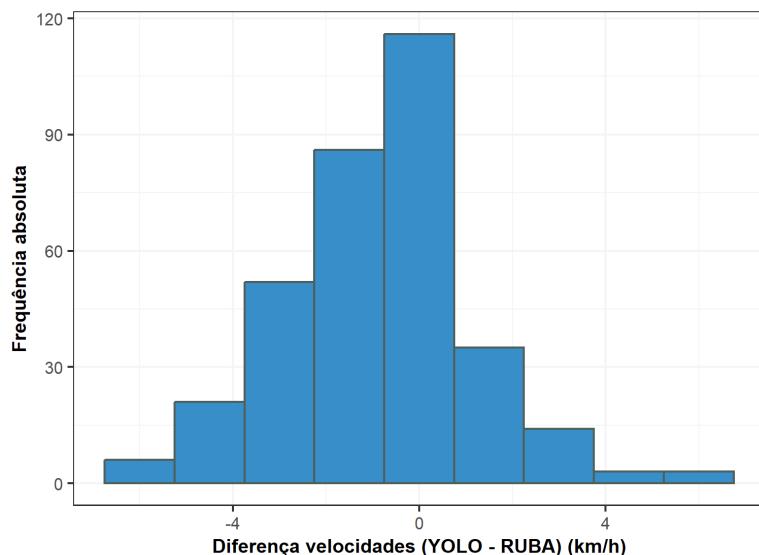
Figura 36 - Gráfico dos erros das velocidades em relação à velocidade coletada no RUBA (em km/h)



Fonte: elaborada pela autora

Em relação ao histograma das frequências absolutas das diferenças entre as velocidades, na Figura 37, a maioria das amostras apresenta diferenças negativas, entre -4 km/h e 0 km/h, sendo assim um histograma assimétrico. Esse resultado é coerente com os resultados encontrados na Tabela 13 e no gráfico da Figura 36.

Figura 37 - Histograma das diferenças entre as velocidades (em km/h)



Fonte: elaborada pela autora

4.3.4 Validação dos atrasos dos pedestres

No caso dos pedestres, os parâmetros analisados são apresentados na Tabela 14, a qual mostra diferenças pequenas, de no máximo 0,2 s nos ICs e nos desvios-padrão.

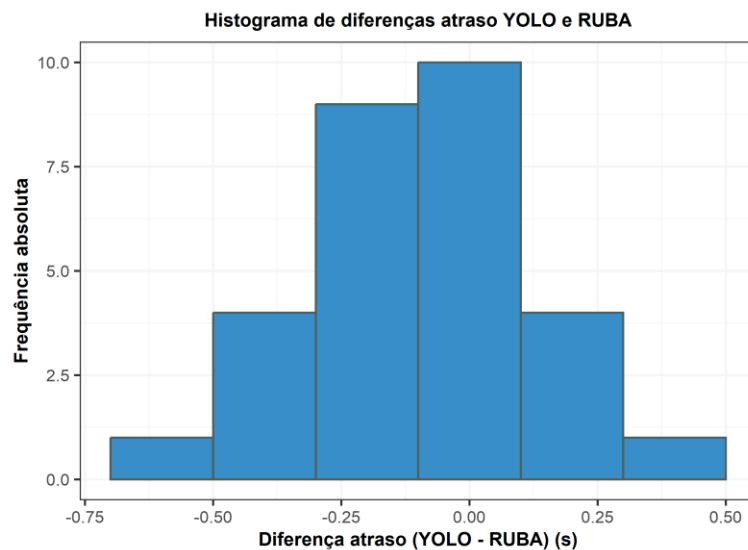
Tabela 14 - IC (95%) da média das diferenças para os pedestres (em s)

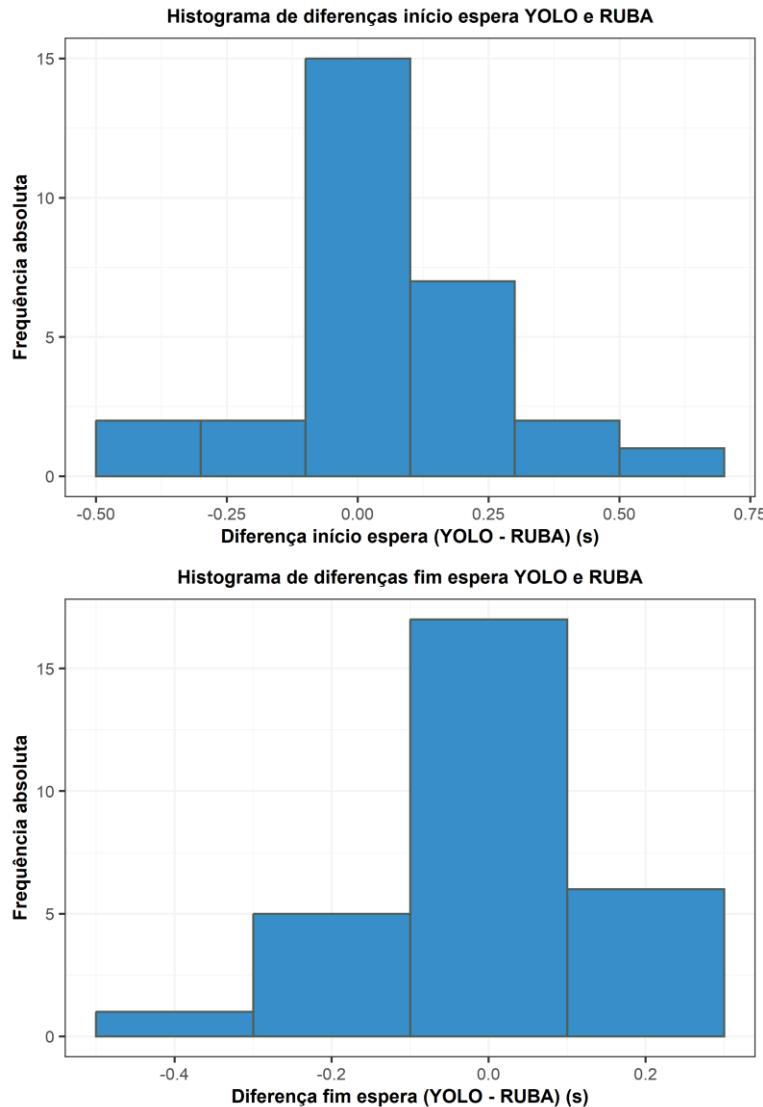
	N	Média (s)	Desvio Padrão (s)	IC (95%) (s)
Dif. atraso	29	-0,1	0,2	[-0,2; 0,0]
Dif. início de espera	29	0,1	0,2	[0,0; 0,1]
Dif. fim de espera	29	0,0	0,1	[-0,1; 0,0]

Fonte: elaborada pela autora

Os histogramas das diferenças dos parâmetros dos pedestres, ilustrados na Figura 38, mostram que não há diferenças grandes entre as coletas pelo YOLO e pelo RUBA em todos os casos, além de todos terem a maioria das amostras em torno de 0 s. No histograma das diferenças dos atrasos, a maior parte dos valores se encontra na faixa entre -0,25 e +0,25 s, e a variabilidade dos dados não é alta, entre -0,75 s e +0,5 s devido às pequenas diferenças nos instantes de início e fim da espera, que variam entre -0,5 s e +0,75.

Figura 38 - Histogramas das diferenças dos parâmetros dos pedestres





Fonte: elaborada pela autora

A incorporação das áreas de espera e de conflito na modelagem é uma melhoria em relação ao estudo de Castro Jr. *et al.* (2021), que contabilizaram o atraso dos pedestres a partir do momento em que eles apareceram e desapareceram no vídeo, procurando-se assim evitar a sua superestimação, pois os tempos de início e fim de espera dos pedestres são contabilizados mais próximos do local de sua travessia. No entanto, sugere-se para trabalhos futuros a adoção de uma metodologia que possibilite uma previsão ainda melhor desses instantes, como pela velocidade do pedestre.

Por fim, em relação aos veículos e pedestres que não formaram pares, foram encontrados erros de identificação da trajetória de pedestres e de bicicletas, invalidando seu rastreio e prejudicando a obtenção de seus instantes de passagem nas respectivas áreas e seções de referência. Tais erros ocorreram devido à oclusão desses objetos por fios, postes e placas, principalmente onde se localiza a ciclofaixa e a calçada direita. Outros erros percebidos foram

a troca de ID dos pedestres em situações de aglomerações na área de espera e na travessia, por perdas em seu rastreio, e a classificação incorreta de um objeto como caminhão, mencionado anteriormente. Uma observação pertinente é o tipo de erro de acordo com o tamanho do objeto, visto que bicicletas e pedestres são objetos pequenos e com trajetórias muitas vezes heterogêneas, e que podem ainda ter sua visualização obstruída pelo cenário. O detalhamento dos erros por classe é exposto na Tabela 15 e exemplos desses erros estão na Figura 39.

Espera-se que um novo treinamento do modelo para pedestres e bicicletas, com amostras mais balanceadas, solucione ou mitigue os problemas de rastreio e troca de ID.

Tabela 15 - Erros encontrados no rastreio

	Carro	Motocicleta	Ônibus/ Caminhão	Bicicleta	Pedestre	Total por erro
Erro no rastreio	0	0	0	7	6	13
Troca de ID	0	0	0	0	2	2
Classificação incorrecta	0	0	1	0	0	1
Total por classe	0	0	1	7	8	-
Total de erros						16

Fonte: elaborada pela autora

Figura 39 - Exemplos de erros encontrados no rastreio (a = oclusão de pedestre; b = oclusão de pedestre e troca de ID de 219 para 271)



Fonte: elaborada pela autora

4.4 Análise exploratória das variáveis relacionadas à aceitação de headways

Para melhor entendimento, as análises exploratórias da relação do atraso dos pedestres na aceitação dos *headways* foram organizadas e discutidas separadamente para: *headways* aceitos em todas as faixas, *headways* mínimos aceitos, *headways* aceitos em todas as faixas no vermelho dos pedestres e *headways* mínimos aceitos no vermelho dos pedestres.

4.4.1 Headways aceitos

Um trecho do arquivo de saída resultante dos *headways* aceitos por pedestre é exibido na Figura 40. Nota-se que cada pedestre (*track_id*) tem 4 registros de *headway* aceito, sendo 1 por faixa (*lane*), e em cada registro constam as informações de classe veicular (*class_name*), ID do veículo (*track_id_vehicle*), o *headway* entre o pedestre e o veículo sucessor a ele, em s (*headway_pedestrian_vehicle*), o início da espera do pedestre, em s (*start_waiting*), o fim da espera do pedestre, em s (*stop_waiting*), o instante no qual o pedestre foi registrado em cada faixa de rolamento, em s (*passage_in_lane*), o atraso do pedestre, em s (*waiting_time*), o *headway* entre o veículo antecessor e o veículo sucessor ao pedestre, em s (*headway_bt_vehicle*) e a velocidade veicular, em km/h (*velocity*).

Figura 40 - Arquivo de saída .csv dos resultados dos *headways* aceitos pelos pedestres

<i>track_id</i>	<i>lane</i>	<i>direction</i>	<i>class_name</i>	<i>track_id_vehicle</i>	<i>headway_pedestrian_vehicle</i>	<i>start_waiting</i>	<i>stop_waiting</i>	<i>passage_in_lane</i>	<i>waiting_time</i>	<i>headway_bt_vehicle</i>	<i>velocity</i>
61	4	1	bicycle	148	99,67	46,65	71,04	71,33	24,39	157,32	13
61	3	1	motorcycle	89	2,7	46,65	71,04	72,69	24,39	8,28	-1
61	2	1	motorcycle	91	56,85	46,65	71,04	74,77	24,39	65,09	16
61	1	1	bus	101	55,66	46,65	71,04	77,11	24,39	77,99	10,7
202	4	1	bicycle	228	28,53	248,25	249,37	249,38	1,12	105,21	22,4
202	3	1	motorcycle	205	10,55	248,25	249,37	250,38	1,12	67,39	19,6
202	2	1	motorcycle	198	8,56	248,25	249,37	252,11	1,12	69,11	16,1
202	1	1	car	185	8,44	248,25	249,37	253,9	1,12	69,27	13,8
564	4	1	bicycle	566	11,16	630,7	633	633,19	2,3	26,53	9,7
564	3	1	car	532	9,29	630,7	633	635,08	2,3	69,2	13,2
564	2	1	motorcycle	554	7,25	630,7	633	637,42	2,3	73,5	16,8
564	1	1	car	541	5,91	630,7	633	641,16	2,3	70,54	10,7
682	4	1	bicycle	683	1,26	748,75	751,33	751,43	2,58	2,53	9,7
682	3	1	motorcycle	671	19,58	748,75	751,33	752,36	2,58	65,99	14,4
682	2	1	car	658	20,71	748,75	751,33	753,71	2,58	67,74	13
682	1	1	motorcycle	686	16,96	748,75	751,33	755,08	2,58	33,97	13

Fonte: elaborada pela autora

O “*headway_pedestrian_vehicle*” é o *headway* aceito pelo pedestre. No total, foram registradas 2892 observações de *headways* aceitos, o que corresponde a 723 observações por faixa, ou 723 pedestres. Aplicando o filtro de *headways* aceitos de até 10 segundos, se tem como resultado 220 observações de *headways* aceitos, de 153 pedestres, sendo 49 *headways* aceitos na faixa 1, 42 na faixa 2, 44 na faixa 3 e 85 na faixa 4.

Os resultados dos Intervalos de Confiança a 95% dos *headways* aceitos por faixa veicular e origem do pedestre (A e B) são apontados na Tabela 16 e na Tabela 17. Nota-se que os *headways* médios têm valor semelhante para as duas origens, variando entre 4 e 7 s, assim como os desvios-padrão, que variam entre 2 s a 3 s, com tendência de *headways* aceitos maiores pelos pedestres da origem B. O número de *headways* aceitos aumenta e seu valor diminui nas faixas de tráfego motorizado mais distantes da origem, ou seja, a faixa 1 para os pedestres da origem B e a faixa 3 para os pedestres da origem A. A faixa 4 (ciclofaixa) apresenta o maior

número de *headways* aceitos em ambas as situações, possivelmente por ser um veículo pequeno e não motorizado, que oferece menor risco de conflitos de maior severidade em comparação aos veículos motorizados. Outra possibilidade é a maior chance de desobediência das bicicletas ao semáforo, então um pedestre que atravessou no vermelho para os veículos pode ter “aceitado” um *headway* de uma bicicleta que se aproximava quando ele passou pela ciclofaixa.

Tabela 16 - IC (95%) dos *headways* aceitos (em s) pelos pedestres da origem A, por faixa veicular

Faixa	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
1	16	6	3	[5; 7]
2	15	6	2	[5; 7]
3	22	5	2	[4; 6]
4	47	5	3	[4; 6]
Total	100	5	3	[5; 6]

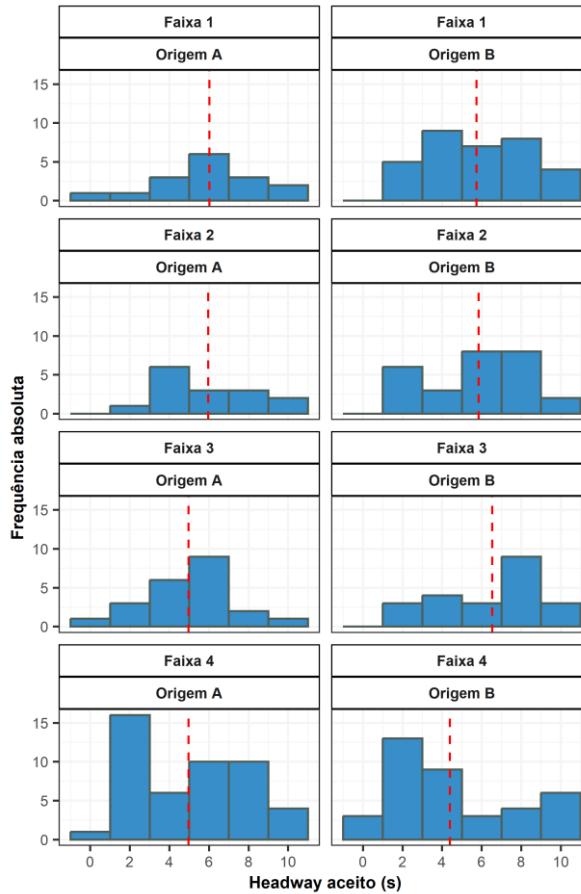
Fonte: elaborada pela autora

Tabela 17 - IC (95%) dos *headways* aceitos (em s) pelos pedestres da origem B, por faixa veicular

Faixa	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
1	33	6	2	[5; 7]
2	27	6	3	[5; 7]
3	22	7	2	[6; 8]
4	38	4	3	[3; 5]
Total	120	6	3	[5; 6]

Os histogramas de frequência dos *headways* aceitos por faixa e origem do pedestre estão na Figura 41 (médias representadas pelas linhas tracejadas). Nota-se uma tendência de os pedestres da origem B aceitarem *headways* levemente maiores do que os da origem A, sobretudo nas faixas 2 e 3. A faixa 4 apresenta a maior variabilidade e predominância de *headways* aceitos entre 1 e 3 s para ambas as origens.

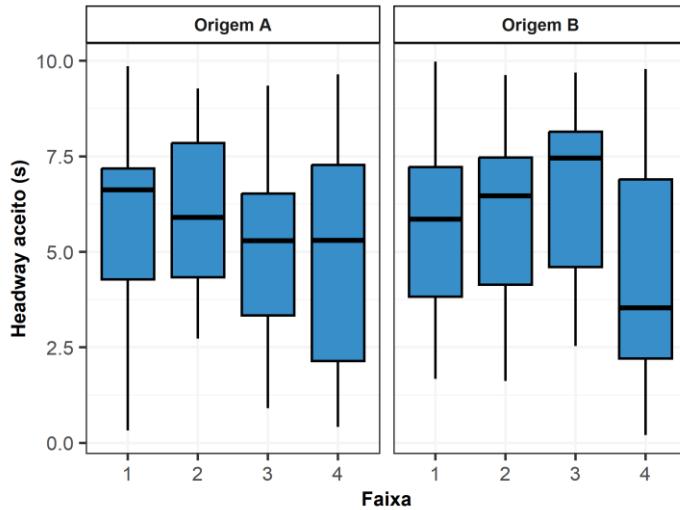
Figura 41 - Histogramas dos *headways* aceitos (em s), por faixa veicular e por zona de origem do pedestre



Fonte: elaborada pela autora

Sobre os *boxplots* dos *headways* aceitos por faixa veicular e por origem do pedestre, representados na Figura 42, é possível perceber que o maior valor de mediana para os pedestres na origem A foi na faixa 1 (7 s) e para os pedestres na origem B foi na faixa 3 (7,5 s), as quais são as faixas mais próximas de cada origem, diminuindo à medida que a faixa se distancia da origem, como foi visto nos Intervalos de Confiança da Tabela 16 e da Tabela 17. A faixa com a maior dispersão dos dados entre os quartis é a faixa 4, principalmente entre o segundo e o terceiro quartis (entre 2,5 e 7,5 s nas duas origens), e na origem B ela apresenta o menor valor.

Figura 42 - Boxplots dos *headways* aceitos por faixa veicular e por zona de origem do pedestre



Fonte: elaborada pela autora

No que tange às velocidades dos veículos relacionados aos *headways* aceitos, os resultados dos Intervalos de Confiança a 95% por tipo de veículo e origem do pedestre da Tabela 18 e da Tabela 19 mostram que as velocidades médias são semelhantes para os pedestres das duas origens. Os veículos com as velocidades médias mais altas foram as motocicletas, em seguida os carros, e as bicicletas foram os veículos com as velocidades médias mais baixas e com o maior número de *headways* aceitos.

Ademais, não foram aceitos *headways* de caminhões por parte dos pedestres das duas origens, provavelmente por serem veículos pesados e oferecerem maior risco mesmo a velocidades mais baixas, ou pela proporção deles na frota ser bem menor. Entretanto, 3 pedestres da origem B aceitaram *headways* de ônibus, enquanto nenhum pedestre da origem A aceitou. Mais observações devem ser coletadas para compreender as razões para esse resultado.

Importante reforçar que, para cálculo dos ICs das velocidades, foram descartadas 4 observações (2 motocicletas), das quais não foi possível extrair a velocidade por problemas no rastreio, totalizando 216 veículos com velocidades válidas nas 4 faixas veiculares.

Tabela 18 - Velocidades (em km/h) dos veículos de *headways* aceitos pelos pedestres da origem A, por tipo de veículo

Tipo de veículo	N	Média (km/h)	Desvio-padrão (km/h)	IC (95%) (km/h)
Bicicleta	57	9	3	[8; 10]
Ônibus	-	-	-	-
Carro	15	19	7	[15; 22]
Motocicleta	26	21	15	[15; 26]
Caminhão	-	-	-	-
Todos os veículos	98	14	10	[12; 16]

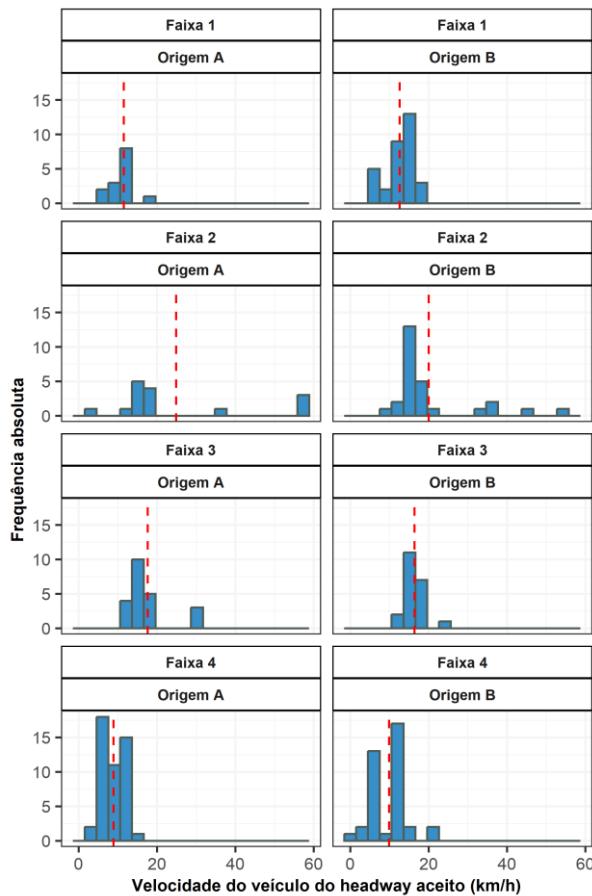
Fonte: elaborada pela autora

Tabela 19 - Velocidades (em km/h) dos veículos de *headways* aceitos pelos pedestres da origem B, por tipo de veículo

Tipo de veículo	N	Média (km/h)	Desvio-padrão (km/h)	IC (95%) (km/h)
Bicicleta	42	9	5	[8; 11]
Ônibus	3	10	2	[5; 15]
Carro	42	17	6	[1; 19]
Motocicleta	31	17	9	[14; 21]
Caminhão	-	-	-	-
Todos os veículos	118	14	7	[13; 15]

Os histogramas de frequências das velocidades por faixa veicular e origem do pedestre, na Figura 43, mostram médias entre 10 km/h e 30 km/h em todos os gráficos, sendo mais altas na faixa 2, por conta de observações com velocidades muito altas, de até 60 km/h. Há frequências maiores na origem B, devido a um maior número de *headways* aceitos menores que 10 s pelos pedestres dessa área.

Figura 43 - Histogramas das velocidades (em km/h) dos veículos de *headways* aceitos pelos pedestres, por faixa veicular e por zona de origem do pedestre

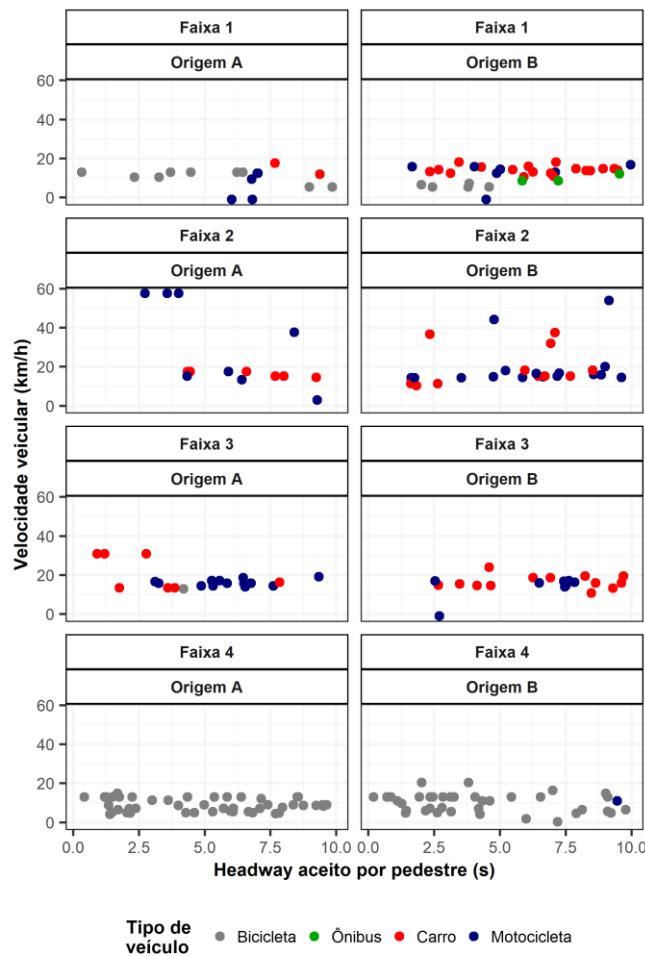


Fonte: elaborada pela autora

Na Figura 44, é representada a relação entre os *headways* aceitos pelos pedestres, em segundos, e a velocidade dos veículos associados a esses *headways*, em km/h, em cada faixa veicular e cada área de origem dos pedestres, por tipo de veículo. Os pedestres de ambas as origens aceitaram predominantemente *headways* de veículos com velocidades máximas de 20 km/h, independente da faixa e do tipo de veículo. Tais velocidades são baixas o suficiente para sinalizar travessias no final do semáforo vermelho para os veículos.

Os veículos com velocidades acima de 40 km/h na faixa 2 das origens A e B estão a velocidades altas o suficiente para dar a entender que estavam trafegando no verde e houve aceitação de *headways* por parte dos pedestres. Nota-se que esses veículos com velocidades mais altas são predominantemente motocicletas, trafegavam na faixa 2 e tiveram *headways* aceitos por pedestres de ambas as origens. As travessias de maior risco provavelmente foram referentes aos três pedestres que atravessaram a partir da origem A e aceitaram *headways* entre 2,5 s e 4 s de motocicletas a 60 km/h.

Figura 44 - Relação entre os *headways* aceitos (em s) e as velocidades veiculares (em km/h), por tipo de veículo, faixa veicular e zona de origem do pedestre



Fonte: elaborada pela autora

Além dos *headways* aceitos e das velocidades relacionadas aos veículos dos *headways* aceitos, também foi realizada uma análise exploratória do atraso dos 153 pedestres, também para os *headways* de até 10 s, por área de origem. Os Intervalos de Confiança a 95%, exibidos na Tabela 20, mostram que o atraso médio do total de pedestres foi de 12 s, e considerando por origem os pedestres da origem A demoraram, em média, quase o triplo do tempo dos pedestres da origem B para iniciarem travessia.

Não há como afirmar que os pedestres da origem B são mais agressivos; talvez eles tenham chegado na interseção principalmente em períodos de semáforo vermelho ou no final do verde para os veículos, enquanto os da origem A esperaram um tempo maior para o semáforo fechar. Outra razão possível seria caso a travessia com origem em A fosse mais arriscada, devido ao diferente uso das faixas pelos diferentes tipos de veículo. Dessa forma, mais observações precisam ser coletadas e mais análises precisam ser conduzidas para se chegar a

uma conclusão. Um aspecto importante a ser analisado é o desvio-padrão dos atrasos por origem, pois os pedestres da origem A apresentam um valor de desvio-padrão que é quase o dobro dos pedestres da origem B.

Tabela 20 - Atrasos (em s) dos pedestres, por área de origem

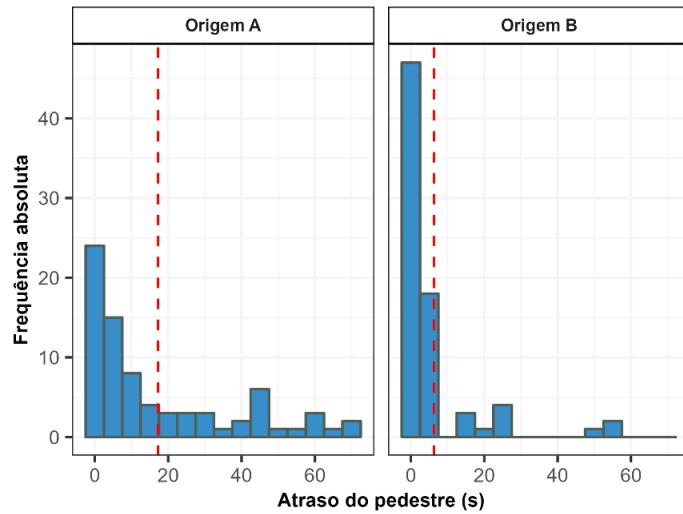
Origem do pedestre	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
A	77	17	20	[13; 22]
B	76	6	12	[4; 9]
Total	153	12	17	[9; 15]

Fonte: elaborada pela autora

Os histogramas de frequência absoluta para o atraso dos pedestres por zona de origem, mostrados na

Figura 45, corroboram com os resultados dos Intervalos de Confiança, pois a média do atraso dos pedestres da origem A é de quase 20 s e dos pedestres da origem B é de menos de 10 s, e o histograma mostrado para a origem A tem uma variabilidade maior dos valores – chegando a mais de 60 s de atraso – do que os da origem B, que tem quase todos os seus valores de atraso concentrados nos primeiros 10 s.

Figura 45 - Histogramas dos atrasos (em s) dos pedestres, por zona de origem do pedestre



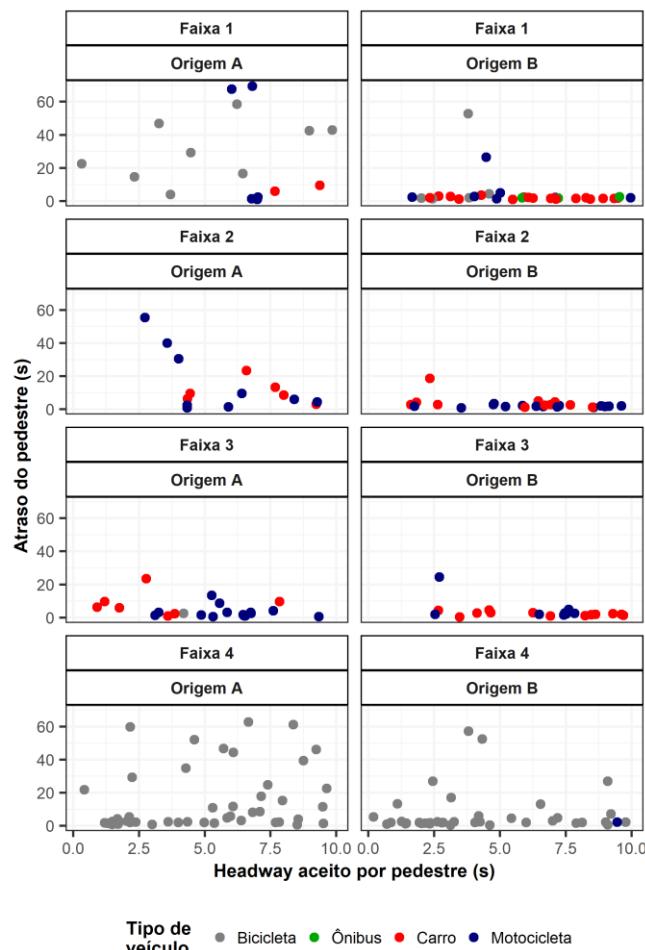
Fonte: elaborada pela autora

A relação entre os *headways* aceitos pelos pedestres e seu atraso, ambos em segundos, em cada faixa veicular e origem do pedestre, por tipo de veículo, é exibida nos gráficos de dispersão da Figura 46. Visualmente, os pedestres da origem B esperaram tempos

pequenos para realizarem travessia, e aceitaram em sua maioria *headways* entre 2,5 s e 10 s, o que pode travessias no final do verde dos pedestres, principalmente os pedestres que aceitaram *headways* de 5 s ou menos. A faixa 4 mostra aceitação de *headways* menores de 2,5 s, o que pode apontar desrespeito dos ciclistas ao semáforo vermelho ou menor risco oferecido segundo a percepção dos pedestres, por ser um veículo menor e não motorizado.

Os pedestres da origem A, por sua vez, não mostram o mesmo padrão em todas as faixas. Os *headways* aceitos na faixa 3 mostram semelhanças com os *headways* aceitos pelos pedestres da origem B, e há pedestres que esperaram um tempo relativamente elevado e aceitaram *headways* baixos de motocicletas e bicicletas nas faixas 1 e 2, supostamente por impaciência, por serem veículos menores, desrespeito desses veículos ao semáforo vermelho, ou ainda por serem travessias que terminaram logo antes do início do verde para os veículos.

Figura 46 - Relação entre os *headways* aceitos e os atrasos dos pedestres (em s) por tipo de veículo, faixa veicular e zona de origem do pedestre



Fonte: elaborada pela autora

4.4.2 Headways mínimos aceitos

Relembra-se que um *headway* aceito mínimo de um pedestre é o menor dentre os *headways* aceitos (1 por faixa) da sua travessia. Foram contabilizados 153 *headways* mínimos aceitos (1 por pedestre), divididos entre as origens A e B, como exibido na Tabela 21 e na Tabela 22. A média para todas as travessias é igual para as duas origens (5 s), e a origem A mostra o mesmo valor médio para todas as faixas, enquanto a origem B mostra médias de 6 s para a faixa 1 e de 4 s para as restantes. Além disso, os desvios-padrão variam de 2 s a 3 s, exceto na faixa 3 da origem B, que apresenta um desvio-padrão de 1,0 s. Em relação aos Intervalos de Confiança, há discrepância moderada entre os valores mínimos e máximos, por conta do tamanho das amostras que, quanto menores, menos precisas são as estimativas.

As maiores frequências ocorrem na faixa 4, na qual há tráfego exclusivo de bicicletas, o que pode ter contribuído para os menores *headways* aceitos serem nessa faixa. Considerando as faixas de tráfego motorizado, um número maior de pedestres aceitou *headways* mínimos nas faixas mais distantes das suas origens, ou seja, a faixa 3 para a origem A e a faixa 1 para a origem B, pois os veículos referentes a esses *headways* provavelmente estavam mais distantes no início da travessia e encontravam-se próximos quando os pedestres chegaram nas faixas correspondentes.

Tabela 21 - *Headways* mínimos aceitos (em s) pelos pedestres da origem A, por faixa veicular

Faixa	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
1	11	5	3	[3; 7]
2	5	5	3	[2; 9]
3	15	5	2	[4; 6]
4	46	5	3	[4; 6]
Total	77	5	3	[4; 6]

Fonte: elaborada pela autora

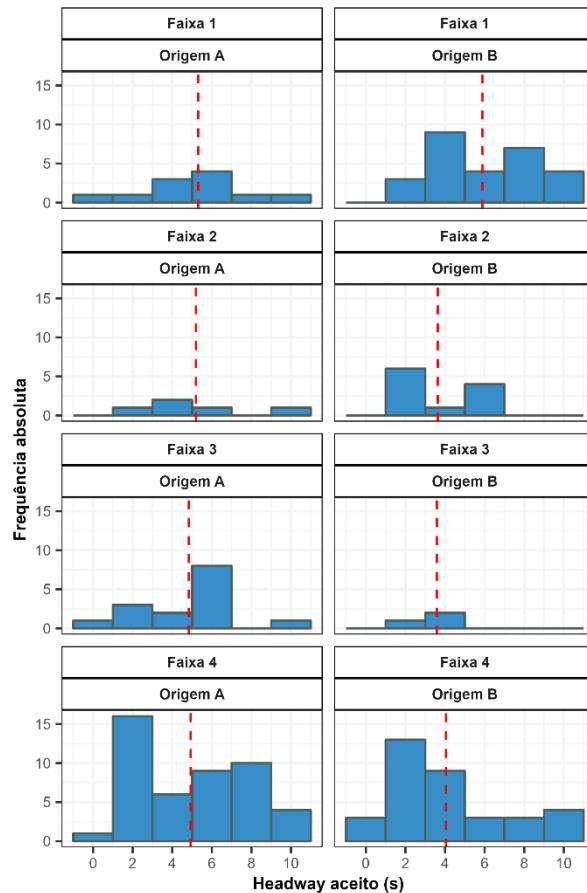
Tabela 22 - *Headways* mínimos aceitos (em s) pelos pedestres da origem B, por faixa veicular

Faixa	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
1	27	6	3	[5; 7]
2	11	4	2	[2; 5]
3	3	4	1	[1; 6]
4	35	4	3	[3; 5]
Total	76	5	3	[4; 5]

Fonte: elaborada pela autora

Nos histogramas dos *headways* mínimos aceitos por faixa veicular e origem do pedestre da Figura 47 nota-se que os pedestres da origem A aceitaram uma maior quantidade de *headways* de 6 s nas faixas de 1 a 3 e de 2 s na faixa 4, e que há tendência de maior variabilidade nos tamanhos desses *headways* mínimos aceitos, entre 0 s e 10 s. Os pedestres da origem B, por sua vez, aceitaram uma maior quantidade de *headways* entre 2 s e 4 s nas 4 faixas, com menor variabilidade de valores nas faixas 2 e 3.

Figura 47 - Histogramas dos *headways* mínimos aceitos (em s) pelos pedestres, por faixa veicular e por zona de origem do pedestre

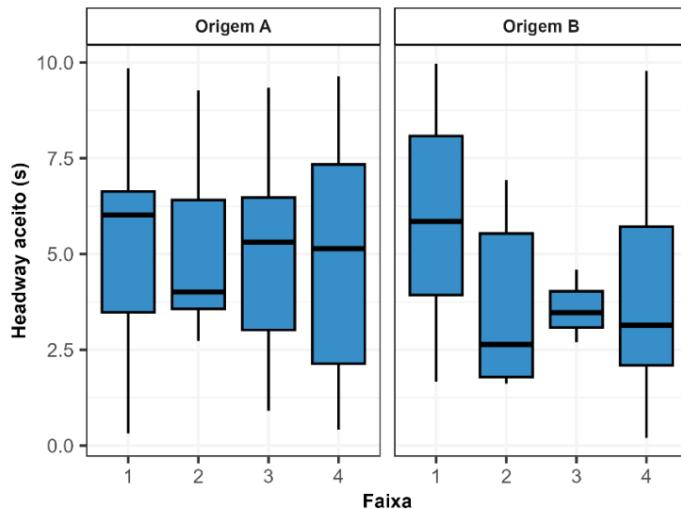


Fonte: elaborada pela autora

Os *boxplots* da Figura 48 apresentam os *headways* mínimos aceitos por faixa veicular e por origem do pedestre. Observa-se para os pedestres da origem A que a variabilidade dos *headways* aceitos é alta, sobretudo nas faixas 1, 3 e 4. A maioria desses pedestres aceitou *headways* entre 3 s e 6 s nas faixas de tráfego motorizado e entre 2,5 s e 7,5 s na ciclofaixa, com uma maior tendência aos *headways* menores terem sido aceitos na faixa 2, pois sua mediana é em torno de 4 s, enquanto as medianas das faixas 1, 3 e 4 se situam em cerca de 5 s e 6 s. O comportamento dos pedestres da origem B é similar na tendência de aceitação de

headways menores na faixa 2 (mediana de 2,5 s), mas aparentemente as medianas são menores em todas as faixas se comparado com a origem A. As faixas 1 e 2 mostram que a maioria dos *headways* mínimos aceitos se encontra em um intervalo maior do que as mesmas faixas da origem A, ao contrário das faixas 3 e 4, com valores mais concentrados em intervalos menores.

Figura 48 - Boxplots dos *headways* mínimos aceitos por faixa veicular e por zona de origem do pedestre



Fonte: elaborada pela autora

Analizando as velocidades dos veículos referentes aos veículos dos *headways* mínimos aceitos, por tipo de veículo e por origem do pedestre, da Tabela 23 e Tabela 24, as velocidades médias calculadas para o total foram semelhantes e baixas, de 13 km/h (origem A) e 12 km/h (origem B), variando entre 11 km/h e 15 km/h de acordo com os limites mínimos e máximos dos Intervalos de Confiança. Novamente, as bicicletas mostram as menores velocidades médias (9 km/h), o que oferece menor risco e pode ter influenciado no maior número de *headways* mínimos aceitos pelos pedestres de ambas as origens, mas também há a possibilidade do já mencionado desrespeito dos ciclistas ao semáforo vermelho.

É interessante destacar as velocidades médias dos carros e das motocicletas cujos *headways* mínimos foram aceitos pelos pedestres da origem A, de 27 km/h e 23 km/h, mais altas do que as mesmas velocidades na tabela da origem B, de 17 km/h e 15 km/h, o que pode sugerir travessias mais arriscadas por parte dos pedestres da origem A, pois os Intervalos de Confiança mostraram valores entre 13 km/h e 41 km/h, indicando que alguns dos *headways* mínimos aceitos estão relacionados a veículos que trafegavam no verde. Por outro lado, os pedestres da origem B aceitaram *headways* mínimos de ônibus e uma quantidade de *headways* mínimos de carros maior do que de motocicletas, todos com velocidades mais baixas, então

esses pedestres podem ter apresentado uma tendência maior de atravessar no vermelho para os veículos, em maior segurança. Reforça-se que todas as hipóteses causais aqui levantadas devem ser investigadas com amostras maiores.

Tabela 23 - Velocidades (em km/h) dos veículos dos *headways* mínimos aceitos pelos pedestres da origem A, por tipo de veículo

Tipo de veículo	N	Média (km/h)	Desvio-padrão (km/h)	IC (95%) (km/h)
Bicicleta	55	9	3	[8; 10]
Ônibus	-	-	-	-
Carro	4	27	9	[13; 41]
Motocicleta	16	23	18	[14; 32]
Caminhão	-	-	-	-
Todos os veículos	75	13	11	[11; 15]

Fonte: elaborada pela autora

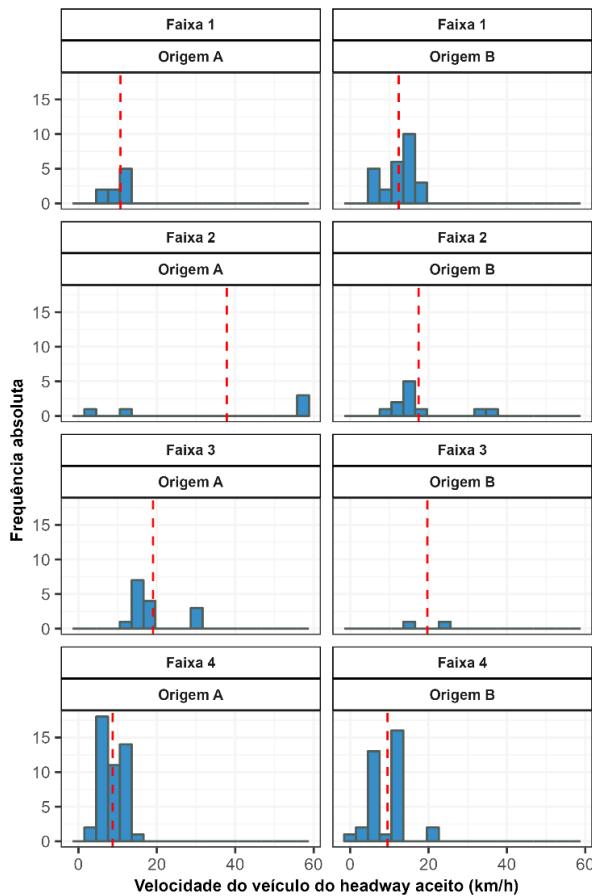
Tabela 24 - Velocidades (em km/h) dos veículos dos *headways* mínimos aceitos pelos pedestres da origem B, por tipo de veículo

Tipo de veículo	N	Média (km/h)	Desvio-padrão (km/h)	IC (95%) (km/h)
Bicicleta	40	9	5	[8; 11]
Ônibus	3	10	2	[5; 15]
Carro	19	17	7	[13; 20]
Motocicleta	12	15	2	[14; 16]
Caminhão	-	-	-	-
Todos os veículos	74	12	6	[11; 13]

Fonte: elaborada pela autora

Os histogramas das velocidades por faixa e origem do pedestre da Figura 49 apontam que as velocidades médias dos veículos referentes aos *headways* mínimos aceitos são semelhantes comparando cada faixa por origem, menos na faixa 2, na qual os pedestres da origem A aceitaram *headways* de veículos a uma velocidade média de 40 km/h, e os da origem B aceitaram *headways* de veículos a uma velocidade média de 20 km/h. Outro aspecto a se destacar é a concentração de observações de até 20 km/h em todas as faixas, exceto na faixa 2 referente aos pedestres da origem A, pois há registros de aceitação de *headways* de veículos a velocidades de 60 km/h, o que aumentou a velocidade média associada a *headways* mínimos aceitos nessa faixa.. Também há registros na faixa 2 da origem B que se encontram muito acima da média e destoam do restante, mostrando velocidades em torno de 40 km/h, e na faixa 3 da origem A, com velocidades próximas de 30 km/h.

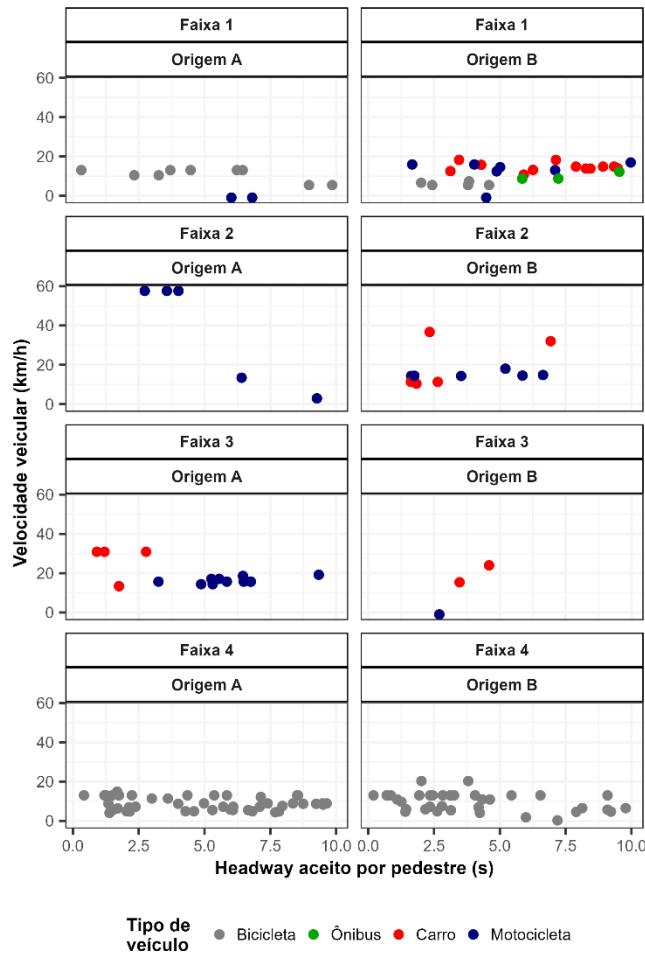
Figura 49 - Histogramas de frequência das velocidades (em km/h) dos veículos de *headways* mínimos aceitos pelos pedestres, por faixa veicular e por zona de origem do pedestre



Fonte: elaborada pela autora

Os gráficos da relação entre os *headways* mínimos aceitos pelos pedestres e as velocidades dos veículos desses *headways* por tipo de veículo, faixa e origem do pedestre, na Figura 50, mostram semelhanças com os gráficos da Figura 44. Quase todos os pedestres das duas origens aceitaram os *headways* mínimos de veículos com velocidades de até 20 km/h, o que sugere a aceitação dos *headways* no semáforo vermelho para os veículos, pois essas são as velocidades registradas quando os veículos passaram pela faixa de pedestres após o semáforo ficar verde. As exceções, que podem indicar aceitação de *headways* no verde dos veículos, são os 3 pedestres da origem A que aceitaram *headways* de motocicletas a 60 km/h na faixa 2, os 3 pedestres também da origem A que aceitaram *headways* de carros a cerca de 30 km/h na faixa 3 e os 2 pedestres da origem B que aceitaram *headways* de carros a 40 km/h na faixa 2.

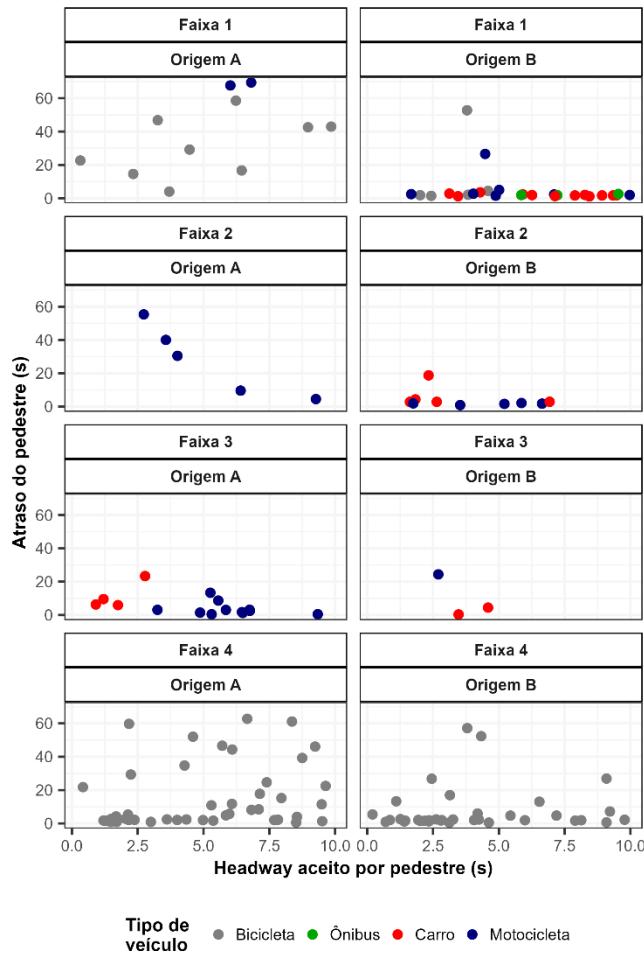
Figura 50 - Relação entre os *headways* mínimos aceitos (em s) e as velocidades veiculares (em km/h), por tipo de veículo, faixa veicular e zona de origem do pedestre



Fonte: elaborada pela autora

Por fim, ao averiguar a relação entre os *headways* mínimos aceitos pelos pedestres e seu atraso por tipo de veículo, faixa veicular e origem do pedestre, na Figura 51, é notado padrão semelhante ao gráfico de todos os *headways* aceitos (Figura 46), mas com menos observações, já que nesse caso há somente um *headway* por pedestre. Os *headways* mínimos aceitos foram, em sua maioria, de bicicletas e motocicletas, principalmente pelos pedestres da origem A, talvez por serem veículos de menor porte, por terem passado no vermelho enquanto os pedestres atravessavam a via, ou por terem saído do repouso logo após o pedestre ter atravessado. A maioria dos pedestres da origem B não esperaram ou esperaram pouco para realizar travessia, o que pode ter sido por chegada na interseção nos momentos finais de semáforo vermelho para os veículos ou chegada e travessia imediata no verde, enquanto grande parte dos que chegaram na origem A esperaram mais tempo até o vermelho para os veículos ou ficaram impacientes nessa espera e atravessaram.

Figura 51 - Relação entre os *headways* mínimos aceitos e os atrasos dos pedestres (em s) por tipo de veículo, faixa veicular e zona de origem do pedestre



Fonte: elaborada pela autora

4.4.3 Headways aceitos no vermelho dos pedestres

A partir do vídeo, foram identificadas duas durações de ciclos semafóricos, uma nas 3 primeiras horas com tempo de vermelho para o pedestre de 70 s, e uma nas 2 horas finais com tempo de vermelho para o pedestre de 80 s, ambos com vermelho piscante de 7 s. Ainda, foram coletadas 45 observações de *headways* aceitos de até 10 s no vermelho, referentes a 36 pedestres: 9 na faixa 1, 12 na faixa 2, 7 na faixa 3 e 17 na faixa 4. Como foram considerados para a análise os *headways* aceitos de até 10 s, a quantidade é diferente para cada faixa.

Os Intervalos de Confiança dos *headways* aceitos pelos pedestres no vermelho por origem e por faixa veicular são apresentados na Tabela 25 e na Tabela 26. As estatísticas dos *headways* aceitos considerando todas as faixas são praticamente iguais entre as duas origens, mas há mais *headways* aceitos no vermelho por parte dos pedestres da origem A, que também

mostram o menor valor médio e o menor desvio-padrão (2 s e 1 s), na faixa 3. Os pedestres da origem A aceitaram, em média, *headways* menores no vermelho do que os pedestres da origem B nas faixas 3 e 4, e os da origem B aceitaram *headways* menores no vermelho nas faixas 1 e 2, e ambas as situações são relacionadas às faixas mais distantes de suas respectivas origens. Como as amostras por faixa são pequenas, os Intervalos de Confiança tendem a ser mais largos, ou seja, menos precisos.

Tabela 25 - *Headways* aceitos no vermelho (em s) pelos pedestres da origem A, por faixa veicular

Faixa	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
1	6	5	3	[2; 8]
2	7	5	2	[3; 7]
3	4	2	1	[0; 3]
4	12	5	3	[3; 8]
Total	29	5	3	[4; 6]

Fonte: elaborada pela autora

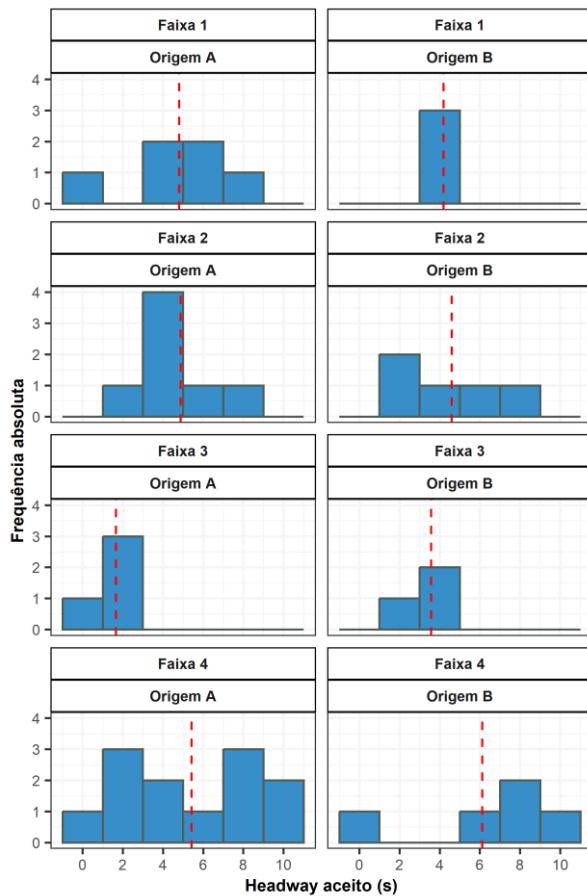
Tabela 26 - *Headways* aceitos no vermelho (em s) pelos pedestres da origem B, por faixa veicular

Faixa	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
1	3	4	1	[3; 5]
2	5	4	3	[2; 8]
3	3	4	1	[1; 6]
4	5	6	3	[2; 10]
Total	16	5	2	[4; 6]

Fonte: elaborada pela autora

Os histogramas da Figura 52 mostram que os *headways* médios aceitos no vermelho por faixa e por origem variam entre 4 s e 6 s, com exceção da faixa 3 da origem A, de 2 s, e que há mais *headways* aceitos pelos pedestres da origem A. Em geral, a maioria dos pedestres das duas origens aceitaram *headways* entre 1 s e 5 s, menos os na faixa 1, que variam entre 3 s e 7 s, talvez por ser a faixa mais próxima e ter um maior tráfego de ônibus. A faixa 4 apresenta comportamento diferente, com maior variabilidade dos dados e alta incidência de aceitação de *headways* em torno de 8 s.

Figura 52 - Histogramas dos *headways* aceitos no vermelho (em s) pelos pedestres, por faixa veicular e por zona de origem do pedestre



Fonte: elaborada pela autora

As velocidades dos veículos referentes aos veículos dos *headways* aceitos no vermelho, por tipo de veículo e por origem do pedestre, expostas na Tabela 27 e na Tabela 28, resultaram no mesmo valor médio (20 km/h) para os pedestres das duas origens, e não houve travessias no vermelho quando os veículos próximos eram ônibus e caminhões, ou seja, veículos pesados. Por outro lado, os pedestres atravessaram no vermelho predominantemente quando os veículos próximos eram bicicletas a velocidades de cerca de 10 km/h e carros a velocidades médias de cerca de 22 km/h. Também há registros de aceitação de *headways* de motocicletas acima de 40 km/h, chegando a mais de 50 km/h para os pedestres da origem A, mas em número bem menor. Então, os resultados sugerem que os pedestres preferiram atravessar no vermelho com a iminência da chegada de veículos a velocidades menores, mais ainda quando o veículo era de pequeno porte, como é o caso das bicicletas.

Tabela 27 - Velocidades (em km/h) dos veículos dos *headways* aceitos no vermelho pelos pedestres da origem A, por tipo de veículo

Tipo de veículo	N	Média (km/h)	Desvio-padrão (km/h)	IC (95%) (km/h)
Bicicleta	17	11	3	[9; 12]
Ônibus	-	-	-	-
Carro	8	22	8	[16; 28]
Motocicleta	4	53	10	[37; 69]
Caminhão	-	-	-	-
Todos os veículos	29	20	15	[14; 25]

Fonte: elaborada pela autora

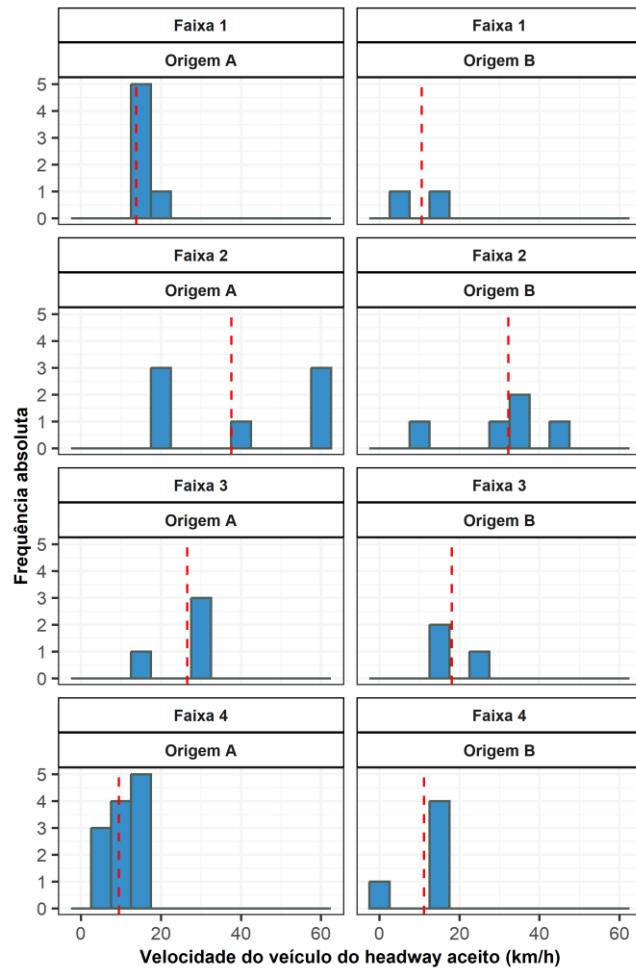
Tabela 28 - Velocidades (em km/h) dos veículos dos *headways* aceitos no vermelho pelos pedestres da origem B, por tipo de veículo

Tipo de veículo	N	Média (km/h)	Desvio-padrão (km/h)	IC (95%) (km/h)
Bicicleta	6	10	6	[4; 17]
Ônibus	-	-	-	-
Carro	8	23	11	[14; 32]
Motocicleta	1	44	-	-
Caminhão	-	-	-	-
Todos os veículos	15	20	13	[12; 27]

Fonte: elaborada pela autora

Os histogramas das velocidades por faixa veicular e origem do pedestre da Figura 53 apontam que os pedestres das duas origens aceitaram *headways* de veículos com velocidades médias similares nas faixas 1 (15 km/h), 2 (35 km/h) e 4 (10 km/h), e na faixa 3 as velocidades dos veículos que tiveram seus *headways* aceitos por pedestres da origem A são maiores do que as referentes aos pedestres da origem B (30 km/h e 20 km/h, respectivamente). A maior variabilidade de velocidades é vista na faixa 2, chegando a cerca de 60 km/h no gráfico da origem A, o que significa que houve pedestres que atravessaram no vermelho e aceitaram *headways* de veículos a essa velocidade. Na faixa 3, também há predominância de comportamentos de risco por parte dos pedestres da origem A, dos quais a maioria aceitou *headways* de veículos com velocidades próximas a 40 km/h, enquanto os da origem B aceitaram em sua maioria *headways* de veículos a menos de 20 km/h. Nas outras faixas, há predominância de pedestres que aceitaram *headways* no vermelho de veículos a no máximo 20 km/h.

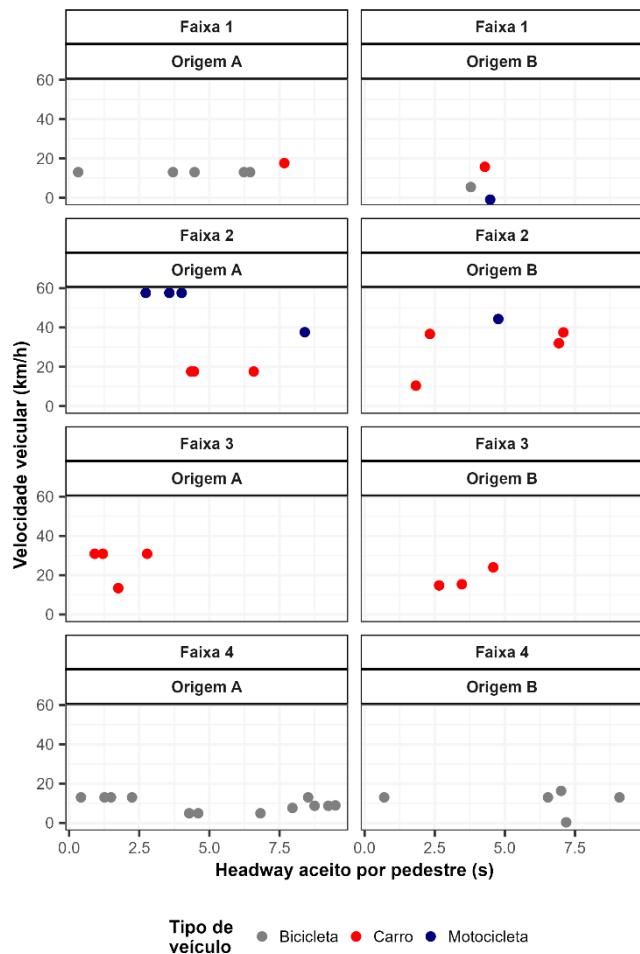
Figura 53 - Histogramas das velocidades (em km/h) dos veículos de *headways* aceitos no vermelho pelos pedestres, por faixa veicular e por zona de origem do pedestre



Fonte: elaborada pela autora

Os gráficos da relação entre os *headways* aceitos no vermelho e as velocidades dos veículos referentes a esses *headways* por tipo de veículo, faixa veicular e área de origem do pedestre, na Figura 54, mostram que nem todos os veículos a velocidades baixas estavam parados no semáforo quando houve travessia de pedestres, principalmente nas faixas 1 e 4, que apresentam veículos a velocidades máximas de 20 km/h. A motocicleta com velocidade de 0 km/h e *headway* aceito de 5 s é a que teve sua velocidade registrada como -1 por problemas em seu rastreio, sendo mantida no gráfico para análise de seu *headway*. As maiores velocidades dos veículos cujos *headways* foram aceitos no vermelho ocorreram nas faixas 2 e 3, com destaque para os pedestres da origem A que aceitaram *headways* de menos de 5 s de motocicletas que estavam a velocidades de 60 km/h, havendo também aceitação de *headways* de carros a velocidades próximas de 40 km/h.

Figura 54 - Relação entre os *headways* aceitos (em s) e as velocidades veiculares (em km/h), por tipo de veículo, faixa veicular e zona de origem do pedestre



Fonte: elaborada pela autora

Os atrasos dos pedestres que atravessaram no vermelho têm seus Intervalos de Confiança exibidos na Tabela 29. Em comparação aos *headways* aceitos considerando todas as travessias no vermelho e no verde (Tabela 20), houve um aumento na média das origens A e B e no tamanho do Intervalo de Confiança, já que os limites superiores se mostram mais de 10 s maiores. Isso indica que os pedestres que se arriscaram no vermelho foram os que esperaram mais. Também é possível levantar a hipótese de que os pedestres da origem B demonstraram mais impaciência para atravessar a via do que os da origem A.

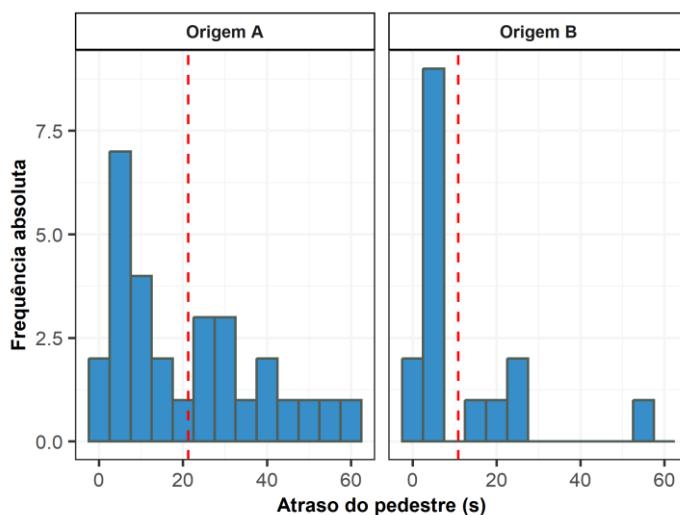
Tabela 29 - Atrasos (em s) dos pedestres, por área de origem

Origem do pedestre	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
A	24	23	18	[16; 31]
B	12	13	16	[3; 23]
Total	36	20	18	[14; 26]

Fonte: elaborada pela autora

Tal comportamento também pode ser visto nos histogramas da Figura 55, que mostra os atrasos médios em torno de 20 s para os pedestres da origem A e de pouco mais de 10 s para os pedestres da origem B. Ainda, os atrasos concentram-se nos intervalos abaixo das médias, e a maior frequência é de atrasos entre 2,5 s e 7,5 s. Há variabilidade dos atrasos para os pedestres das duas origens, mas a distribuição apresenta descontinuidades na origem B, predominando os valores até 35 s, ao contrário da origem A, que mostra observações em todos os intervalos.

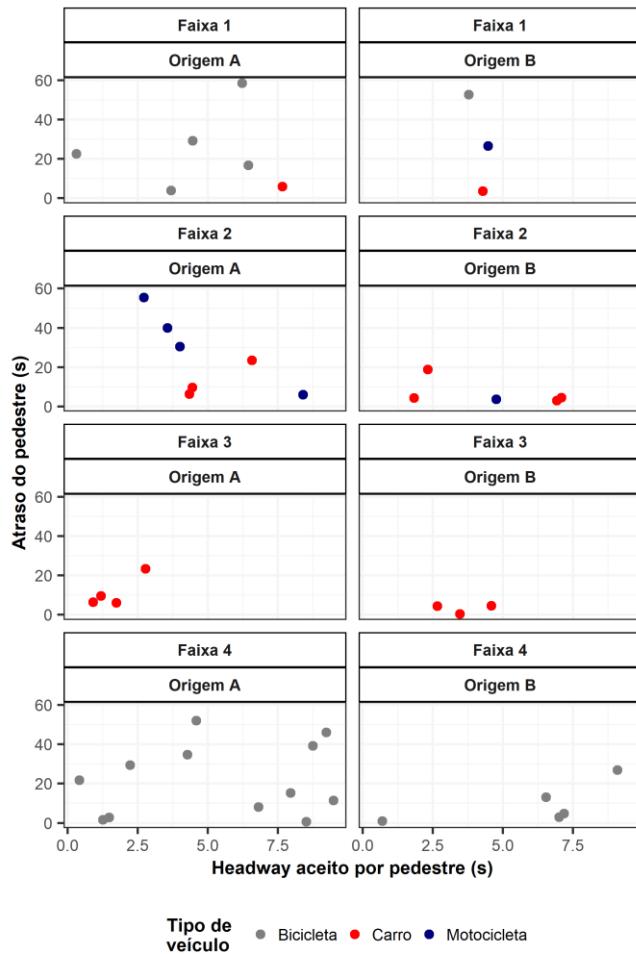
Figura 55 - Histogramas dos atrasos (em s) dos pedestres, por origem do pedestre



Fonte: elaborada pela autora

Ao explorar a relação entre os *headways* aceitos no vermelho pelos pedestres e seu atraso, na Figura 56, há mais *headways* aceitos pelos pedestres da origem A nas 4 faixas, porém sem um padrão definido entre elas. Na faixa 1, por exemplo, há diferentes tempos de espera, chegando a 60 s, e há predominância de aceitação de *headways* pelos pedestres da origem A quando os veículos eram bicicletas, e os da origem B mostram equilíbrio no tipo de veículo. Já em relação à faixa 2, os pedestres da origem B aceitaram *headways* de carros e motocicletas após esperarem até 20 s, enquanto os da origem A esperaram mais tempo, e na faixa 3 os pedestres de ambas as origens esperaram até cerca de 20 s, mas os da origem A aceitaram *headways* menores de 2,5 s, ao passo que os da origem B aceitaram *headways* entre 2,5 s e 5 s. Por fim, na faixa 4, há divergência nos *headways* aceitos e nos atrasos dos pedestres da origem A, mas os da origem B esperaram 20 s ou menos e aceitaram *headways* de 7,5 s ou maiores.

Figura 56 - Relação entre os *headways* aceitos no vermelho e os atrasos dos pedestres (em s), por tipo de veículo, faixa veicular e zona de origem do pedestre



Fonte: elaborada pela autora

4.4.4 Headways mínimos aceitos no vermelho dos pedestres

Para a amostra de 36 *headways* mínimos aceitos no vermelho (um por pedestre), foram calculados os Intervalos de Confiança a 95% exibidos na Tabela 30 e Tabela 31, por faixa e área de origem do pedestre. Ressalta-se nessas tabelas que as amostras são pequenas, ou seja, mais horas de observação seriam necessárias para permitir análises robustas. Em geral, os *headways* mínimos aceitos pelos pedestres da origem A são em maior quantidade e de durações iguais (faixas 1 e 2) ou menores (faixas 3, 4 e total) do que os aceitos pelos pedestres da origem B. Além disso, para os pedestres da origem A há uma diminuição no valor do *headway* médio da faixa 1, mais próxima, à faixa 3, mais distante, que apresenta uma média de apenas 2 s. Os Intervalos de Confiança dos *headways* aceitos pelos pedestres no vermelho da origem B aparecem ser mais largos do que os dos pedestres da origem A, com exceção da faixa 1.

Tabela 30 - *Headways* mínimos aceitos no vermelho (em s) pelos pedestres da origem A, por faixa veicular

Faixa	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
1	5	4	3	[1; 7]
2	3	3	1	[2; 5]
3	4	2	1	[0; 3]
4	12	5	3	[3; 8]
Total	24	4	3	[3; 6]

Fonte: elaborada pela autora

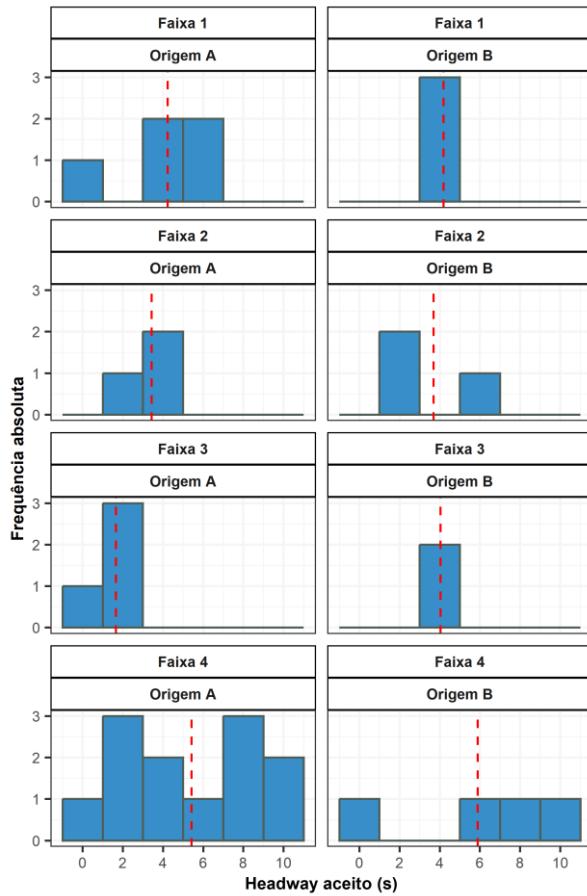
Tabela 31 - *Headways* mínimos aceitos no vermelho (em s) pelos pedestres da origem B, por faixa veicular

Faixa	N	Média (s)	Desvio-padrão (s)	IC (95%) (s)
1	3	4	0	[3; 5]
2	3	3	3	[0; 11]
3	2	4	1	[0; 11]
4	4	6	4	[0; 12]
Total	12	5	3	[3; 6]

Fonte: elaborada pela autora

Tais comportamentos são confirmados pelos histogramas da Figura 57, nos quais as médias dos *headways* mínimos aceitos pelos pedestres da origem A são menores do que os aceitos pelos pedestres da origem B. As maiores frequências de *headways* mínimos aceitos pelos pedestres da origem A foram entre 3 s e 7 s na faixa 1, entre 3 s e 5 s na faixa 2 e entre 1 s e 3 s na faixa 3, já os pedestres da origem B aceitaram mais *headways* entre 3 s e 5 s na faixa 1, entre 1 s e 3 s na faixa 2 e entre 3 s e 5 s na faixa 3. A faixa 4 mostra comportamentos distintos das outras faixas, por apresentar maior variabilidade nos resultados.

Figura 57 - Histogramas dos *headways* mínimos aceitos no vermelho (em segundos) pelos pedestres, por faixa veicular e por zona de origem do pedestre



Fonte: elaborada pela autora

Na Tabela 32 e Tabela 33 são mostrados os Intervalos de Confiança das velocidades dos veículos dos *headways* mínimos aceitos no vermelho pelos pedestres, por tipo de veículo e origem do pedestre. Os pedestres da origem A aceitaram, em média, *headways* de veículos com velocidades maiores do que os pedestres da origem B, incluindo 3 motocicletas a quase 60 km/h, sendo a classe veicular com o menor número de *headways* mínimos aceitos no vermelho. A maior quantidade de *headways* aceitos pelos pedestres da origem A foi de bicicletas, as quais apresentam a menor velocidade média, e na origem B aceitou-se mais *headways* de carros e bicicletas a velocidades relativamente baixas, o que pode indicar que esse é um critério de decisão dos pedestres em atravessar no vermelho. Vale salientar que houve uma motocicleta cujo *headway* foi aceito por um pedestre da origem B, mas sua velocidade não foi corretamente extraída por problemas no rastreio, sendo descartada para cálculo dos ICs.

Tabela 32 - Velocidades (em km/h) dos veículos dos *headways* mínimos aceitos no vermelho pelos pedestres da origem A, por tipo de veículo

Tipo de veículo	N	Média (km/h)	Desvio-padrão (km/h)	IC (95%) (km/h)
Bicicleta	17	11	3	[9; 12]
Ônibus	-	-	-	-
Carro	4	27	9	[13; 40]
Motocicleta	3	58	0	[58; 58]
Caminhão	-	-	-	-
Todos os veículos	24	19	17	[12; 26]

Fonte: elaborada pela autora

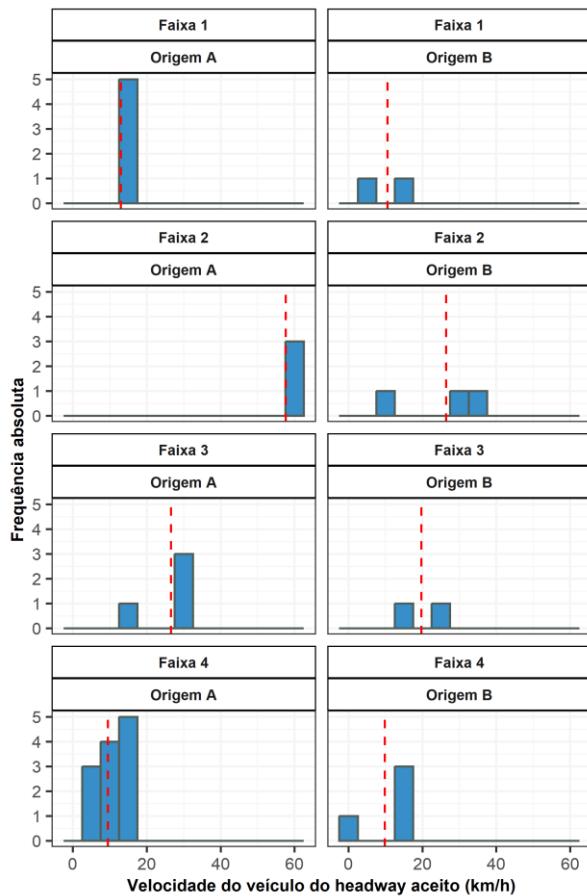
Tabela 33 - Velocidades (em km/h) dos veículos dos *headways* mínimos aceitos no vermelho pelos pedestres da origem B, por tipo de veículo

Tipo de veículo	N	Média (km/h)	Desvio-padrão (km/h)	IC (95%) (km/h)
Bicicleta	5	9	6	[2; 16]
Ônibus	-	-	-	-
Carro	6	22	10	[12; 33]
Motocicleta	-	-	-	-
Caminhão	-	-	-	-
Todos os veículos	11	16	11	[9; 24]

Fonte: elaborada pela autora

Nos histogramas da Figura 58, as velocidades médias dos veículos dos *headways* mínimos aceitos no vermelho pelos pedestres da origem A mostram-se maiores que as dos veículos dos *headways* aceitos pelos pedestres da origem B nas 3 faixas de tráfego motorizado e semelhantes na faixa 4, e há mais observações nos gráficos referentes à origem A. Na faixa 1, houve mais pedestres aceitando *headways* de veículos no intervalo entre 12,5 km/h e 17,5 km/h na origem A e entre 2,5 km/h e 17,5 km/h na origem B. Já na faixa 2, os pedestres da origem A aceitaram mais *headways* de veículos no intervalo entre 57,5 km/h e 62,5 km/h e os da origem B aceitaram em sua maioria *headways* de veículos a velocidades abaixo de 40 km/h. Na faixa 3, as maiores frequências se encontram nas faixas de velocidade menores que 40 km/h para ambas as origens, e na faixa 4 as velocidades mais frequentes registradas na aceitação de *headways* mínimos no vermelho foram no intervalo entre 12,5 km/h e 17,5 km/h.

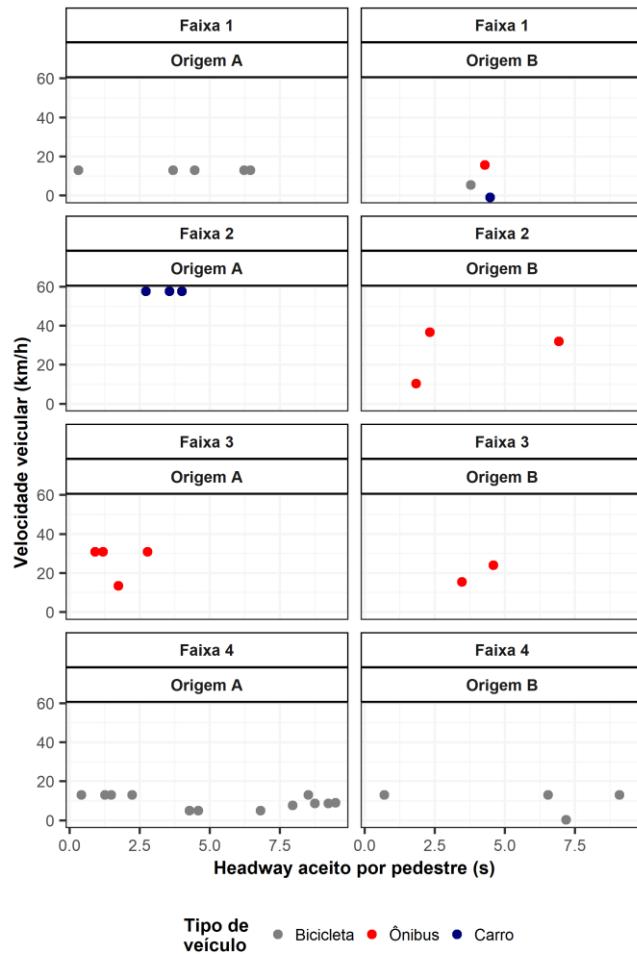
Figura 58 - Histogramas das velocidades (em km/h) dos veículos dos *headways* mínimos aceitos no vermelho pelos pedestres, por faixa veicular e por origem do pedestre



Fonte: elaborada pela autora

A Figura 59 expõe a relação entre os *headways* mínimos aceitos no vermelho e as velocidades dos veículos referentes a eles. Os *headways* mínimos aceitos no vermelho pelos pedestres foram, em sua maioria, de veículos a velocidades máximas de 20 km/h, pois houve maior incidência de *headways* mínimos aceitos de bicicletas nas faixas 1 e 4. Analisando as faixas 2 e 3, os pedestres da origem A aceitaram *headways* mínimos de motocicletas a 60 km/h na faixa 2 e de carros a velocidades de cerca de 30 km/h na faixa 3, e os pedestres da origem B aceitaram *headways* mínimos de carros a 40 km/h na faixa 2 e de carros a velocidades próximas de 20 km/h na faixa 3. Isso sinaliza que os pedestres da origem A aceitaram *headways* de veículos a velocidades maiores, e esses *headways* mínimos aceitos foram em geral menores que os aceitos pelos da origem B.

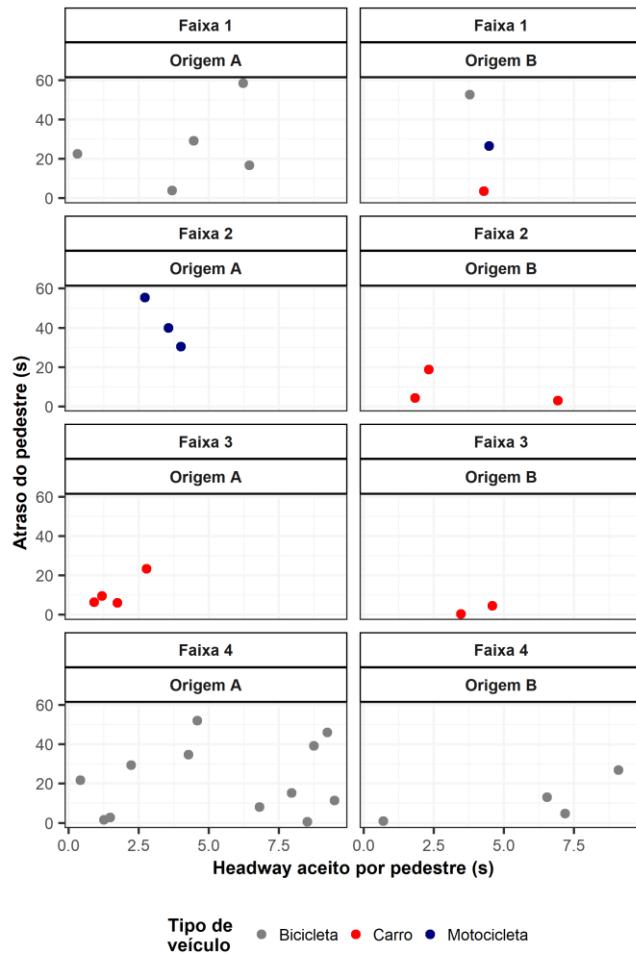
Figura 59 - Relação entre os *headways* mínimos aceitos no vermelho (em s) e as velocidades veiculares (em km/h), por tipo de veículo, faixa veicular e origem do pedestre



Fonte: elaborada pela autora

Por último, os gráficos da relação entre os *headways* mínimos aceitos no vermelho e os atrasos dos pedestres mostram que os veículos mais recorrentes nesse cenário de aceitação foram carros e bicicletas, como pode ser visto na Figura 60. Tais veículos tiveram predominantemente *headways* mínimos aceitos no vermelho de 2,5 s ou menos, chegando a menos de 1 s, principalmente pedestres da origem A, o que pode ser uma situação de extremo risco para os pedestres dependendo do veículo. Houve também aceitação de *headways* mínimos entre 2,5 s e 5 s referentes a motocicletas, e *headways* de carros e bicicletas de mais de 5 s, chegando a mais de 7,5 s para as bicicletas da faixa 4. Em relação aos atrasos, observa-se que, em geral, os pedestres da origem B esperaram até 20 s, menos tempo do que os pedestres da origem A, enquanto estes mostram esperas acima de 40 s, chegando a até 60 s. Por outro lado, os pedestres da origem B apresentam ter atravessado a via no vermelho quando os veículos estavam mais distantes na maioria das situações de comparação entre faixas.

Figura 60 - Relação entre os *headways* mínimos aceitos no vermelho e os atrasos dos pedestres (em s) por tipo de veículo, faixa veicular e origem do pedestre



Fonte: elaborada pela autora

Em resumo, as bicicletas foram os veículos com mais *headways* aceitos, seguido de carros e motocicletas. Os pedestres da origem A aceitaram mais *headways*, de tamanho menor e de veículos a velocidades maiores do que os da origem B. Por outro lado, os pedestres da origem B esperaram menos tempo para realizar travessia em comparação com os da origem A.

Do total de 723 pedestres rastreados realizando travessia no vídeo da Av. Antônio Sales, apenas 36, ou 5%, atravessaram no vermelho aceitando *headways* menores de 10 s. Portanto, nesse local e horários, o número de pedestres que se arriscou de alguma forma para atravessar a via é muito pequeno, de forma que não foi possível estimar, estatisticamente, o efeito dos atrasos dos pedestres e das velocidades veiculares na aceitação dos *headways* no vermelho. Isso pode ter ocorrido devido ao fluxo veicular que não permite tantas aceitações de *headways*, ou pelo tempo de vermelho que não é considerado tão longo, ou mesmo pelos pedestres terem sido conservadores. Dessa forma, as análises realizadas aqui são apenas de teor

exploratório, sendo recomendado aplicar a ferramenta em vídeos atualizados da mesma interseção por mais tempo, gerando assim amostras maiores, ou em vídeos de interseções diferentes, para verificação das semelhanças e diferenças no comportamento dos pedestres em situações distintas.

5 CONCLUSÕES E RECOMENDAÇÕES PARA TRABALHOS FUTUROS

A presente dissertação teve como objetivo customizar e aplicar uma ferramenta automatizada para coletar variáveis importantes em estudos de travessias de pedestres em interseções semaforizadas. Para atingi-lo, foram propostos três objetivos específicos: definir as variáveis importantes para a compreensão do fenômeno de aceitação de *headways* pelos pedestres, calibrar e validar uma ferramenta de coleta automática de variáveis relacionadas ao processo de aceitação de *headways* pelos pedestres e coletar e explorar dados de variáveis relativas ao processo de aceitação de *headways* em travessias semaforizadas.

A primeira etapa foi definir as variáveis relacionadas ao processo de aceitação dos *headways*, com base na revisão da literatura existente sobre o tema. Assim, além dos *headways* veiculares, o atraso dos pedestres, o fluxo veicular, o tipo de veículo, a velocidade veicular e o número de faixas da via foram as variáveis consideradas.

Para coleta dessas variáveis, foram utilizadas as ferramentas YOLOv7 (WANG *et al.*, 2022) para detecção e StrongSORT (DU *et al.*, 2023) para rastreio dos veículos e pedestres no vídeo escolhido para aplicação, que foi o da aproximação da Av. Antônio Sales na interseção com a Av. Desembargador Moreira, por atender aos critérios de número de faixas, fluxo veicular e posicionamento da câmera.

Antes da aplicação da ferramenta, foi realizado um treinamento usando imagens rotuladas de outros vídeos de interseções semaforizadas de Fortaleza para aprendizado do modelo. O treinamento resultou em um mAP de validação de 94%, e um mAP de teste de quase 90%. Contudo, houve incidência de falsos positivos para caminhões, que tiveram precisão de acertos de 51% e AP de 76%. É possível retreinar o modelo com novas imagens dessa e de outras classes de menor proporção (como bicicletas), o que aumentaria a precisão da ferramenta para essas classes. A Matriz de Confusão gerada a partir das imagens de teste, que compara a classificação manual dos objetos e a prevista pela ferramenta, mostrou valores acima de 85% de acertos para todas as classes, exceto para a de caminhões, que apresentou 70% de acertos. Baseado nesses resultados, pode-se considerar que a ferramenta foi bem treinada e está, em geral, calibrada para utilização.

Com a ferramenta treinada, foram coletados os fluxos veiculares por tipo de veículo e por faixa, as velocidades veiculares, os instantes de passagem dos veículos na seção definida para obtenção dos *headways*, o fluxo de pedestres, o início da espera, o fim da espera e o atraso dos pedestres por zona de origem, e o instante de passagem dos pedestres por cada faixa veicular.

Este trabalho partiu do trabalho de Castro Jr. *et al.* (2021) e propõe melhorias a partir dele, pois foi usada uma ferramenta de detecção e rastreio em uma versão mais atualizada, que coleta os *headways* por faixa, as velocidades veiculares, estima o atraso do pedestre de forma mais precisa, além de coletar o instante de passagem no centro de cada faixa.

No total, 9427 veículos foram rastreados no vídeo, em sua maioria carros e motocicletas, e 723 pedestres. Os *headways* contabilizados na aproximação têm grande amplitude, de até 600 s, mas praticamente todos foram de até 100 s. Em relação à velocidade, a média dos veículos foi de 28 km/h, com a velocidade mais baixa sendo a de bicicletas. O atraso médio dos pedestres foi de 18 s.

Para validar os resultados obtidos pela ferramenta automatizada, foi realizada uma comparação com os encontrados pela coleta manual com o *software RUBA (Road User Behaviour Analysis)* nos 10 primeiros minutos de vídeo. A coleta manual contabilizou 1,7% de veículos e 13,5% de pedestres a mais que a coleta automatizada, mas não houve erros de classificação, de acordo com a Matriz de Confusão obtida.

As médias das diferenças entre os instantes de passagem no início da faixa de pedestres, dos instantes de passagem no fim da faixa de pedestres e dos *headways* veiculares mostraram que não houve diferenças na coleta pelos dois métodos. Já a média das diferenças das velocidades foi de -0,9 s, sinalizando que as velocidades coletadas pelo RUBA foram maiores que as coletadas pela ferramenta automatizada. Além disso, resultados sugerem que a dispersão dos erros das velocidades entre os dois métodos aumenta com o aumento da velocidade coletada manualmente, o que pode ser investigado em trabalhos futuros com testes estatísticos de homoscedasticidade. Por fim, as médias das diferenças do início da espera, do fim da espera e dos atrasos dos pedestres foram de até 0,2 s nos ICs, consideradas baixas. Em resumo, os resultados das duas ferramentas foram similares, validando a ferramenta automatizada e possibilitando seu uso para análise dos *headways* aceitos, das velocidades veiculares e dos atrasos dos pedestres.

A última etapa foi a análise exploratória das variáveis relacionadas à aceitação dos *headways*, feita para os seguintes tipos de *headway*: *headways* aceitos em todas as faixas, *headway* mínimo aceito, *headways* aceitos no vermelho dos pedestres em todas as faixas e *headway* mínimo aceito no vermelho dos pedestres. Os *headways* aceitos foram adotados como a distância em segundos entre o pedestre e o veículo sucessor à sua passagem em cada faixa de tráfego, e foram considerados para análise apenas os *headways* aceitos de até 10 s, porque valores abaixo desse mostram que houve uma avaliação do pedestre em seu processo de decisão de travessia.

Foram extraídas 220 observações de *headways* aceitos, 153 *headways* mínimos aceitos, 45 *headways* aceitos no vermelho e apenas 36 *headways* mínimos aceitos no vermelho. Para os 4 tipos de análise, é notada uma repetição de comportamento por parte dos pedestres: semelhança nos valores médios de *headways* aceitos e de velocidades entre os pedestres das duas origens, com maior número de *headways* aceitos relacionados a bicicletas - que também mostraram as menores velocidades dentre todos os tipos de veículo -, provavelmente por oferecerem menor risco ou pelo desrespeito dos ciclistas ao semáforo. Outro aspecto importante é que os pedestres da origem B demonstraram mais impaciência e esperaram menos tempo para iniciar travessia do que os da origem A.

Destacando-se a relação entre os *headways* aceitos no vermelho, as velocidades dos veículos e os atrasos dos pedestres, os pedestres da origem A esperaram um tempo maior para atravessarem a via e aceitaram mais *headways* de tamanho menor e de veículos a velocidades maiores do que os da origem B, e as bicicletas foram os veículos com mais *headways* aceitos. Tais resultados dão a entender um comportamento arriscado por parte dos pedestres da origem A, mas é importante salientar o teor exploratório das análises, de forma que amostras maiores precisam ser coletadas e mais análises precisam ser realizadas para se chegar a uma conclusão.

O trabalho traz limitações que devem ser mitigadas em trabalhos futuros, como erros de identificação de trajetórias de alguns veículos como carros, motocicletas e principalmente bicicletas, o que prejudicou a obtenção de suas velocidades. Também foram notados problemas no rastreio dos pedestres, como oclusão e trocas de ID em situações de aglomeração nas áreas de espera e nos momentos de travessia, dificultando a coleta dos instantes de início de espera, dos instantes de fim de espera, dos atrasos e dos instantes de passagem de alguns pedestres por todas as faixas veiculares. Uma limitação importante encontrada foi o tamanho amostral para as análises exploratórias, impossibilitando estimar, estatisticamente, as relações entre as variáveis aqui exploradas, como o efeito do atraso dos pedestres na aceitação dos *headways* no vídeo da Av. Antônio Sales, pois apenas 36 pedestres de fato avaliaram os *headways* e atravessaram no vermelho.

Recomenda-se para trabalhos futuros, nesses casos, um aprimoramento da ferramenta de rastreio por meio de um novo treinamento com amostras mais refinadas e balanceadas ou ajuste de seus parâmetros, a utilização de vídeos de ângulos que diminuam a oclusão e a aplicação da ferramenta em novos vídeos da aproximação analisada nesta dissertação, para aumentar o tamanho amostral e possibilitar análises mais aprofundadas. Pode-se igualmente aplicar a ferramenta em vídeos de outras interseções semafORIZADAS com fluxo relevante de pedestres, para verificação do seu comportamento em outras situações.

É recomendado também analisar, além dos *headways* aceitos, os *headways* rejeitados pelos pedestres por faixa, por origem do pedestre e por tipo de veículo, obtendo-se também o máximo *headway* rejeitado por pedestre. Outra recomendação é desenvolver um método de coleta dos tempos de início e fim de espera dos pedestres mais preciso do que a delimitação de áreas de espera nas calçadas, como por exemplo pela avaliação da velocidade dos pedestres em sua chegada próximo à interseção.

Por fim, sugere-se a elaboração, calibração e validação de modelos estatísticos de regressão, considerando variáveis além das já utilizadas, como o padrão de chegada dos veículos na interseção, para prever a relação entre os *headways* aceitos no vermelho pelos pedestres e seu atraso nas interseções semafORIZADAS de Fortaleza.

REFERÊNCIAS

- AFSHARI, A.; AYATI, E.; BARAKCHI, M. Evaluating the effects of external factors on pedestrian violations at signalized intersections (a case study of Mashhad, Iran). **IATSS Research**, 2021.
- ALOMARI, A. H.; KHEDAYWI, T. S.; SHDOOH, H. I. Investigation of pedestrian crossing behavior at signalized intersections in Jordan. *Advances in Transportation Studies: An International Journal*, n.59, p. 147-164, 2023.
- AL-QANESS, M. A. A. *et al.* An improved YOLO-based road traffic monitoring system. **Computing**, v. 103, n. 2, p. 211–230, 2021.
- ALVER, Y. *et al.* Evaluation of pedestrian critical gap and crossing speed at midblock crossing using image processing. **Accident Analysis & Prevention**, v. 156, p. 1-9, 2021.
- ANSARNIA, M. S. *et al.* Contextual Detection of Pedestrians and Vehicles in Orthophotography by Fusion of Deep Learning Algorithms. **Sensors**, v. 22, n. 4, p. 1381, 2022.
- ASHA, C. S.; NARASIMHADHAN, A. V. Vehicle Counting for Traffic Management System using YOLO and Correlation Filter. **IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)**, 2018.
- BANDEIRA, T. P. **A Method for Microscopic Modelling of Pedestrian Delay at Signalized Crossings**. 2019. 97 f. Dissertação (Mestrado em Engenharia de Transportes) - Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2019.
- BANDEIRA, T. P.; MARTIN, L. E.; CASTRO-NETO, M. M. A method for estimating pedestrian critical gap using microsimulation. **Revista Transportes**, v. 29, n. 1, p. 132-147, 2021.
- BATHIJA, A.; SHARMA, G. Visual Object Detection and Tracking using YOLO and SORT. **International Journal of Engineering Research**, v. 8, n. 11, p. 705-708, 2019.
- BENDAK, S. *et al.* Factors affecting pedestrian behaviors at signalized crosswalks: An empirical study. **Journal of Safety Research**, p. 269–275, 2021.
- BEWLEY, A. *et al.* Simple online and realtime tracking. In: IEEE Int.Conf. on Image Process (ICIP), 2016, p. 3464-3468.
- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. YOLOv4: optimal speed and accuracy of object detection. **ArXiv**, 2020.
- BROSSEAU, M. *et al.* The impact of waiting time and other factors on dangerous pedestrian crossings and violations at signalized intersections: A case study in Montreal. **Transportation Research Part F: Traffic Psychology and Behaviour**, [s. l.], v. 21, p. 159–172, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.trf.2013.09.010>>

CASTRO-JUNIOR, F. A. B.; CASTRO-NETO, M. M.; CUNTO, F. J. C. Análise do atraso e da brecha aceita dos pedestres em travessias semaforizadas: um estudo na cidade de Fortaleza utilizando técnicas de visão computacional baseadas em *deep learning*. In: Congresso de Pesquisa e Ensino em Transportes (ANPET), XXXV, 2021, Online. **Anais**. Online, 2021, p. 2470-2481.

CHANDRA, S.; RASTOGI, R.; DAS, V. R. Descriptive and parametric analysis of pedestrian gap acceptance in mixed traffic conditions. **KSCE Journal of Civil Engineering**, [s. l.], v. 18, n. 1, p. 284–293, 2014.

DEVORE, J. L. **Probabilidade e Estatística para Engenharia e Ciências**. São Paulo: Cengage Learning Edições Ltda., 2006.

DHOKE, A.; KUMAR, A.; GHOSH, I. Hazard-Based Duration Approach to Pedestrian Crossing Behavior at Signalized Intersections. **Transportation Research Record: Journal of the Transportation Research Board**, p. 1-14, 2021.

DIEPENDAELE, K. Non-compliance with pedestrian traffic lights in Belgian cities. **Transportation Research Part F: Traffic Psychology and Behaviour**, v. 67, p. 230–241, 2018.

DOMMES, A. *et al.* Red light violations by adult pedestrians and other safety-related behaviors at signalized crosswalks. **Accident Analysis & Prevention**, v. 80, p. 67–75, 2015.

DU, Y. *et al.* StrongSORT: Make DeepSORT Great Again. **IEEE Transactions on Multimedia**, 2023.

DUDUTA, N.; ZHANG, Q.; KRONEBERGER, M. Impact of Intersection Design on Pedestrians' Choice to Cross on Red. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2464, n. 1, p. 93–99, 2014.

GENC, B.; TUNC, H. Optimal training and test sets design for machine learning. **Turkish Journal of Electrical Engineering & Computer Sciences**, p. 1534–1545, 2019.

GUO, H. *et al.* Modeling Pedestrian Violation Behavior at Signalized Crosswalks in China: A Hazards-Based Duration Approach. **Traffic Injury Prevention**, v. 12, n. 1, p. 96–103, 2011.

HASHEMI, H.; BARGEOL, I.; HAMED, G. H. Using logistic regression and point-biserial correlation, an investigation of pedestrian violations and their opportunities to cross at signalized intersections. **IATSS Research**, v. 46, n. 3, p. 388–397, 2022.

IBADOV, S. *et al.* Algorithm for detecting violations of traffic rules based on computer vision approaches. **MATEC Web of Conferences**, v. 132, p. 1-4, 2017.

KADALI, B. R.; VEDAGIRI, P. Effect of Vehicular Lanes on Pedestrian Gap Acceptance Behaviour. **Procedia - Social and Behavioral Sciences**, v. 104, p. 678–687, 2013.

KARIMPOUR, A. *et al.* Estimating pedestrian delay at signalized intersections using high-resolution event-based data: a finite mixture modeling method. **Journal of Intelligent Transportation Systems**, v. 26, n. 5, p. 511–528, 2022.

- KHAN, S. D. *et al.* Estimating Speeds of Pedestrians in Real-World Using Computer Vision. Em: WĄS, J.; SIRAKOULIS, G. CH.; BANDINI, S. (Eds.). **Cellular Automata**. Lecture Notes in Computer Science. Cham: Springer International Publishing, 2014. v. 8751, p. 526–535, 2014.
- KOH, P. P.; WONG, Y. D. Gap acceptance of violators at signalised pedestrian crossings. **Accident Analysis and Prevention**, [s. l.], v. 62, p. 178–185, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.aap.2013.09.020>>
- KOLLURI, J.; DAS, R. Intelligent multimodal pedestrian detection using hybrid metaheuristic optimization with deep learning model. **Image and Vision Computing**, v. 131, p. 1-10, 2023.
- KUMAR, A.; GHOSH, I. Non-compliance behaviour of pedestrians and the associated conflicts at signalized intersections in India. **Safety Science**, v. 147, 2022.
- LEAL-TAIXÉ, L. *et al.* MOTChallenge 20115: Towards a Benchmark for Multi-Target Tracking. **ArXiv**, 2015.
- LIN, T.-Y. *et al.* Microsoft COCO: Common Objects in Context. **ArXiv**, 2015.
- LIN, J.-P.; SUN, M.-T. A YOLO-based Traffic Counting System. **Conference on Technologies and Applications of Artificial Intelligence (TAAI)**, p. 82-85, 2018.
- LIU, Y.-C.; TUNG, Y.-C. Risk analysis of pedestrians' road-crossing decisions: Effects of age, time gap, time of day, and vehicle speed. **Safety Science**, v. 63, p. 77–82, 2014.
- MA, Y.; LU, S.; ZHANG, Y. Analysis on Illegal Crossing Behavior of Pedestrians at Signalized Intersections Based on Bayesian Network. **Journal of Advanced Transportation**, v. 2020, p. 1–14, 2020.
- MARISAMYNATHAN, S.; VEDAGIRI, P. Modeling pedestrian delay at signalized intersection crosswalks under mixed traffic condition. **Procedia - Social and Behavioral Sciences**, v. 104, p. 708-717, 2013.
- MARISAMYNATHAN, S.; VEDAGIRI, P. Study on Pedestrian Crossing Behavior at Signalized Intersections. **CICTP 2014**, p. 2641-2652, 2014.
- MARISAMYNATHAN, S.; VEDAGIRI, P. Pedestrian perception-based level-of-service model at signalized intersection crosswalks. **Journal of Modern Transportation**, v. 27, n. 4, p. 266–281, 2019.
- MUKHERJEE, D.; MITRA, S. What affects pedestrian crossing difficulty at urban intersections in a developing country? **IATSS Research**, v. 46, n. 4, p. 586–601, 2022.
- NAG, D.; GOSWAMI, A. Comprehensive Pedestrian Level of Service Measure For Urban Footways Using Unsupervised Mining. **SSRN Electronic Journal**, 2022.
- NIKOLAOU, D. *et al.* Pedestrian safety attitudes and self-declared behaviour in Greece. **IATSS Research**, 2022.

NOH, B. *et al.* Vision-Based Pedestrian's Crossing Risky Behavior Extraction and Analysis for Intelligent Mobility Safety System. **Sensors**, v. 22, n. 9, p. 3451, 2022.

ONELCIN, P.; ALVER, Y. Illegal crossing behavior of pedestrians at signalized intersections: Factors affecting the gap acceptance. **Transportation Research Part F: Traffic Psychology and Behaviour**, [s.l.], v. 31, p. 124–132, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.trf.2015.04.007>>

ONELCIN, P.; ALVER, Y. The crossing speed and safety margin of pedestrians at signalized intersections. **Transportation Research Procedia**, [s. l.], v. 22, n. 2016, p. 3–12, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.trpro.2017.03.002>>

PADILLA, R.; NETTO, S. L.; DA SILVA, E. A. B. A Survey on Performance Metrics for Object-Detection Algorithms. In: International Conference on Systems, Signals, and Image Processing (IWSSIP), Niterói, Brazil. Disponível em: <<https://ieeexplore.ieee.org/document/9145130/>>.

PMF. Relatório Anual de Segurança Viária. Prefeitura Municipal de Fortaleza, Fortaleza, 2019.

RAKOTOARIVELO, A. N.; AUBERLET, J.-M.; BRÉMOND, R. Will I cross when I see you crossing? Towards illegal pedestrian road crossing simulations. **Transportation Research Part F: Traffic Psychology and Behaviour**, v. 93, p. 309–325, 2023.

RAONIAR, R.; MAURYA, A. K. Pedestrian red-light violation at signalised intersection crosswalks: Influence of social and non-social factors. **Safety Science**, v. 147, 2022.

REDMON, J.; FARHADI, A. YOLOv3: An Incremental Improvement. **ArXiv**, 2018.

SAYED, T.; ZAKI, M.; TAGELDIN, A. Automated Pedestrians Data Collection Using Computer Vision. Em: LEON-GARCIA, A. et al. (Eds.). **Smart City 360°**. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering. Cham: Springer International Publishing, v. 166, p. 31–43, 2016.

SONG, Y.; WANG, J.; LONG, X. Analysis and Modelling of Pedestrian Crossing Behavior at Intersections. **CICTP 2019**, p. 6083–6093, 2019.

TIWARI, G. *et al.* Modification of a Highway Capacity Manual Model for Evaluation of Capacity and Level of Service at a Signalized Intersection in India. **Proceedings of the Eastern Asia Society for Transportation Studies**, 2011.

TØNNING, C. *et al.* Road user behaviour analyses based on video detections: Status and best practice examples from the RUBA software, 2017.

TRB. **Highway Capacity Manual**. 6. ed. Transportation Research Board, National Research Council, Washington D.C, 2016.

ULTRALYTICS. **YOLOv5 documentation**, 2020. Disponível em: <<https://docs.ultralytics.com/>>. Acesso em: 15 de abril de 2023.

ULTRALYTICS. **YOLOv8 documentation**, 2023. Disponível em: <<https://docs.ultralytics.com/>>. Acesso em: 15 de abril de 2023.

WANG, C.-Y.; BOCHKOVSKIY, A.; LIAO, H.-Y. M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. p. 17, **ArXiv**, 2022.

WHO. Global status report on road safety 2018. Genova: World Health Organization.

WOJKE, N.; BEWLEY, A.; PAULUS, D. Simple online and realtime tracking with a deep association metric. In: IEEE Int. Conf. on Image Process (ICIP), 2017, p. 3645-3649. DOI: 10.1109/ICIP.2017.8296962.

WU, Y.; GUO, Y.; YIN, W. Real Time Safety Model for Pedestrian Red-Light Running at Signalized Intersections in China. **Sustainability**, v. 13, n. 4, p. 1-11, 2021.

ZAKI, M. H. *et al.* Use of Computer Vision to Identify Pedestrians' Nonconforming Behavior at Urban Intersections. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2279, n. 1, p. 54–64, 2012.

ZHAO, J.; LIU, Y. Modeling Pedestrian Delays at Signalized Intersections as a Function of Crossing Directions and Moving Paths. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2615, n. 1, p. 95–104, 2017.

ZHANG, S. *et al.* Prediction of Pedestrian Crossing Intentions at Intersections Based on Long Short-Term Memory Recurrent Neural Network. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2674, n. 4, p. 57–65, 2020.

ZHANG, W. *et al.* Exploring factors affecting pedestrians' red-light running behaviors at intersections in China. **Accident Analysis & Prevention**, v. 96, p. 71–78, 2016.

ZHU, D.; SZE, N. N.; BAI, L. Roles of personal and environmental factors in the red light running propensity of pedestrian: Case study at the urban crosswalks. **KSCE Journal of Civil Engineering**, v. 76, p. 47–58, 2021.