

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*

Analysis of delays and accepted gaps in signalized crossings: a study in Fortaleza using deep learning computer vision techniques

Francisco Altanizio Batista de Castro Junior¹, Manoel Mendonça de Castro Neto¹, Flávio José Craveiro Cunto¹

¹Universidade Federal do Ceará, Fortaleza, Ceará, Brasil

Contato: altanizio@hotmail.com,  (FABCJ); manael@det.ufc.br (MMCN); flaviocunto@det.ufc.br (FJCC)

Recebido:

30 de setembro de 2022

Aceito para publicação:

4 de abril de 2023

Publicado:

25 de agosto de 2023

Editor de Área:

Sara Ferreira

Universidade do Porto, Portugal

Palavras-chave:

Travessia de pedestres.

Atraso.

Brecha aceita.

Visão computacional.

Keywords:

Pedestrians crossings.

Delay.

Accepted gap.

Computer vision.

DOI: 10.58922/transportes.v31i2.2845

**RESUMO**

O aumento da atenção ao transporte ativo em países em desenvolvimento tem motivado estudos sobre a compreensão dos fatores que afetam seus usuários. O atraso é um dos principais indicadores do nível de serviço de travessias de pedestres e ele é afetado pelas brechas disponíveis. Este trabalho visa relacionar atrasos e brechas aceitas em travessias semaforizadas de Fortaleza, além de comparar os atrasos coletados com os estimados pelo método do *Highway Capacity Manual – 6ª. edição*. Os dados foram coletados por meio de algoritmos visão computacional, em cinco travessias de interseções semaforizadas, obtendo-se 1642 observações. O método inclui uma análise de agrupamentos de pares de atraso e brecha aceita. Os resultados mostraram similaridade dos atrasos estimados com os do HCM, e as relações entre brecha aceita e atraso possibilitam uma inferência acerca do risco das travessias dos pedestres.

ABSTRACT

The increasing attention to active transport in developing countries has motivated studies on understanding the factors that affect its users. Delay is one of the main indicators of the level of service of pedestrian crossings and it is affected by the available gaps. This work aims to relate delays and accepted gaps in signalized crossings in Fortaleza, as well as to compare the estimated delays with those obtained by the method of the *Highway Capacity Manual – 6th. edition*. The data were collected by means of computer vision algorithms, in five crossing located at signalized intersections, resulting in 1642 crossing observations. The method includes a cluster analysis of delay and accepted gap. The results showed similarity of the estimated delays with those obtained with the HCM. Also, the relationship between accepted gap and delay allows an inference about the risk of pedestrian crossings.

1. INTRODUÇÃO

A implantação de interseções semaforizadas em corredores de transporte busca, entre outros objetivos, disciplinar os fluxos veiculares e minimizar os conflitos entre veículos e pedestres, sendo comum a adoção de estágios dedicados à travessia de pedestres. Entretanto, apesar dos benefícios *a priori* em segurança viária, a ocorrência de tempos de ciclo elevados e baixos tempos de verde efetivo para os pedestres tendem a elevar o atraso dos pedestres nessas travessias, impondo uma penalidade em tempo de viagem para esses usuários vulneráveis do sistema de transportes. O atraso em interseções semaforizadas é um dos principais fatores apontados pela literatura que tendem a favorecer a ocorrência de travessias mais arriscadas (Jacobsen, 2011; Ma et al., 2015).

Além de agravar os riscos de atropelamentos devido a travessias arriscadas, o atraso em interseções semaforizadas tende a diminuir os níveis de serviço dos pedestres e desfavorecer a atratividade dos modos ativos. Identificar pontos críticos de atraso para pedestres em trechos urbanos, com foco nas interseções semaforizadas, é essencial para melhorar as condições de segurança viária das cidades, prevenir conflitos veículo-pedestre e reduzir as impedâncias desse meio de transporte sustentável. Diante da multiplicidade de travessias em espaços urbanos e da elevada variabilidade dos fluxos de pedestres e veículos ao longo do dia, é desejável que se estabeleça um método de coleta que seja acessível, flexível, escalonável e preciso na estimativa dos indicadores coletados (Alver et al., 2021; Zhang et al., 2020).

Este trabalho possui três objetivos: o primeiro é apresentar um método de coleta e estimação dos atrasos e das brechas aceitas de pedestres em travessias semaforizadas, desenvolvido a partir de algoritmos de visão computacional, com as características desejadas anteriormente mencionadas. O segundo é comparar as estimativas de atraso feitas com esse método com as obtidas pelo método do *Highway Capacity Manual* (HCM), 6ª edição (TRB, 2016). Por fim, o terceiro objetivo é investigar a relação entre os atrasos e as brechas aceitas pelos pedestres; tal relação pode dar indícios sobre o risco nas travessias.

Para alcançar esses três objetivos, este trabalho está organizado em cinco seções, além da introdução. Na Seção 2, apresenta-se uma síntese da revisão da literatura compreendendo os principais estudos sobre travessias de pedestres. Na Seção 3, apresentam-se os métodos de coleta propriamente dito, onde se descreve as estratégias adotadas para a estimação do atraso e da brecha aceita por meio de algoritmos de visão computacional. Na Seção 4, realiza-se uma aplicação do método para Fortaleza, utilizando de filmagens realizadas em câmeras de videomonitoramento do tráfego. Por fim, a Seção 5, traz as conclusões e recomendações para trabalhos futuros.

2. SÍNTESE DA REVISÃO DA LITERATURA

O atraso do pedestre é definido como o tempo que o pedestre espera para iniciar a travessia, sendo o atraso médio dos pedestres uma das principais medidas de desempenho em travessias (TRB, 2016). Vários fatores podem influenciar o atraso, como o tempo de verde efetivo para os pedestres e a quantidade de travessias ocorridas durante o tempo de verde dos veículos, ou seja, durante o vermelho dos pedestres (Li et al., 2005; Lipovac et al., 2013; Martín et al., 2019; Suh et al., 2013; Tang et al., 2020; Wang e Tian,

2010). Na literatura, essas travessias são comumente denominadas de oportunistas (Jacobsen, 2011; Liu, Silva e Seco, 2000), mas no presente trabalho elas serão chamadas travessias no vermelho, quando possível.

Diversos estudos buscam compreender travessias de pedestres. Li et al. (2005) desenvolveram um método de estimação do atraso em travessias de interseções semaforizadas na China e observaram uma variação substancial nos atrasos médios devido às travessias no vermelho. Wang e Tian (2010) concluíram que a chegada de pelotões de pedestres influencia significativamente no atraso. Suh et al. (2013) observaram que o atraso e a brecha aceita tiveram relação com o tempo de verde e o fluxo veicular. Lipovac et al. (2013) estudaram o comportamento do pedestre em travessias com exibidor de contagem regressiva e concluíram que nesses locais as travessias no vermelho eram, significativamente, menos frequentes. Mais recentemente, Tang et al. (2020) estudaram o comportamento de travessia em diferentes configurações de interseção e os resultados demonstraram que o aumento do tempo de ciclo semaforico aumentou o atraso dos pedestres em todas as configurações.

Martin et al. (2019) realizaram um estudo comparando o atraso estimado pelo HCM e o estimado a partir de uma análise de simulação microscópica de tráfego, utilizando dados de travessias da cidade de Fortaleza. O estudo mostrou que quanto mais frequente for a travessia no vermelho, mais o atraso é subestimado pelo HCM, visto que esse método não considera tal comportamento.

O método de estimação do atraso médio do *Highway Capacity Manual 6th Edition* (HCM) adota as seguintes premissas: i) o atraso médio é independente do volume de pedestres; ii) a chegada dos pedestres é uniforme; iii) todos os pedestres que esperam pelo sinal verde do pedestre iniciam a travessia simultaneamente; iv) os pedestres que chegam durante o verde atravessam à medida que chegam; e v) travessia no vermelho não é considerada (Martín et al., 2019; Roupail et al., 1998; TRB, 2016). Tais premissas podem impossibilitar a aplicação do método em travessias típicas brasileiras (Martín et al., 2019). O valor do atraso médio dos pedestres (dp) é obtido no HCM por meio da Equação 1.

$$dp = (C - g + 4)^2 / 2C \quad (1)$$

Em que C é o tempo de ciclo total e g é o tempo de verde do pedestre. Observa-se que o método do HCM exige apenas dois dados de entrada, ambos de fácil obtenção.

Atualmente, vários algoritmos e programas computacionais permitem o uso de Inteligência Artificial para realizar o rastreamento e a detecção de objetos a partir de filmagens, para aplicações diversas. Em transportes, essa tecnologia permite, por exemplo, coletar dados em larga escala de fluxos de usuários motorizados e não-motorizados. Com os algoritmos atualmente disponíveis, pode-se obter as trajetórias detalhadas das pessoas e dos veículos ao longo do tempo (Alver et al., 2021; Zhang et al., 2020).

Na última década, surgiram estudos de travessias de pedestres que usaram ferramentas de visão computacional (Alver et al., 2021; Zhang et al., 2020). Alhajyaseen e Iryo-Asano (2017) verificaram a influência de fatores, como a distância de travessia, na velocidade dos pedestres, por meio de processamento de imagem. Zhang et al. (2020)

analisaram a intenção de travessia dos pedestres no vermelho e suas características, utilizando algoritmos de aprendizagem profunda (*deep learning*). E mais recentemente, Alver et al. (2021) aplicaram métodos de visão computacional para avaliar a brecha crítica pelos pedestres em Esmirna, na Turquia.

3. MÉTODO ADOTADO

O método adotado neste trabalho consiste nas cinco etapas mostradas na Figura 1. Cada etapa será discutida nos cinco subitens desta seção.



Figura 1. Método empregado na pesquisa.

3.1. Coleta e tratamentos dos dados

Os dados foram coletados a partir de uma análise de vídeos gravados por câmeras de videomonitoramento do Controle de Tráfego em Área de Fortaleza (CTAFOR) em dias úteis. Foram utilizadas cinco interseções semaforizadas, localizadas em áreas densas da cidade, com elevada concentração de pessoas devido à presença de atividade e de uso do solo comercial. Todas as filmagens foram obtidas durante o dia, buscando favorecer o rastreamento dos pedestres com imagens de melhor qualidade (luminosidade). Por fim, os dados obtidos foram tratados e analisados por meio de rotina computacional desenvolvida em linguagem R.

3.2. Pré-processamento dos vídeos

O pré-processamento consiste em uma série de atividades de tratamento dos vídeos: recorte dos trechos a serem analisados, conversão para um formato apropriado, redução das taxas de captura de imagens em frames por segundo (*fps*) (foi adotado 10 *fps*) e hospedagem na plataforma dedicada do *Google* (*Google Drive*). A adoção de 10 de cadência (*fps*) dos vídeos representa um equilíbrio entre a qualidade do processamento e o esforço computacional: quanto maior a taxa de *fps*, maior a qualidade e a precisão do rastreamento de objetos, entretanto maior o tempo de processamento.

A literatura não aponta um valor ideal de *fps* para rastreamento de objetos, pois o valor depende de vários fatores, incluindo as necessidades da aplicação. Neste estudo, foi observado, a partir de testes, que o valor de 10 *fps* foi o mais adequado, já que valores maiores não compensaram o incremento do tempo de processamento. Além disso, a adoção de um valor maior inviabilizaria o estudo, devido à limitação de tempo de processamento disponibilizado pela plataforma utilizada (*GoogleColab*), em sua versão gratuita – cerca de 12h.

3.3. Detecção e rastreamento

O processamento de vídeos foi semelhante aos dos trabalhos de Alver et al. (2021) e de Zhang et al. (2020), baseado em três etapas: (i) o *YOLOv4* (Redmon e Farhadi, 2018; Bochkovskiy, Wang e Liao, 2020; Wang, Bochkovskiy e Liao, 2021), algoritmo do estado

da arte da Inteligência Artificial que permite a detecção de objetos em tempo real; (ii) *DeepSort* (Wojke e Bewley, 2018; Wojke, Bewley e Paulus, 2017), algoritmo de *deep learning* para rastreamento de objetos em vídeo; e (iii) *GoogleColab*, plataforma de desenvolvimento de linguagem Python na *nuvem*, que permite o processamento computacional com a disponibilidade de Placas de Vídeo (*GPUs*). A ferramenta usada neste trabalho foi uma adaptação do código disponibilizado de forma livre no *GitHub* - *theAIGuysCode/yolov4-deepsort* (GitHub, 2020), a partir do qual foi realizada uma série de procedimentos em Python para coletar os fluxos, os atrasos e as brechas aceitas dos pedestres. A Figura 2 apresenta um fluxograma dessas etapas.

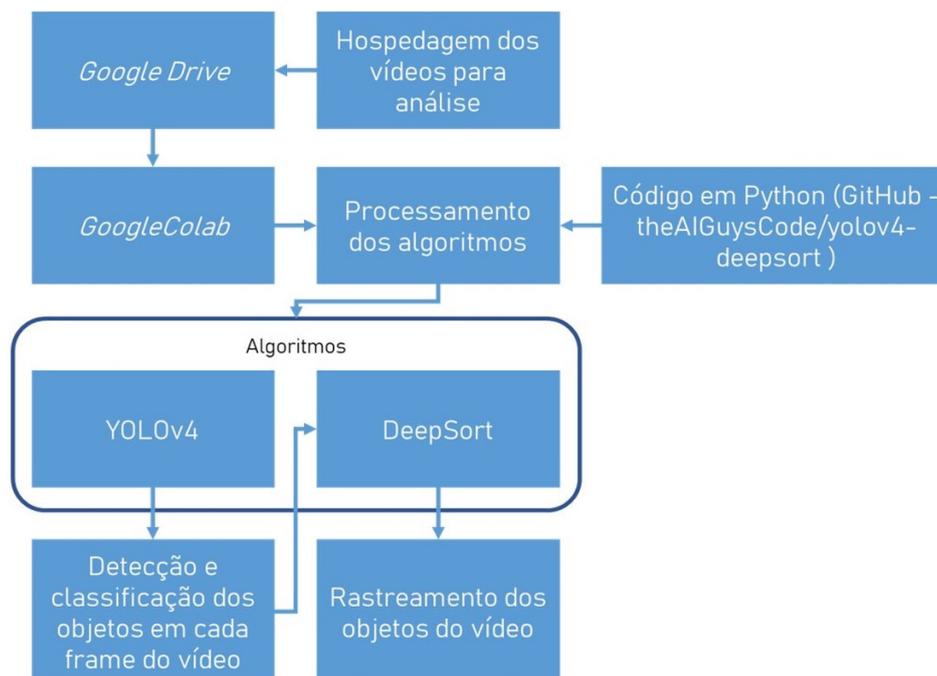


Figura 2. Fluxograma da detecção e do rastreamento de objetos.

A detecção de objetos foi realizada com base no algoritmo *YOLOv4*, o qual consegue detectar 80 categorias de objetos com uma *Average Precision (AP₅₀)* de 65% no banco de dados *Common Objects in Context (COCO)* (Bochkovskiy, Wang e Liao, 2020; Wang, Bochkovskiy e Liao, 2021). Além disso, Alver et al. (2021) verificou acertos acima de 95% na detecção de pedestres utilizando o *YOLOv3*. Nesta etapa, os fatores determinantes para a correta detecção e rastreamento dos objetos são a qualidade das imagens analisadas, o posicionamento das câmeras e a ausência de obstáculos (oclusões) ou objetos próximos que gerem confusão na análise das imagens. Para verificar a precisão do algoritmo no cenário proposto, foi realizada, ao final, uma etapa de verificação de erros de detecção.

A Figura 3 ilustra o processo de detecção e rastreamento, especificado para diferenciar pessoas, motocicletas, carros, ônibus e caminhões, identificados com quadrículas nos vídeos processados. Cada quadrícula (*bounding box*) é representada por um centroide, que é rastreado temporalmente, isto é, tem sua posição (relativa ao vídeo) registrada ao longo do tempo.

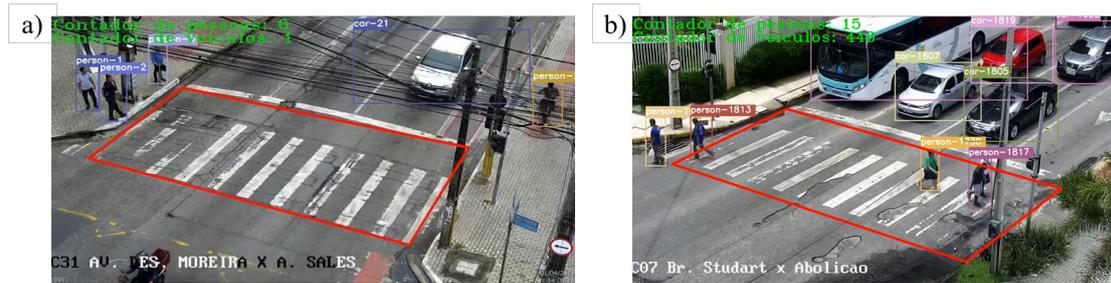


Figura 3. Exemplo da detecção e rastreamento realizados nas interseções (a) Av. Des. Moreira x Av. Antônio Sales e (b) Av. da Abolição x Av. Barão de Studart.

3.4. Estimação do atraso e das brechas aceitas

Neste trabalho, por questão de facilidade, o atraso dos pedestres foi definido como o intervalo de tempo entre a primeira detecção do pedestre no vídeo, e o início da travessia. Reconhece-se que essa definição do atraso – a partir do aparecimento dele no vídeo (e não da chegada no ponto de espera) – pode causar superestimação dos atrasos, a depender do grau de abertura das câmeras de videomonitoramento.

Foi definida uma fronteira (polígono em vermelho na Figura 3) que delimita a zona de travessia: sempre que o centroide de um objeto da categoria *Pessoa* cruza o polígono pelas laterais (aresta adjacente à calçada), é contabilizado o instante de início de travessia e adicionada uma unidade ao contador de pessoas. Processo similar é feito com os automóveis, porém nas arestas voltadas às faixas de tráfego: sempre que um objeto da categoria *Carro*, *Motocicleta*, *Ônibus* ou *Caminhão* cruza a primeira aresta da área de conflito (vermelha), é registrado o instante desse evento e é adicionada uma unidade ao contador de veículos.

A brecha aceita pelos pedestres foi definida como o intervalo de tempo entre os centroides de dois veículos consecutivos (*headway*), independentemente da faixa de tráfego e do momento de chegada do pedestre, definição essa adotada em outros trabalhos (Alver et al., 2021; Mohamad Nor et al., 2017). Assim, a brecha aceita pode não ter a duração da brecha avaliada pelo pedestre: se um pedestre chega no instante $t = 40$ s e os veículos que limitam a brecha passaram no instante $t = 0$ s e $t = 50$ s, a brecha aceita considerada neste trabalho será de 50 s, e não de 10 s. Portanto, brechas aceitas grandes não implicam, necessariamente, em travessias seguras. Porém, essa forma de cálculo permite inferir se o pedestre atravessou no vermelho ou no verde, pois no caso de travessia no verde, o valor da brecha aceita será equivalente ao tempo de vermelho veicular. Brechas aceitas maiores que o tempo de vermelho veicular podem significar também travessias no vermelho, quando o fluxo veicular for muito baixo, ou seja, quando o sinal ficar verde para o fluxo veicular quando não há veículos na fila. Admite-se que a brecha aceita e o atraso estimados podem conter, em alguns casos, erro por conta de uma travessia interrompida, caso em que o centroide do pedestre cruza a linha de detecção, mas esse não realiza a travessia, prefere esperar por outra oportunidade.

Em resumo, a detecção e o rastreamento deste trabalho estimaram: (i) os volumes fluxos de pedestres e de veículos a cada 15 minutos; (ii) os atrasos dos pedestres (segundos); e (iii) as durações das brechas aceitas (em segundos). Por fim, foi realizada uma comparação entre os atrasos médios estimados pelo HCM e pela ferramenta usada neste manuscrito.

3.5. Relação entre atraso e brecha aceita

Visando explorar a relação entre o atraso e a brecha aceita pelos pedestres, que pode dar indícios de características comportamentais das travessias, inicialmente, foi realizada uma análise visual de gráfico de dispersão e, em seguida, uma análise de agrupamento usando o método *k-means clustering*. Esse método foi aplicado porque a simples visualização de gráficos de dispersão pode não ser suficiente para a identificação adequada de agrupamentos. O método *k-means clustering* (Forgy, 1965) possibilitou a criação de grupos que podem ser representar relações entre o risco (brecha aceita) e o nível de serviço (atraso) da travessia. A escolha do número de grupos foi feita visualmente para cada interseção buscando encontrar interpretações sobre os pares de atraso e de brecha aceita dos pedestres nas travessias.

O procedimento consiste, primeiramente, em k objetos escolhidos aleatoriamente, cada um representa um centroide de grupo. Em seguida, cada objeto restante é assimilado a um grupo, baseado na menor distância entre o objeto e o centroide do grupo. Finalmente, um novo centroide para cada grupo é computado e o processo é iterado até um ponto de parada (Forgy, 1965; Al Malki et al., 2016).

4. RESULTADOS

4.1. Travessias analisadas

A Tabela 1 mostra uma breve descrição dos cruzamentos analisados. Vale ressaltar que os dados dessa tabela foram obtidos do trabalho de Mesquita, Castro Jr e Cunha (2020), o qual analisou o comportamento de travessia no vermelho nas mesmas interseções. Os tempos de ciclo semafórico foram obtidos por meio dos vídeos e verificou-se que apenas a C06 apresentou ciclo variável, com amplitude máxima de ciclos de 2 min 10 s a 2 min 25 s], com variação de cerca de cinco segundos para o verde do pedestre.

O processamento envolveu cerca de 15 horas de vídeos, sendo aproximadamente três horas por local. Em se tratando de um algoritmo implementado em Python, essencialmente aberto, as restrições envolvidas no processo de tratamento estavam mais ligadas à plataforma utilizada para o processamento de vídeos (*GoogleColab*), que limitava a um máximo gratuito de 12 h de uso de *GPUs*. Entretanto, esse tempo disponível mostrou-se suficiente para processar os vídeos utilizados. A Tabela 2 mostra características operacionais dos locais. Foram coletadas um total de 1642 observações de travessias (somatório da coluna #N). A Tabela 2 também mostra os fluxos de pedestres por hora (PPH) e de veículos por hora (VPH) dos 15 minutos mais carregados de cada local.

Tabela 1: Características físicas dos cruzamentos

Código	Logradouro A	Logradouro B	Ciclofaixas	%Uso do solo		Distância de Travessia (m)
				não residencial	Faixas	
C12	Av. Dom Luís	Av. Des. Moreira	Sim	86%	4	15,8
C06	Av. Dom Manuel	Av. Monsenhor Tabosa	Não	81%	3	17,5
C21	Av. da Universidade	Av. 13 de maio	Não	100%	4	17,5
C31	Av. Des. Moreira	Av. Antônio Sales	Sim	100%	3	12,5
C35	Av. da Abolição	Av. Barão de Studart	Não	82%	4	19,0

Fonte: Mesquita, Castro Jr e Cunha (2020)

Tabela 2: Características operacionais dos cruzamentos

	Horário		Tempo de Ciclo (s)	g (s) pedestres	VPH (veic/h)	PPH (ped/h)	#N (obs.)
	Início	Fim					
C06	01/04/2019 13:00	01/04/2019 16:05	128	73	1492	44	59
C35	03/04/2019 11:10	03/04/2019 14:09	127	73	1632	44	54
C21	29/03/2019 13:00	29/03/2019 16:00	145	99	1384	388	689
C31	01/04/2019 13:00	01/04/2019 16:00	128	62	1848	248	502
C12	03/04/2019 11:09	03/04/2019 14:09	145	65	2208	164	338

#N: número de observações de pedestres.
 VPH: veículos por hora; e PPH: pedestres por hora.

4.2. Estimação do atraso e das brechas aceitas

Nesta subseção, por limitações de espaço, apresentam-se os resultados detalhados para uma das interseções, a C31 (Figura 4), escolhida por ter fluxos elevados e configuração mais típica. Como indica a planta do local, não há movimento de conversão veicular conflitando com pedestres.



Figura 4. (a) Planta com a programação semafórica, (b) mapa e (c) visualização da interseção C31 [adaptado da Autarquia Municipal de Trânsito e Cidadania (AMC) de Fortaleza e Google Maps].

Na Figura 5, apresenta-se a variação temporal do volume de pedestres na referida interseção. O resultado mostra maiores fluxos de pedestres na pausa do almoço (próximo a 13 h) e no final da tarde (próximo às 16 h).

A Figura 6 mostra que a variação temporal do tráfego veicular foi menor, talvez porque a via já se encontre saturada. Os *headways* veiculares médios, obtidos pelos tempos de passagem dos centroides das quadrículas estão na Figura 7. Percebe-se valores próximos a dois segundos e relativamente estáveis ao longo do período analisado, indicando operação próxima à capacidade.

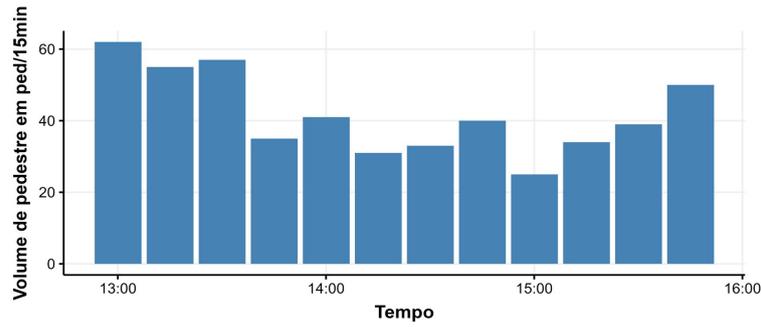


Figura 5. Variação temporal do fluxo de pedestres na travessia C31.

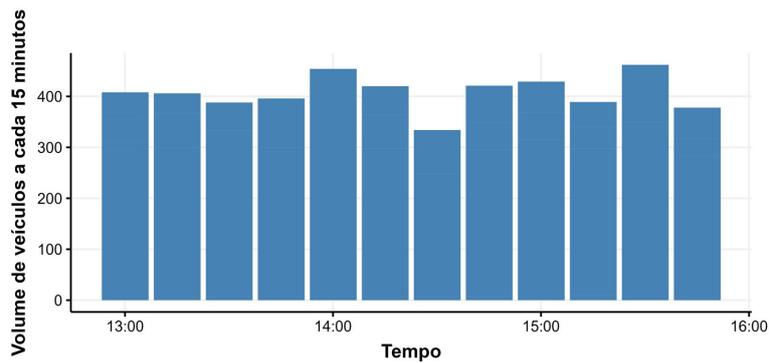


Figura 6. Volume veicular na C31 – somatório das três faixas.

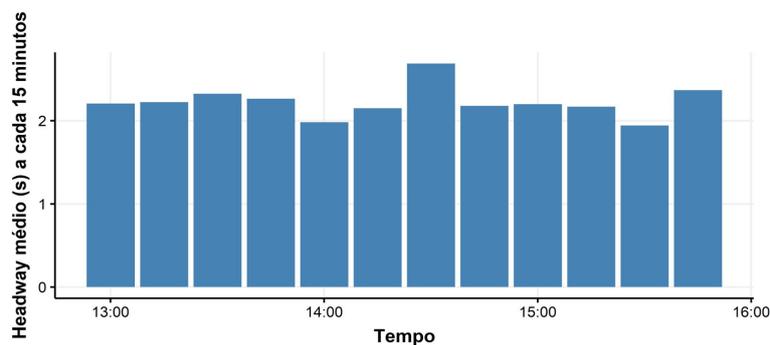


Figura 7. Variação do headway médio veicular na C31.

A Figura 8 mostra o histograma dos *headways* veiculares menores que 10 s. Percebe-se que poucos *headways* são maiores que 5 s, indicando que não há tanta facilidade de aceitação de brecha pelos pedestres nessa travessia de três faixas.

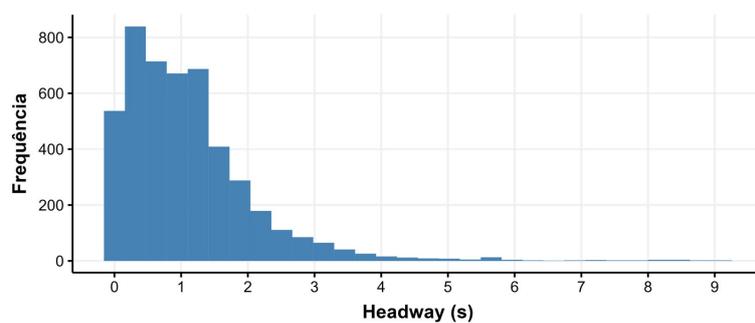


Figura 8. Histograma do headway veiculares menores que 10 s na C31.

Apresenta-se a seguir os resultados da estimação do atraso de pedestres na interseção. O histograma e o *boxplot* de atrasos (Figura 9) revela uma predominância de atrasos entre zero e cinco (s), que ocorre nos casos de pedestres que chegam na interseção durante o verde ou que chegam no vermelho, mas conseguem atravessar rapidamente.

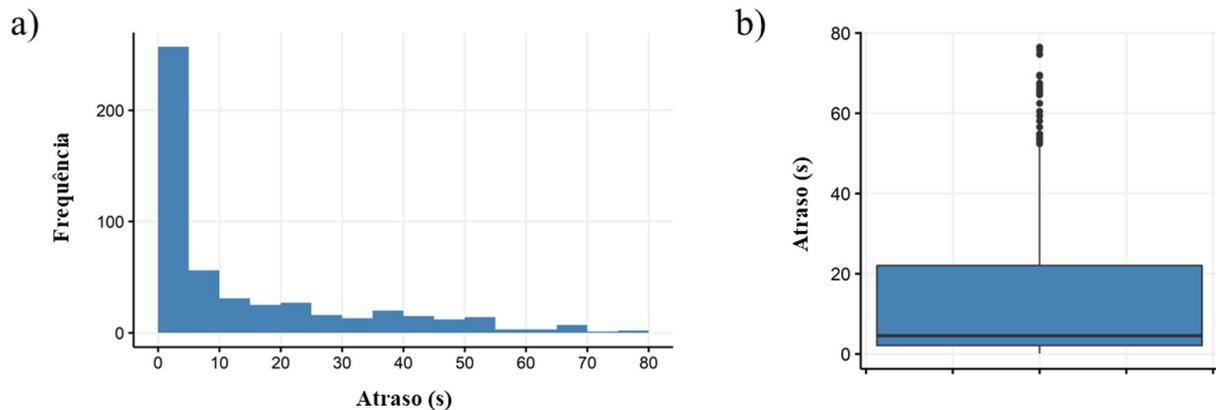


Figura 9. (a) Histograma e (b) *boxplot* do atraso de pedestres na C31.

Por meio dos dados dos instantes de passagem dos veículos e de travessia dos pedestres, foram obtidas as durações das brechas aceitas (Figura 10). Observam-se valores próximos de zero (s), o que pode ocorrer devidos a travessias interrompidas, ou seja, o pedestre entrou na área de conflito, mas desistiu de atravessar, fazendo com que a ferramenta computasse a brecha como aceita, sem na verdade ser. Outro motivo pode ser devido a falhas de detecção da ferramenta de coleta. A brechas aceitas tem mediana de 30 s, média de 33 s e desvio padrão de 27 s, indicando forte dispersão, como mostra a Figura 10. Essa variabilidade pode ser consequência da variabilidade das chegadas dos pedestres, das brechas disponíveis e das brechas críticas dos pedestres.

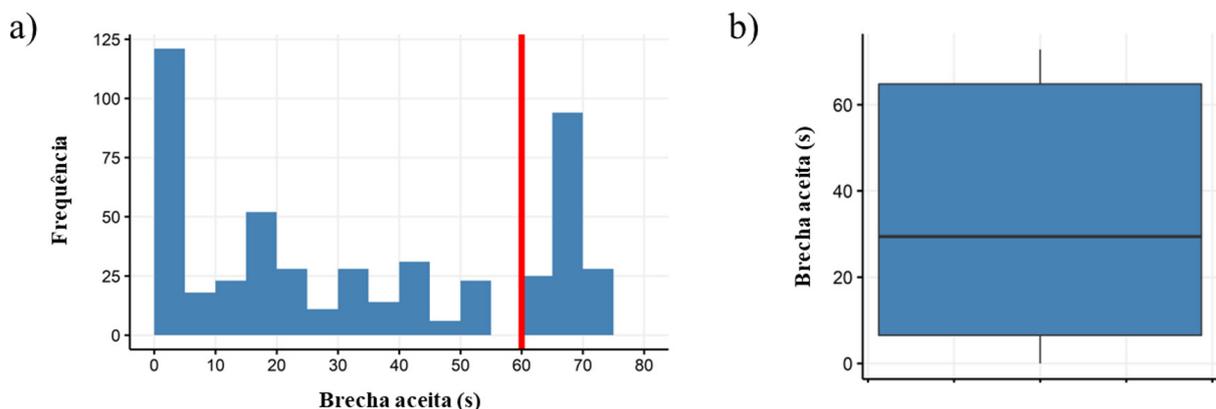


Figura 10. (a) Histograma e (b) *boxplot* da brecha aceita por pedestres na C31.

Observa-se, na Figura 10, um *cluster* de brechas aceitas superiores a 60 s, separado pela linha vermelha vertical na figura. Tendo em vista o ciclo semaforico da interseção em questão pode-se levantar as hipóteses que as brechas aceitas superiores a 60 s podem refletir em travessias potencialmente menos arriscadas. É dito *potencialmente*, porque,

vale lembrar que, neste trabalho, a primeira brecha veicular referente a um pedestre tem como instante inicial a passagem do veículo líder, e não o instante da chegada do pedestre. Portanto, uma brecha aceita grande (ex.: 50 s) pode ocorrer quando o pedestre chega à interseção faltando apenas poucos segundos para o próximo veículo chegar (ex.: 8 s), significando uma travessia arriscada, porém com brecha aceita grande. Na maioria dos casos, brechas aceitas maiores que 60 s ocorrem quando o semáforo está vermelho para os veículos ou o fluxo veicular era baixo o suficiente para ocasionar *headways* superiores a 60 s durante o verde veicular, o que não é comum nesta interseção. Por outro lado, brechas inferiores a 60 s podem, potencialmente, significar travessias mais arriscadas, pois o pedestre poderia estar em conflito com os veículos.

4.3. Comparação das estimativas de atraso do método proposto e do HCM

A Figura 11 compara os atrasos médios calculados pelo HCM com os estimados pelo método do trabalho com intervalos de confiança (IC) de 95%. Devido à premissa de comportamento obediente, esperava-se que as estimativas de atraso do HCM fossem maiores que as do método empregado (Martín et al., 2019; Suh et al., 2013; Wang e Tian, 2010). As estimativas pontuais atendem a essa hipótese na maioria das interseções. As estimativas do HCM estão contidas nos ICs em 4 das 5 interseções analisadas. Portanto, pode-se dizer que se verificou certa semelhança entre os dois métodos.

A interseção C21 apresentou o menor valor de atraso calculado pelo HCM (6,0 s) e a maior diferença ao estimado pelo método deste trabalho. A C21 apresenta uma configuração viária – apresentada com mais detalhes na seção 4.5 – que pode gerar erros nos atrasos estimados, pois a área efetiva de espera dos pedestres se encontra mais distante da área de surgimento deles quando comparado com outras interseções do estudo. Como a metodologia do trabalho para o cálculo do atraso é a diferença do tempo de surgimento no vídeo e o momento de travessia, essa configuração gera uma superestimação dos atrasos.

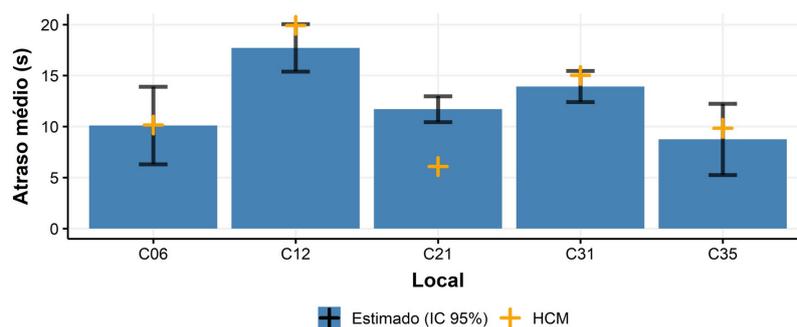


Figura 11. Comparação do atraso médio estimado com o calculado pelo HCM.

4.4. Relação entre atraso e brecha aceita dos pedestres

Visando explorar com maior profundidade a relação entre o atraso e a brecha aceita, que pode dar indícios de características comportamentais das travessias, plotou-se as observações em um gráfico de dispersão (Figura 12). Observa-se que há uma separação entre as observações com brechas aceitas abaixo e acima de 60 s, o que é interpretado, como discutido

anteriormente, como a fronteira do comportamento menos arriscado (à direita da linha vermelha) contra travessias potencialmente arriscadas (à esquerda da linha vermelha).

Para buscar mais agrupamentos, realizou-se uma análise de *k-means clustering* (Forgy, 1965), com quatro e cinco grupos (Figura 12). É possível interpretar os grupos do lado direito (C e D) como grupos de pedestres com travessias menos arriscadas, sendo o grupo D com um maior atraso e o grupo C com um menor atraso.

Já os grupos A e B, por terem brechas aceitas inferiores aos prováveis tempos de vermelho veicular, são interpretados como travessias provavelmente mais arriscadas, ou seja, grupos críticos, sendo o grupo B com um maior atraso e o grupo A com um menor. Por fim, o grupo E contempla os pedestres que aceitaram uma brecha relativamente suficiente para realizar uma travessia evitando um conflito mais grave com os veículos, pois acima de 20 s, em qualquer uma das cinco interseções, o pedestre teria uma velocidade média de 0,8 m/s, o que configura como uma travessia sem a necessidade de corrida (Alhajyaseen e Iryo-Asano, 2017; Alver et al., 2021). Ressalta-se que os grupos E e B não foram observados em todas as interseções, o que exigiu alteração no número de grupos para se adequar com a caracterização proposta.

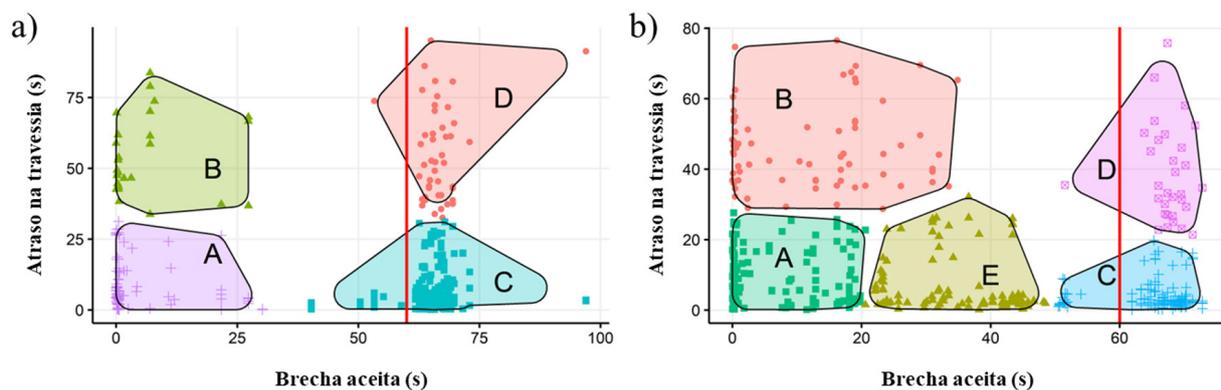


Figura 12. Análise de *clusters* de atraso e brecha aceita para a) C12 e b) C31.

A Tabela 3 mostra as porcentagens de observações dos grupos críticos (A e B) para cada travessia. Esperava-se que as interseções com maior porcentagem nesses grupos apresentassem uma diferença maior entre os atrasos estimados pelos dois métodos, pois provavelmente tais travessias ocorrem com mais frequência no vermelho. Observa-se que, em todas as interseções, existe uma porcentagem relevante de pedestres aceitando brecha curta (grupos A e B) (em média 38%). Existem diversos fatores que podem motivar a aceitação de brechas menores, como tempo de verde para os pedestres, uso do solo e fluxo veicular (Alver et al., 2021; Mohamad Nor et al., 2017; Suh et al., 2013; Tang et al., 2020).

Comparando dois locais com usos do solo semelhantes, um com menos porcentagem nos grupos A e B (C12, 33%) e outro com mais (C35, 52%), observa-se que no primeiro local o fluxo veicular é 35% maior, ciclo semafórico é 14% maior e o verde para os pedestres é 12% menor. Portanto, pode-se levantar as hipóteses que essas características podem ser causadoras dessas diferenças de intensidade de travessias no vermelho. Isso pode ser corroborado pelo menor atraso de pedestres ser no primeiro local (C35), em acordo com a literatura (Suh et al., 2013; Tang et al., 2020).

A travessia C21 apresenta características distintas das demais: forte presença de pedestres universitários, semáforo atuado pelo pedestre e o maior tempo de verde. Isso pode explicar o fato de essa travessia ter uma das menores proporções de pedestres com atraso elevado.

Tabela 3: Resumo dos resultados entre o atraso e brecha aceita pelos pedestres

Local	Atraso médio (s)			% nos Grupos Crítico	
	Proposto	HCM	Brecha aceita média (s)	A	B
C06	10,1 IC [6,3 ; 13,9]	10,2	67,3 IC [56,5 ; 78,2]	32%	-
C35	8,7 IC [5,2 ; 12,2]	9,8	42,9 IC [31,0 ; 54,8]	52%	-
C21	11,7 IC [10,4 ; 13,0]	6,1	56,3 IC [53,4 ; 59,2]	28%	6%
C31	13,9 IC [12,4 ; 15,5]	15,0	32,9 IC [30,6 ; 35,3]	27%	14%
C12	17,7 IC [15,4 ; 20,0]	19,9	46,4 IC [43,2 ; 49,5]	25%	8%

Desconsiderando a interseção C21, devido as suas peculiaridades, observa-se uma correlação entre a soma das porcentagens nos grupos A e B (brechas aceitas curtas) e a diferença de estimativas de atraso médio entre os dois métodos (proposto vs. HCM) (Figura 13). Segundo Martin et al. (2019), quanto mais intensa for a travessia no vermelho, mais o atraso se distancia do valor estimado pelo HCM, visto que esse método não considera esse tipo de travessia. Ressalta-se, entretanto, que as diferenças dos atrasos encontradas não foram significativas, talvez pelo fato de o atraso obtido pelo método utilizado superestimar os atrasos em campo, como discutido anteriormente.

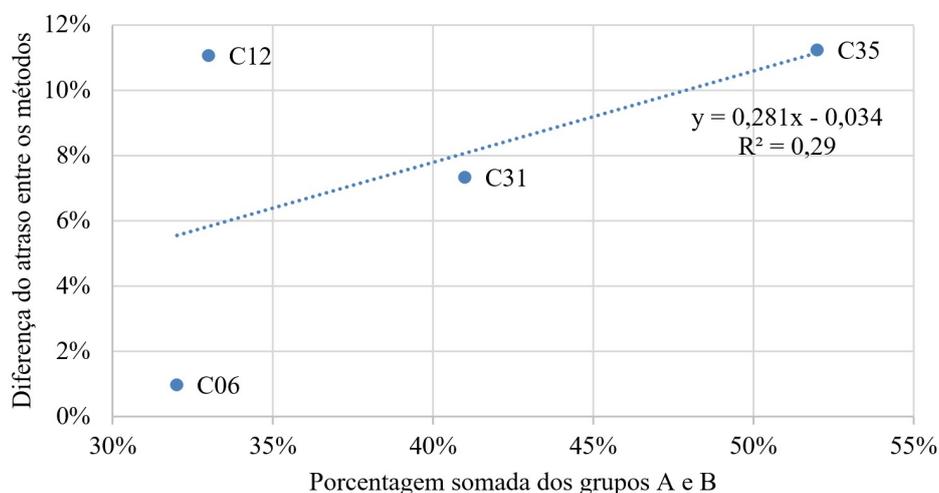


Figura 13. Relação da diferença do atraso entre os métodos e as porcentagens de observações nos grupos A e B.

4.5. Possíveis erros de detecção

Alguns erros de detecção podem ocorrer com a ferramenta utilizada, como os básicos de classificação, que ocorre quando um objeto (pessoa ou veículo) é classificado erroneamente, e de não-deteção (ver exemplos na Figura 14), que é mais frequente em situações em que há aglomerações de pessoas na travessia (a) ou onde há objetos que acabam confundindo a detecção de imagem (b). Um terceiro tipo de erro é retratado na Figura 14c, que apresenta a travessia do cruzamento C21; logo que os pedestres aparecem no vídeo, seu atraso começa a

ser contabilizado. Isso ocasiona superestimação do atraso, principalmente na parte esquerda da figura, em que há muita área no vídeo que vai além da área de espera para a travessia.



Figura 14. Exemplos de possíveis erros de medição do algoritmo: (a) erros por aglomeração, (b) erros por objetos e (c) erros por geometria.

Para se estimar a magnitude dos erros de detecção do algoritmo, realizou-se um processo de validação em três locais da pesquisa, em trechos de 30 minutos de vídeos. As taxas de acerto, que correspondem à proporção de pedestres corretamente classificados são apresentadas na Tabela 4.

Observa-se que as taxas de acerto variaram entre 67% e 95%, estando compatível com o estudo de Alver et al. (2021), o qual verificou acertos acima de 95% na detecção de pedestres utilizando o YOLOv3. Entretanto, essa comparação deve ser feita com cautela visto que a não detecção depende de vários fatores, como a localização da câmera, obstáculos na via etc.

Tabela 4: Taxas de acerto de pedestres detectados por local de coleta

Código	Taxa de Acerto
C12	85%
C31	95%
C35	67%

5. CONCLUSÕES E RECOMENDAÇÕES

A principal contribuição deste trabalho foi desenvolver um método, utilizando algoritmos gratuitos do estado da arte em visão computacional, para obter automaticamente atraso e brechas aceitas pelos pedestres e fluxos veiculares e de pedestres em interseções semaforizadas. Com relativamente simples adaptações, pode-se obter outras variáveis do tráfego de pedestres e de veículos nas interseções.

A principal vantagem do método reside na rapidez e na praticidade da coleta automatizada, sem necessidade de computador pessoal de alto desempenho para o processamento. Caso as 1642 as observações de atrasos e as respectivas brechas fossem coletadas manualmente (em escritório, com análise de vídeo, ou em campo), exigiria custos consideráveis, bem como estaria sujeito a outros tipos de erros de coleta (Alver et al., 2021). Cada brecha veicular precisa, não só ser correspondida a pedestres que porventura estejam esperando para atravessar, como também ser classificada em aceita ou rejeitada para cada pedestre, o que dificultaria sobremaneira a coleta manual.

A comparação com os valores estimados pelo método do HCM aponta para uma semelhança de resultados na maioria dos locais, possivelmente devido, em parte, à

superestimação dos atrasos pelo método adotado, uma vez que os atrasos são contabilizados a partir do momento que o pedestre é detectado pela primeira vez no vídeo. Além disso, as análises mostraram que quanto maior a porcentagem de pedestres que aceitaram brechas curtas maior é a diferença do método do HCM com o estimado, embora essas diferenças não foram significativas.

A relação entre as brechas aceitas e o atraso dos pedestres permitiram inferir, grosso modo, sobre o risco da travessia. Observou-se maiores porcentagens de travessias mais arriscadas em interseções com menores fluxos de pedestres e veículos, possivelmente devido à facilidade de se encontrar brechas durante o vermelho. Foi verificado que os atrasos dos pedestres foram menores nas interseções com menores ciclos semaforicos e com maiores tempos de verde para esses usuários. Ressalta-se que não é objetivo deste artigo concluir acerca dessas complexas relações de causalidade, mas sim de apresentar um método de coleta de dados que permita investigar a relação entre atraso e brecha aceita. Essa e as demais relações podem ser exploradas em trabalhos futuros, com o aprimoramento da ferramenta de coleta apresentada.

Como sugestões para trabalhos futuros, recomenda-se: aprimorar a ferramenta para contabilizar o atraso a partir do instante que o pedestre começa a espera; treinar os algoritmos com mais imagens para melhorar a detecção e o rastreamento dos diferentes usuários, inclusive para gravações de vídeo com diferentes angulações e luminosidade. Finalmente, recomenda-se a utilização de máquinas físicas capazes de executar os algoritmos em filmagens mais longas e com maiores taxa de *fps*.

REFERÊNCIAS

- Alhajyaseen, W.K.M. e M. Iryo-Asano (2017) Studying critical pedestrian behavioral changes for the safety assessment at signalized crosswalks. *Safety Science*, v. 91, p. 351-60. DOI: 10.1016/j.ssci.2016.09.002.
- Alver, Y.; P. Onelcin; A. Cicekli et al. (2021) Evaluation of pedestrian critical gap and crossing speed at midblock crossing using image processing. *Accident; Analysis and Prevention*, v. 156, n. April, p. 106127. DOI: 10.1016/j.aap.2021.106127. PMID:33865175.
- Bochkovskiy, A.; C. Wang e H.M. Liao (2020) YOLOv4: Optimal Speed and Accuracy of Object Detection. Disponível em: <<http://arxiv.org/abs/2004.10934>> (acesso em 04/04/2023).
- Forgy, E. (1965) Cluster analysis of multivariate data: efficiency versus interpretability of classifications. *Biometrics*, v. 21, p. 768-80.
- GitHub (2020) theAIGuysCode/yolov4-deepsort. Disponível em: <<https://github.com/theAIGuysCode/yolov4-deepsort>> (acesso em 13/04/2023).
- Jacobsen, A.C. (2011) *Microssimulação da travessia de pedestres*. Dissertação (mestrado). Universidade Federal do Rio Grande do Sul, Porto Alegre. Disponível em: <<https://www.lume.ufrgs.br/handle/10183/32007>> (acesso em 04/04/2023).
- Li, Q.; Z. Wang; J. Yang et al. (2005) Pedestrian delay estimation at signalized intersections in developing cities. *Transportation Research Part A, Policy and Practice*, v. 39, n. 1, p. 61-73. DOI: 10.1016/j.tra.2004.11.002.
- Lipovac, K.; M. Vujanic; B. Maric et al. (2013) Pedestrian behavior at signalized pedestrian crossings. *Journal of Transportation Engineering*, v. 139, n. 2, p. 165-72. DOI: 10.1061/(ASCE)TE.1943-5436.0000491.
- Liu, R.; J.P. Silva e A.J. Seco (2000) A bi-modal micro-simulation tool for the assessment of pedestrian delays and traffic management. In *9th International Association of Travel Behavior Research Conference*. Gold Coast, Australia: University of Sydney.
- Ma, W.; D. Liao; Y. Liu et al. (2015) Optimization of pedestrian phase patterns and signal timings for isolated intersection. *Transportation Research Part C, Emerging Technologies*, v. 58, p. 502-14. DOI: 10.1016/j.trc.2014.08.023.
- Al Malki, A.; M.M. Rizk; M.A. El-Shorbagy et al. (2016) Hybrid genetic algorithm with K-means for clustering problems. *Open Journal of Optimization*, v. 5, n. 2, p. 71-83. DOI: 10.4236/ojop.2016.52009.

- Martín, L.E.; T.P. Bandeira; L.D.G. Pinto et al. (2019) Atraso de pedestres em travessias semaforizadas: uma comparação entre as modelagens pelo HCM e pelo microssimulador VISSIM. *Transportes*, v. 27, n. 1, p. 128-40. DOI: 10.14295/transportes.v27i1.1581.
- Mesquita, K.G.A.; F.A.B. Castro Jr e M.G. H. Cunha (2020) Caracterização de pedestres obedientes e oportunistas em travessias semaforizadas de Fortaleza. In Associação Nacional de Pesquisa e Ensino em Transportes (ed.) *34º Congresso de Pesquisa e Ensino em Transporte da ANPET*. 100% digital: ANPET, p. 2474-2485.
- Mohamad Nor, S.N.; B. David Daniel; R. Hamidun et al. (2017) Analysis of pedestrian gap acceptance and crossing decision in Kuala Lumpur. In: *MATEC Web of Conferences*. Melaka, Malaysia: EDP Sciences. DOI: 10.1051/mateconf/201710308014
- Redmon, J., e A. Farhadi (2018) YOLOv3: an incremental improvement. *Computer Vision and Pattern Recognition*. DOI: 10.48550/arXiv.1804.02767
- Rouphail, N.; J. Hummer; J. Milazzo et al. (1998) Recommended procedures – Chapter 13: Pedestrians. In: Transportation Research Board (ed.), *Highway Capacity Manual*. Washington, DC: Transportation Research Board. (Report FHWA-RD-98-107).
- Suh, W.; D. Henclewood; A. Greenwood et al. (2013) Modeling pedestrian crossing activities in an urban environment using microscopic traffic simulation. *Simulation*, v. 89, n. 2, p. 213-24. DOI: 10.1177/0037549712469843.
- Tang, L.; Y. Liu; J.L. Li et al. (2020) Pedestrian crossing design and analysis for symmetric intersections: efficiency and safety. *Transportation Research Part A, Policy and Practice*, v. 142, p. 187-206. DOI: 10.1016/j.tra.2020.10.012.
- TRB (2016) *Highway Capacity Manual* (6th ed.). Washington, DC: Transportation Research Board.
- Wang, C., A. Bochkovskiy e H.M. Liao (2021) Scaled-YOLOv4: Scaling Cross Stage Partial Network. Disponível em: <https://openaccess.thecvf.com/content/CVPR2021/papers/Wang_Scaled-YOLOv4_Scaling_Cross_Stage_Partial_Network_CVPR_2021_paper.pdf> (acesso em 13/04/2023).
- Wang, X. e Z. Tian (2010) Pedestrian delay at signalized intersections with a two-stage crossing design. *Transportation Research Record: Journal of the Transportation Research Board*, v. 2173, n. 1, p. 133-8. DOI: 10.3141/2173-16.
- Wojke, N. e A. Bewley (2018) Deep cosine metric learning for person re-identification. In *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*. Lake Tahoe, NV, USA: IEEE, p. 748-756. DOI: 10.1109/WACV.2018.00087
- Wojke, N.; A. Bewley e D. Paulus (2017) Simple online and realtime tracking with a deep association metric. In *International Conference on Image Processing*. Beijing, China: IEEE, p. 3645-3649. DOI: 10.1109/ICIP.2017.8296962
- Zhang, S.; M. Abdel-Aty; J. Yuan et al. (2020) 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. DOI: 10.1177/0361198120912422.