

# Análise de Métricas Telemáticas para Auditoria de Veículos Autônomos

Fernando M. Ortiz<sup>1</sup>, Matteo Sammarco<sup>2</sup>,  
Marcin Detyniecki<sup>2</sup> e Luís Henrique M. K. Costa<sup>1</sup>

<sup>1</sup>Universidade Federal do Rio de Janeiro - DEL/Poli-PEE/COPPE

{fmolano, luish}@gta.ufrj.br

<sup>2</sup>AXA Group, France

{matteo.sammarco, marcin.detyniecki}@axa.com

**Abstract.** *Autonomous vehicles (AVs) use external sensing systems to obtain information about diverse objects present around them and thus make driving decisions in an automated way. In fact, the information obtained through vehicle telematics serves to monitor the functioning and the way of driving any motor vehicle, not just the AVs. According to the literature, different metrics are used by insurance company applications to assess potential-risk situations and how the person drives. As for AVs, however, the evaluation of these metrics is still incipient, given that most of these vehicles are under development. Thus, to assess and quantify traffic risk events involving AVs and other road users, this work analyzes surrogate safety measures based on proprioceptive and exteroceptive sensor readings in AV datasets. The results show that at least 10% of the events represent any level risk for the AV. These results help to explain the driving behavior and how decisions are made by the autonomous system.*

**Resumo.** *Veículos autônomos (AVs) usam sistemas de sensoriamento externo para obter informações sobre os diversos objetos presentes ao seu redor e assim tomar decisões de condução de forma automatizada. De fato, as informações obtidas através da telemática veicular servem para monitorar o funcionamento e a forma de condução de quaisquer veículos automotores, não apenas dos AVs. De acordo com a literatura, diferentes métricas são usadas por aplicativos de seguradoras para avaliar situações de risco potencial e como os motoristas dirigem. Quanto a AVs, porém, a avaliação destas métricas ainda é incipiente, dado que a maioria destes veículos está em desenvolvimento. Assim, com o objetivo de avaliar e quantificar a gravidade de eventos de risco no trânsito envolvendo AVs e outros usuários viários, este trabalho estuda métricas de segurança substitutas baseado em leituras de sensores exteroceptivos e proprioceptivos contidas em conjuntos de dados de AVs. Os resultados indicam que ao menos 10% dos eventos representam algum nível risco para o AV. Estes resultados ajudam a explicar o comportamento e a tomada de decisões no sistema autônomo.*

## 1. Introdução

A pesquisa em veículos autônomos (AVs – *Autonomous Vehicles*) envolve diversas tecnologias, desde sensores e atuadores a processadores, software e redes de

comunicação. Para além do desafio de projeto do AV em si, existem diversas questões relacionadas à substituição (gradual) do condutor humano e à convivência de veículos tradicionais com AVs. A chamada transição humano-máquina (HMT – *Human-Machine Transition*) [Bellet et al., 2019] implica, entre outros aspectos, que as responsabilidades pela tomada de decisões de condução têm que ser reavaliadas; p. ex., já existem acidentes reportados com veículos com algum nível de autonomia [Betz et al., 2019]. Em se tratando de decisões de condução e ocorrência de acidentes, além da HMT, coloca-se também um cenário desafiador para a indústria de seguros: a forma de condução do veículo não mais depende apenas do condutor, humano, mas também do sistema autônomo do veículo. Assim, torna-se importante investigar métricas que possam modelar o comportamento do AV para, em última instância, auxiliar a definição do custo do seguro.

Os fabricantes de veículos estão equipando seus veículos com sistemas de assistência e suporte ao motorista, que constituem sistemas parciais de automação. A SAE americana (*Society of Automotive Engineering*) definiu uma classificação para o nível de automação dos veículos, a SAE J3016 [SAE, 2018]. Numerados do 0 ao 5, níveis de autonomia maiores significam maior complexidade do sistema autônomo, assim como o sensoriamento intensivo no veículo. Esta complexidade demanda um compromisso entre o envolvimento do motorista e o amadurecimento do sistema autônomo. Funcionalmente, os AVs possuem sistemas de controle para a detecção e resposta a qualquer evento em presença de qualquer objeto. Contudo, existem limitações relacionadas com o tipo de situações e como estas são gerenciadas pelo sistema autônomo. Tais limitações são intrínsecas à aleatoriedade da infraestrutura viária, assim como às condições climáticas e de luminosidade inerentes ao ambiente no qual operam os veículos. Portanto, torna-se necessário analisar fatores operacionais do veículo que permitam identificar eventos de risco para o próprio veículo, passageiros, pedestres e outros usuários viários.

Uma forma de monitorar eventos de risco no trânsito é por meio de medições de segurança substitutas (SSMs – *Surrogate Safety Measures*). As SSMs são indicadores que permitem quantificar a severidade, baseadas nas características de mobilidade do veículo. Além disto, as SSMs permitem prever eventos de risco a partir de eventos observáveis que não constituem uma batida. No entanto, as SSMs não são usadas para prevenir ou evitar acidentes, e sim para avaliar e analisar a probabilidade de qualquer evento de risco e a sua severidade. Atualmente, a análise de segurança em veículos normais (sem funções autônomas) acontece através da aquisição de dados de dispositivos de prateleira e sensores proprioceptivos do veículo [Ortiz et al., 2020]. Entretanto, os AVs contêm um conjunto de tecnologias que visa o melhoramento da percepção do ambiente exterior ao veículo, permitindo fazer análises de segurança relacionados com os usuários viários interagindo com o AV através da mobilidade dos sensores.

Apesar da vasta literatura em análise de segurança através de SSMs, o estado da arte foca principalmente em simulações, bases de dados de colisões, análise de pontos de referência nas rodovias, e conjuntos de dados de veículos com sensores instalados para análise de perfis de motoristas, sem analisar o ambiente externo do veículo. Como avanço em relação ao estado da arte, este trabalho investiga o uso de SSMs baseado em conjuntos de dados obtidos de sensores de AVs. São utilizados traços de dados obtidos a partir dos sensores de dois carros autônomos em fase de testes, disponíveis publicamente através do projeto nuScenes (Seção 4). Os traços contêm dados de sensoriamento

exteroceptivo (p. ex., câmeras e LiDAR), além de medições objetivas do veículo, isto é, dados de velocidade, aceleração, e dados semânticos dos objetos detectados ao longo dos traços. Três métricas são avaliadas: o tempo para colisão (TTC – *Time-to-Collision*), o tempo pós-invasão (PET – *Post Encroachment Time*), e a taxa de desaceleração para evitar a colisão (DRAC – *Deceleration Rate to Avoid Collision*), além de métricas objetivas próprias do veículo. Estas informações são relevantes uma vez que a análise de segurança corresponde estritamente às variações dos sensores e as ações evasivas tomadas pelo AV.

Este trabalho está organizado da seguinte forma. A Seção 2 discute os trabalhos relacionados com análise de SSMs em diferentes cenários. A Seção 3 descreve as SSMs implementadas para auditar eventos de risco no trânsito. Já na Seção 4 descreve os conjuntos de dados usados para avaliação. A Seção 5 apresenta a metodologia e os resultados obtidos. Por fim, a Seção 6 conclui o trabalho e identifica trabalhos futuros.

## 2. Trabalhos Relacionados

As SSMs permitem quantificar a severidade dos eventos de risco no trânsito. Estas métricas permitem, por exemplo, descrever a probabilidade de uma batida, assim como a frequência das interações com diferentes objetos ao longo da viagem do veículo de interesse (p. ex., diferença de tempo entre veículos, distância de um objeto, velocidade máxima do veículo, entre outras).

Para analisar múltiplas interações através de SSMs, diversos trabalhos têm desenvolvido estudos baseados em simulação por *software*. Viridi *et al.* faz uma avaliação de segurança para frotas de veículos autônomos e conectados através da ferramenta de simulação SSAM (*Surrogate Safety Assessment Model*). Os autores observaram que a maioria de conflitos dos AVs acontecem em interseções, e concluem que dependendo do grau de penetração dos AVs, a taxa de conflitos pode diminuir [Viridi et al., 2019]. Zhang *et al.* avaliam a segurança de veículos autônomos conectados, analisando a troca e a exclusividade de faixas através da ferramenta de simulação PTV-VISSIM [Zhang et al., 2020]. Por outra parte, Alghodhaifi e Lakshmanan analisam SSMs como base para um sistema de proteção para pedestres, através de simulações em Matlab/Simulink [Alghodhaifi e Lakshmanan, 2020].

Outros trabalhos usam dados de veículos equipados com sensores para o monitoramento interno e externo do veículo, além de dispositivos de comunicação. Conjuntos de dados como 100-Car [Dingus et al., 2006] e SHRP2 (*Strategic Highway Research Program 2*) [Campbell, 2012] têm sido amplamente estudados na análise do TTC, com o objetivo de analisar eventos de risco em traços reais e simulados, e formular novas métricas. O conjunto de dados SPMD (*Safety Pilot: Model Deployment*) [Nodine et al., 2015] tem sido usado por He *et al.* para comparar três métricas: TTC, DRAC e MTTC (*Modified Time-to-Collision*). Os autores concluíram que o MTTC apresenta o melhor desempenho geral [He et al., 2018]. Entretanto, Xie *et al.* usam dados coletados no SPMD para analisar locações de alto risco. A ideia é calcular uma métrica de segurança baseada no TTC, que analisa colisões que podem acontecer na frontal do veículo ego por conta de perturbações acontecidas no veículo à frente. Os autores estudam bases de dados de batidas da cidade de Michigan com dados da SPMD em 75 segmentos de rodovia onde os veículos rodaram e aconteceram acidentes. Os autores observaram uma alta correlação entre o TTC, o DRAC e o TTCD (*Time-to-Collision with Disturbance*). Entretanto, o TTCD

detectou riscos que não foram observados nas análises de TTC e DRAC [Xie et al., 2019]. Este trabalho avalia a segurança do AV baseado na formulação geral das SSMs, dado que nem todas as métricas cinemáticas do objeto detectado estão contempladas no conjunto de dados, quando comparado com o MTTC (p. ex., a aceleração dos objetos detectados).

Nessa mesma linha, estudos sobre a avaliação do TTC por meio de sensores exteroceptivos têm sido desenvolvidos para reconhecer as diversas entidades com as quais um veículo pode interagir. Aycard *et al.* propõem um sistema de avaliação de risco em cruzamentos [Aycard et al., 2011]. Para isso, os dados da câmera e dos sensores LiDAR são fusionados para detectar e estabelecer a dinâmica dos objetos detectados. Para quantificação de risco, o TTC é usado como um indicador de risco de colisão. Os autores concluem que a avaliação de risco por meio da percepção pode melhorar as aplicações de segurança na indústria automotiva. Kilicarlsan e Zheng analisam colisões de veículos por meio de TTC usando câmeras de vídeo. Os autores analisam a divergência de movimento horizontal e vertical em quadros de vídeo sem depender de caixas delimitadoras. Para isso, a análise de TTC é baseada nas variações de tamanho do objeto detectado no vídeo, dividido pelas mudanças de tamanho em intervalos de tempo. O algoritmo proposto é utilizado em vídeos de condução naturalística sem acidentes. Os resultados mostram uma acurácia de 94% e uma precisão de 93% na relação entre o sistema computado e o vídeo real. Entretanto, comparado com a detecção do sensor LiDAR no conjunto de dados KITTI, um conjunto de dados de um AV experimental, os autores observam que as medições baseadas em LiDAR dependem da profundidade de detecção, interrupções na detecção, além de requerer análise 3D [Kilicarlsan e Zheng, 2019].

A análise de métricas de segurança viária estão estreitamente relacionadas com a coleta de dados de imagens de áreas específicas (majoritariamente interseções), ou análise de vídeo em veículos com dispositivos embarcados. Diferente destes trabalhos, este estudo trata de explorar o potencial do uso de dados gerados pelos AVs para desenvolver soluções de análise de segurança baseados no sensoriamento próprio dos veículos. Especificamente, dados de AVs em fase de teste são usados neste estudo. Um processo detalhado das métricas e sensores usados pelo veículo para a aquisição dos dados é apresentado. Estes veículos geram um grande volume de dados de alta resolução que permitem analisar seu desempenho operacional e de segurança, além de esclarecer a sua interação com outros usuários viários.

### **3. Medições de Segurança Substitutas (SSMs)**

As SSMs são definidas como medições usadas para descrever a relação entre dois ou mais usuários viários em um evento de risco no trânsito, com o objetivo de quantificar a probabilidade de acidente e/ou a potencial gravidade de conflitos de trânsito [Johnsson et al., 2018]. O principal propósito das SSMs é medir a segurança no trânsito. Para isso, as SSMs descrevem de forma contínua diversos eventos no trânsito que podem acontecer em um determinado tempo e espaço. Estes eventos podem diferir no nível de gravidade, o que permite analisar a frequência dos eventos de risco. A gravidade de um evento depende de vários fatores, podendo ser estes sérios e não-sérios [Hydén, 1987]. Portanto, as SSMs podem explicar as condições envolvidas em eventos de risco no trânsito que podem resultar em colisões dos veículos de interesse. Estas condições estão baseadas em tempo e espaço, e possibilitam a previsão de colisões por meio da análise de eventos observáveis sem colisão, de modo que é possível modelar

a frequência destes eventos por meio de métodos de análise prática [Tarko et al., 2009]. Além disso, essa área torna-se mais importante considerando que a tendência evolutiva dos veículos, é de cada vez maior autonomia. Assim, a análise das tomadas de decisão e das ações/reações delas decorrentes contribui para a auditabilidade do AV. Deste modo, a análise da segurança no trânsito obedece aos processos de explicabilidade e justificabilidade para as partes interessadas.

A análise de conflitos no trânsito pode ser realizada através de métricas diretas e/o métricas de contexto, ou seja, métricas que descrevem a situação ocorrida. Dado que as métricas diretas não são suficientes para descrever os conflitos de trânsito, são necessárias outras métricas para descrever a situação de conflito. Estas outras métricas, de contexto, preveem análises matemáticas para avaliar o risco de acidente de acordo com a situação do veículo ego e os outros veículos, objetos e pedestres ao seu redor.

### 3.1. Métricas diretas

As métricas diretas usam valores instantâneos produto do movimento do veículo, tais como velocidade, aceleração e distância. Portanto, são definidas como medidas específicas (p. ex., variações de velocidade, taxa de aceleração/desaceleração, entre outras). Essas medições são obtidas através de sensores proprioceptivos ou de dispositivos de prateleira. A Tabela 1 descreve as métricas diretas mais usadas na avaliação de SSMs.

**Tabela 1. Métricas diretas mais usadas na análise de segurança viária.**

Métricas	Descrição
Velocidade	A velocidade permite analisar o comportamento da condução do veículo em termos de velocidade limite e velocidade média alcançada pelo veículo ego em qualquer percurso.
Taxa de aceleração/ desaceleração	Variações na aceleração estão relacionadas com o aumento/redução da velocidade e à aceleração/desaceleração bruscas. Valores negativos de aceleração estão associados a medições de desaceleração. Estas medições podem ser adquiridas por meio de sensores proprioceptivos no veículo ou dispositivos de prateleira quando disponíveis.
Desaceleração máxima ( <i>Maximum Deceleration</i> - maxD)	A maxD descreve a desaceleração máxima do veículo ego. Este valor pode variar dependendo da velocidade e da análise de dados de tempo, ou do valor da aceleração quando as leituras do acelerômetro estão disponíveis.
Velocidade máxima ( <i>Maximum Speed</i> - maxS)	A maxS descreve a velocidade máxima dos veículos envolvidos em um conflito de trânsito. Esta métrica permite explicar a gravidade de um conflito no trânsito ou manobras perigosas baseada no limite de velocidade ou tempo de reação.

### 3.2. Métricas de contexto

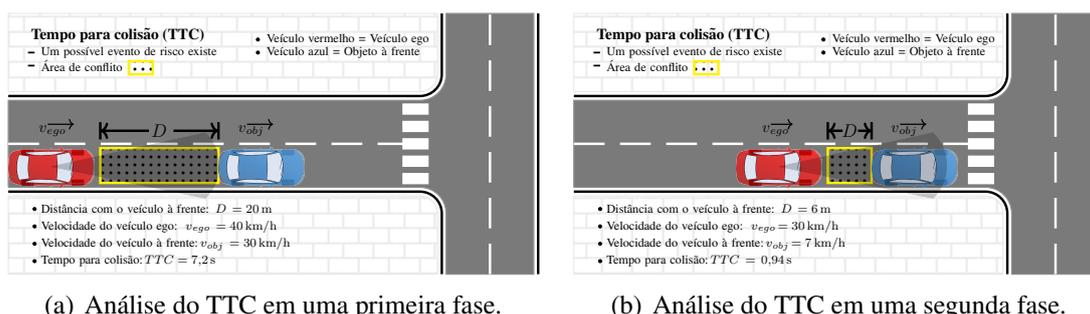
As métricas de contexto dependem das métricas diretas para avaliar o risco de acidente em relação ao veículo ego e os objetos detectados ao redor. Para identificar potenciais conflitos no trânsito, o TTC [Hayward, 1972], a DRAC [Almqvist et al., 1991] e o PET [Hydén, 1996] são as principais métricas de contexto. Normalmente, as SSMs são avaliadas entre veículos em áreas de conflito. Uma área de conflito é definida como uma área espacial comum entre trajetórias projetadas dadas medidas instantâneas de velocidade e distância para dois ou mais usuários viários.

*Tempo para colisão (TTC):* O TTC é definido como o tempo que levaria para o veículo ego colidir com um objeto à frente, se a velocidade relativa atual fosse mantida desde a localização anterior ao longo do mesmo caminho [Hayward, 1972]. Esta é uma medida contínua de segurança que pode ser calculada a qualquer momento considerando que o veículo está em uma área de conflito. A Equação 1 mostra a relação entre a distância entre o veículo ego e os objetos detectados à frente ( $D_{(ego.obj)}$ ), e a diferença de velocidade

entre eles ( $v_{ego}$ ) e ( $v_{obj}$ ). Normalmente, o valor TTC indica o tempo mínimo para colidir ( $TTC_{min}$ ), calculado continuamente através do processo de detecção de possíveis eventos de risco no trânsito. Deste modo, os valores do TTC assumem um valor finito, diminuindo à medida que a gravidade do evento de risco de trânsito aumenta. Portanto, o valor do TTC permite inferir o tempo de reação para manobras evasivas a fim de diminuir os riscos.

$$TTC = \begin{cases} \frac{D_{(ego,obj)}}{v_{ego}-v_{obj}}, & \text{se } v_{ego} > v_{obj}, \\ \infty, & \text{se } v_{ego} < v_{obj}. \end{cases} \quad (1)$$

Um exemplo que representa o cálculo do TTC é mostrado na Figura 1. Variações de distância e velocidade entre o veículo ego (cor vermelha) e diversos objetos detectados podem se traduzir em um TTC maior ou menor, e, portanto, um evento de risco potencial proporcional às variações no movimento. Isto é representado nas Figuras 1(a) e 1(b), onde à medida que o veículo ego aproxima-se do veículo azul, o TTC diminui, e a probabilidade de um evento ter maior risco aumenta. Pelo contrário, um aumento na velocidade do veículo à frente pode reduzir a probabilidade de risco e o curso de colisão pode deixar de existir, com o TTC tendendo a  $\infty$  neste caso.

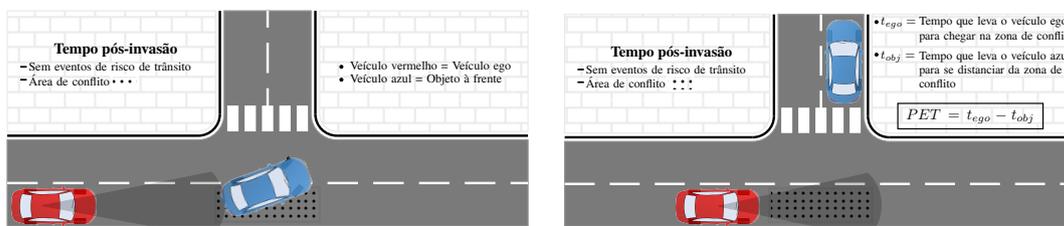


**Figura 1. Exemplo da análise do TTC em um evento de risco.**

A severidade de qualquer evento de risco do veículo ego por meio do cálculo do TTC depende das medições de velocidade e distância. Portanto, em velocidades altas e baixas é possível estabelecer a severidade de qualquer evento. Um valor alto de TTC representa um evento de baixo risco no trânsito, enquanto valores baixos de TTC representam eventos de alto risco. Enquanto isso, para quantificar a severidade dos eventos de risco no trânsito, um coeficiente de risco deve ser determinado para distinguir a gravidade do evento, como descrito na Seção 5.3. Na primeira etapa, os eventos de risco no trânsito são analisados considerando um veículo à frente do AV (veículo ego). Portanto, não levamos em consideração o comprimento do objeto detectado à frente.

*Tempo pós-invasão (PET):* O valor do PET é a diferença entre o tempo que leva o veículo ego para chegar à área de conflito, e o tempo que leva para o veículo à frente se afastar da área de conflito [Allen et al., 1978]. Um exemplo que representa o cálculo do PET é mostrado na Figura 2. Os valores de PET representam medidas do intervalo de tempo pelo qual uma colisão foi evitada. Ao contrário do TTC, os valores PET não definem um critério para quantificar um evento de risco potencial no trânsito, isso porque o PET não requer medições cinemáticas dos usuários da estrada, o que o torna vantajoso

quando há ausência de dados do veículo ou dos objetos detectados. Por exemplo, um valor  $PET = 0$  s pode significar um acidente. Outros limites superiores a 0 s podem representar uma condução potencialmente mais perigosa. No entanto, os valores de PET não permitem a avaliação precisa da severidade em um evento trânsito, uma vez que não usa medições cinemáticas dos usuários da estrada envolvidos em um evento potencial.



(a) Análise do PET em uma primeira fase.

(b) Análise do PET em uma segunda fase.

**Figura 2. Exemplo da análise do PET em um evento de risco.**

*Taxa de desaceleração para evitar a colisão (DRAC):* A manobra evasiva mais usada para evitar colisões é a frenagem. Esta ação permite reduzir o impacto de uma colisão, bem como reduzir eventos de risco no trânsito, a partir do momento em que são detectadas. Para medir os efeitos da frenagem e a redução da velocidade a partir das ações evasivas, a DRAC é usada para calcular a taxa de desaceleração mínima requerida no veículo ego para evitar uma colisão com o objeto detectado à frente [Almqvist et al., 1991]. O cálculo do DRAC requer a análise das variações cinemáticas do veículo ego e do objeto à frente, e a distância entre eles. A Equação 2 mostra a relação da distância entre o veículo ego e os objetos detectados à frente ( $D_{(ego.obj)}$ ) e a diferença de velocidade entre eles ( $v_{ego}$ ) e ( $v_{obj}$ ) para o cálculo do DRAC.

$$DRAC = \begin{cases} \frac{(v_{ego} - v_{obj})^2}{2D_{(ego.obj)}}, & \text{se } v_{ego} > v_{obj}, \\ 0, & \text{se } v_{ego} < v_{obj}. \end{cases} \quad (2)$$

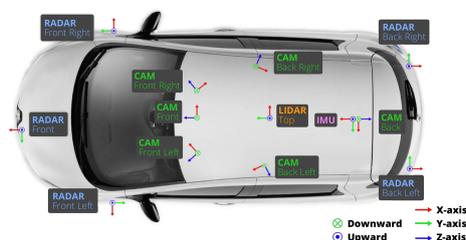
## 4. Descrição do Conjunto de Dados

Para a análise de segurança viária, este trabalho utiliza o conjunto de dados do nuScenes AV [Caesar et al., 2020]. Este conjunto de dados contém informações de leituras de dados de sensores multimodais, isto é, leituras de sensores proprioceptivos e exteroceptivos [Ortiz et al., 2020]. Além disso, informações em diferentes condições climáticas e períodos do dia, além de rastreamento, localização, mapeamento e dados semânticos relacionados aos objetos detectados são fornecidos. O nuScenes AV inclui dados processados para identificar objetos por meio de caixas delimitadoras, anotações, categorias e atributos associados aos objetos detectados. Este trabalho usa o conjunto de dados da nuScenes AV como entrada para a análise das SSMs apresentadas na seção anterior.

### 4.1. nuScenes AV

O nuScenes é um conjunto de dados público de grande escala para direção autônoma, que permite a análise da infraestrutura rodoviária em cenários urbanos usando sensores exteroceptivos em um AV. Este conjunto de dados fornece dados de detecção

adquiridos por meio de 6 câmeras, 1 LiDAR, 5 radares, 1 GPS/IMU (*Inertial Measurement Unit*), e dados dos sensores internos do veículo. A Figura 3 mostra a configuração dos sensores no nuScenes AV. No total, de 5 a 6 horas de dados coletados por um AV em Boston (EUA) e outro em Cingapura (SG) são fornecidas.



- 979 cenas de 20 s cada;
- 1,4 milhões de imagens da câmera;
- 390 k varreduras de LiDAR;
- 1,4 milhões de caixas delimitadoras 3D;
- 1,1 bilhões de pontos de LiDAR;
- 1,3 milhões de pontos de Radar;
- 11 camadas de mapeamento;
- Cenários no dia/noite e claros/chuvosos.

**Figura 3. Configuração dos sensores no nuScenes AV. Além do LiDAR com campo de visão de 360°, distribuição de radares e câmeras cobre também 360°.**

Os dados brutos dos sensores são armazenados em dados de nuvem de pontos, no caso do LiDAR e o radar, e pixels de imagem da câmera. A partir do processamento das leituras destes sensores no AV, é possível obter dados semânticos do ambiente ao redor do AV. Os dados semânticos permitem associar metadados das leituras dos sensores com diferentes classes de objetos detectados, além de facilitar processos de explicabilidade necessários para as partes interessadas. Nesse sentido, o conjunto de dados fornece diversas categorias para descrever cada instância detectada. Essas anotações dos objetos detectados são descritas dinamicamente à medida que interagem com o AV. Assim, o conjunto de dados fornece 23 categorias com objetos identificados em movimento e parados (p. ex., pedestres, veículos, bicicletas, entre outros), que correspondem a imagens de primeiro plano que são totalmente identificadas. Além das leituras de dados dos sensores exteroceptivos, o conjunto de dados do nuScenes AV também inclui dados de sensores proprioceptivos adquiridos através do barramento CAN (*Controller Area Network*) do veículo, para cada cena (p. ex., movimento do volante, velocidade do veículo, entre outros).

## 5. Resultados

Para a análise de segurança, são consideradas todas as interações do AV com os objetos ao redor, enquanto estes são detectados pelos sensores do veículo. Assim, para cada amostra disponível no conjunto de dados, são analisadas todas as interações do AV com objeto detectado pelo LiDAR e a câmera frontal. Especificamente, os dados de velocidade e distância dos objetos são estimados através das medições do LiDAR, enquanto as imagens são usadas para o reconhecimento dos diversos objetos ao redor do AV. Esses dados estão disponíveis no conjunto de dados em forma de anotações e metadados para cada um dos objetos detectados. Por outro lado, a velocidade e a distância dos objetos são calculadas através da ferramenta disponibilizada pela nuScenes [Caesar et al., 2020].

O conjunto de dados nuScenes AV possui 850 cenas com metadados disponíveis. Todas as cenas possuem também dados do barramento CAN do AV. É importante mencionar que esses dados estão sincronizados com as anotações das leituras dos sensores exteroceptivos. Os dados são analisados separadamente por cidade, uma vez que a orientação no trânsito é diferente: em Boston, o padrão de condução é a mão esquerda, enquanto em Cingapura é do lado direito, ou mão inglesa.

## 5.1. Rastreamento do veículo ego

O rastreamento de veículos é importante na telemática de seguros para monitorar com precisão a localização do veículo, os tipos de estradas onde transita, o deslocamento em áreas inseguras, o estilo de condução do veículo, entre outros. Uma vez que o conjunto de dados não inclui estas informações, neste trabalho são adicionadas informações sobre a posição geográfica, endereço, tipo de estrada e limite de velocidade de cada rota seguida pelo AV. Estas informações permitem, por exemplo, identificar se o veículo ego ou outros veículos detectados trafegam a velocidades maiores que a permitida em uma via. A Figura 4 mostra as zonas onde circula o AV. Primeiro, as coordenadas geodésicas são calculadas para determinar os endereços das ruas por onde o AV trafegou através da ferramenta OpenStreetMap (OSM) Nominatim. A partir destes endereços, as consultas são feitas ao banco de dados do OSM por meio da API OverPass, que fornece dados sobre o tipo e o limite de velocidade das estradas. Além do rastreamento, esses parâmetros permitem delinear o perfil de direção AV em relação aos regulamentos de trânsito.

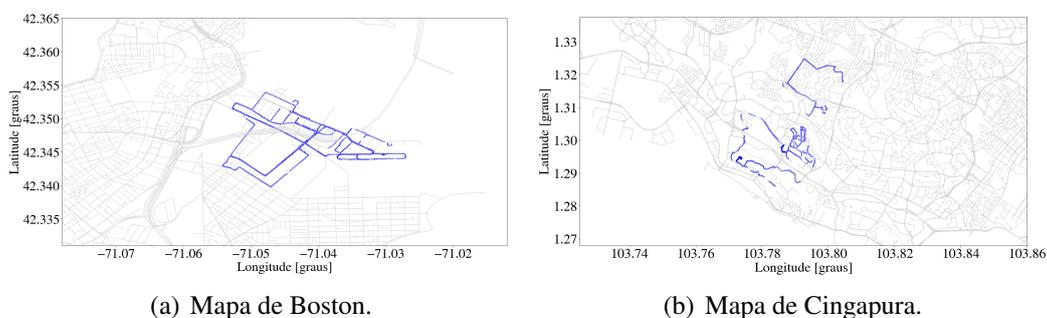


Figura 4. Localização do AV nas duas cidades.

## 5.2. Análise da velocidade limite

A partir da análise de rastreamento do veículo verifica-se o perfil de velocidade do veículo ego. A Figura 5 mostra que o veículo ego mantém uma velocidade média entre 15 km/h e 30 km/h em Boston, e 20 km/h e 40 km/h na Cingapura. Da mesma forma, é analisada a velocidade dos veículos se deslocando à frente do veículo ego. É possível observar que algumas amostras superam o limiar de velocidade limite estabelecido pelos regulamentos de trânsito; informação obviamente relevante dado que o excesso de velocidade aumenta a probabilidade de eventos de risco.

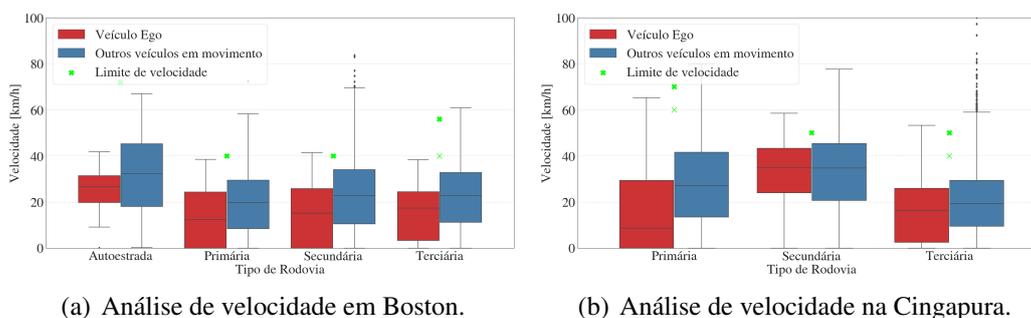
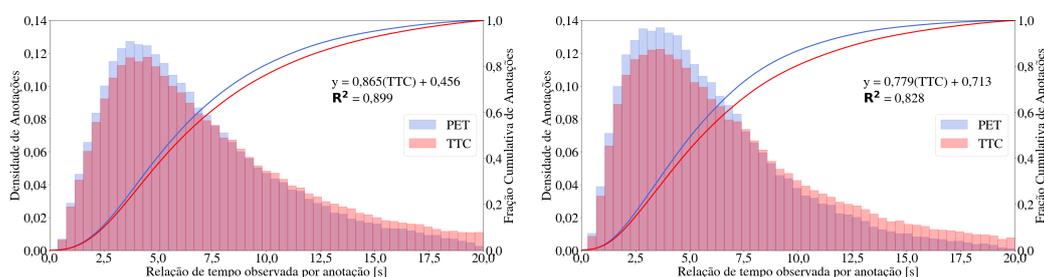


Figura 5. Análise de velocidade do veículo ego e os objetos detectados.

### 5.3. Avaliação de TTC e PET

Os limiares de TTC e PET são cruciais para identificar interações críticas relacionadas ao tempo entre o veículo e os objetos detectados pelo veículo ego. Para tanto, são analisados o TTC e o PET por meio de distribuições estatísticas de frequência. A Figura 6 mostra que as variações de tempo das duas métricas são semelhantes, com uma alta correlação entre as duas métricas (0,899 no cenário de Boston, e 0,828 no cenário da Cingapura). Entretanto, se observa que ao menos 40% das amostras se concentra entre 0 s e 5 s, com a maior densidade de amostras nesse intervalo. Este resultado corresponde aos critérios usados em outros trabalhos para definir limiares de tempo absolutos para determinar a severidade de um evento de risco [Hydén, 1987, Li et al., 2017].



(a) TTC vs. PET no subconjunto de Boston.

(b) TTC vs. PET no subconjunto da Cingapura.

**Figura 6. Comparação entre as métricas TTC e PET.**

Apesar de não existir um consenso sobre os limiares que definem um evento de alto risco, baseado nos resultados da Figura 6, este trabalho usa os coeficientes de risco propostos em [Li et al., 2017]; este critério reúne valores de acordo com os limites usados em outros trabalhos para definir eventos de alto risco. Enquanto isso, o coeficiente de risco DRAC é baseado no critério de Hydén [Hydén, 1996], uma vez que esses limites são baseados na reação esperada do motorista para desacelerar. A Tabela 2 mostra o coeficiente de risco usado para o TTC e DRAC.

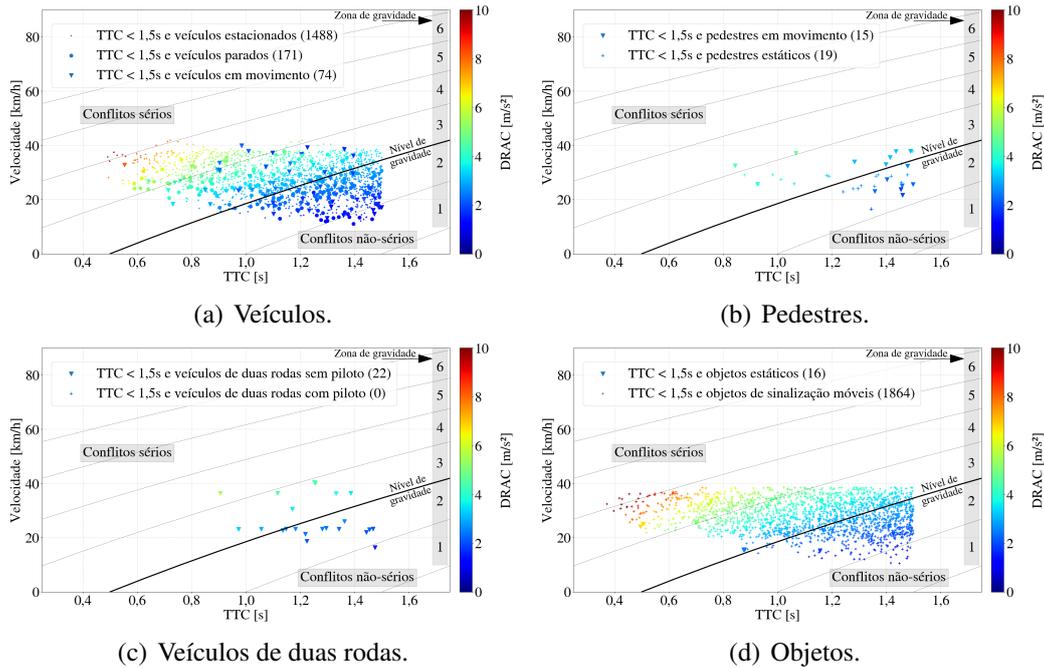
**Tabela 2. Coeficiente de risco para TTC e DRAC [Li et al., 2017].**

Grau de Severidade	TTC [s]	DRAC [ $m/s^2$ ]	Descrição	Coefficiente de Risco
Sem conflito	> 4,0	0 a 1	Sem risco	0,0
1	2,5 a 4,0	1 a 2	Razão acidente-conflito estável	0,2
2	1,5 a 2,5	2 a 4	Nível de risco baixo	0,3
3	1,0 a 1,5	4 a 6	Nível de risco moderado	0,6
4	$\leq 1,0$	$\geq 6$	Nível de risco alto	0,8

Para descrever de forma quantitativa os eventos de risco, este trabalho usa a análise de níveis e zonas de severidade de [Hydén, 1987]. Este modelo define limiares para conflitos sérios e não-sérios. Baseado no modelo de hierarquias, são adaptadas as curvas resultantes para observar de forma gráfica os eventos de alto risco percebidos pela análise de SSMs em cima dos dados do nuScenes AV. A análise mostra a relação entre o TTC, o DRAC e a velocidade do veículo ego e cada anotação disponível dos objetos detectados no nuScenes AV, com a sua categoria e atributo correspondente.

A Figura 7 mostra os resultados da análise de conflitos potenciais para o subconjunto de dados de Boston. Eventos de risco com  $TTC < 1,5$  s mostram que a maioria dos eventos representam conflitos sérios, com a maior concentração de eventos na zona 3 e

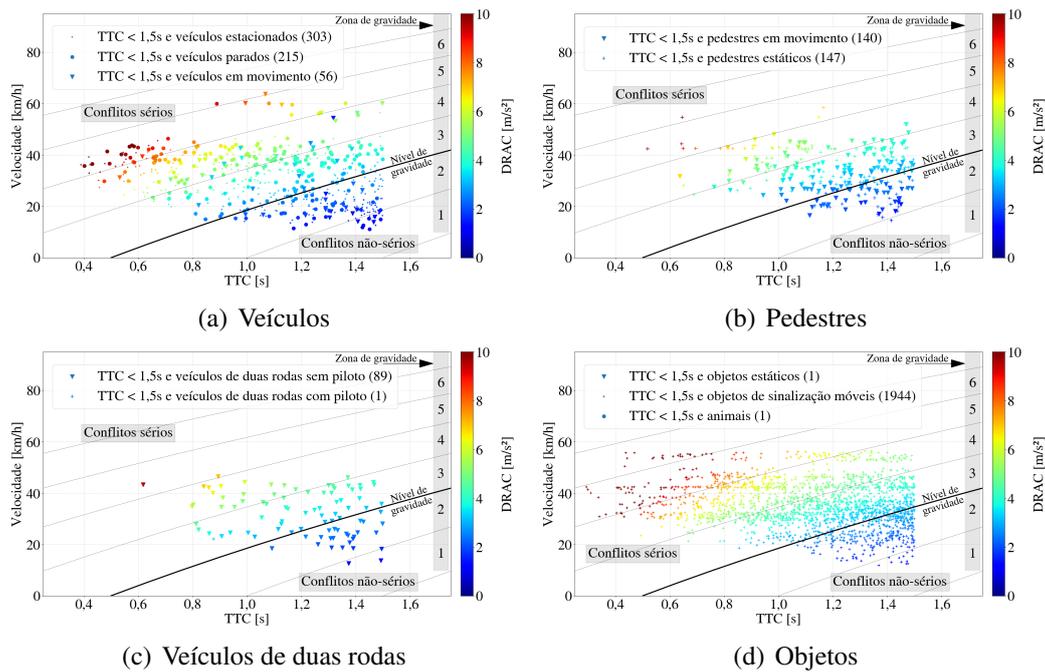
na zona 4. Na Figura 7(a) a maioria dos eventos detectados ocorrem com veículos estacionados na zona 4. Entretanto, observou-se um evento com um veículo em movimento que apresentou uma forte desaceleração. Com relação às interações com pedestres (Figura 7(b)), e veículos de duas rodas (Figura 7(c)), é possível observar que embora existam alguns eventos em zona 3 e zona 4, estes não representam maior risco uma vez que a desaceleração do veículo ego apresenta um nível de risco baixo, como mostrado na Tabela 2. Por último, na Figura 7(d) observa-se que há muitas interações com objetos de sinalização móveis. Isto é esperado uma vez que são objetos sem velocidade.



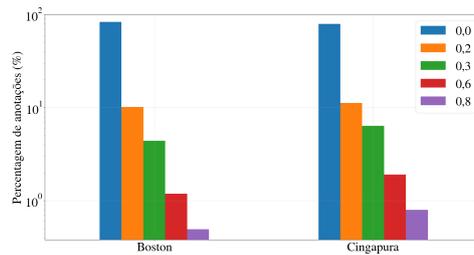
**Figura 7. Eventos de risco moderado a alto em Boston com TTC < 1,5 s.**

No subconjunto de Cingapura (Figura 8) observa-se a mesma tendência descrita de Boston, com a diferença de que existem eventos com maior velocidade e eventos na zona de gravidade 6. Na Figura 8(a) a maioria de eventos detectados ocorrem com veículos parados na zona 4 e zona 5. Entretanto, se observam alguns eventos com forte desaceleração tanto com veículos parados como com outros veículos em movimento. Com relação às interações com pedestres (Figura 8(b)), alguns eventos mostram um risco de colisão alto, tanto para pedestres em movimento como estáticos. Isto pode ser atribuído às diferenças de velocidade entre o veículo ego e os pedestres, o que mostra um TTC baixo; já comparado com o DRAC, pode se considerar que existe um nível de risco moderado. Por último, as interações com veículos de duas rodas e objetos de sinalização móveis (Figuras 8(c) e 8(d)) mostram um comportamento semelhante ao observado no subconjunto de Boston, com interações com objetos sem velocidade.

Por fim, analisa-se a proporção de interações que ocorrem abaixo do limite de 1,5 s. A Figura 9 mostra que os eventos de alto risco representam menos de 2%, com a maioria dos eventos ocorrendo em interações com objetos sem mobilidade, como veículos estacionados e objetos de sinalização móveis. Enquanto isso, eventos com algum nível de risco representam cerca de 10% de todos os dados analisados. Por outro lado, os eventos de não conflito representam mais de 80% das interações com o veículo ego.



**Figura 8. Eventos de risco moderado a alto em Cingapura com  $TTC < 1,5$  s.**



**Figura 9. Volume de anotações baseado no coeficiente de risco da Tabela 2.**

Embora o veículo ego mantenha uma velocidade média dentro da regulamentação de cada cidade, é possível perceber ainda eventos de risco com relação a ele. Isto se observa também na tendência do TTC, dada a proximidade em tempo do AV com outros objetos detectados ao redor, ou da DRAC, que mostra que assim que o AV se aproxima de outros objetos detectados aumenta a sua desaceleração de forma progressiva. Por outro lado, há muitas interações com objetos estáticos, que se infere estar relacionado com o ambiente onde o AV está se deslocando (rodovias secundárias e terciárias maiormente), como pelas áreas que percorre (áreas urbanas residenciais e industriais).

Uma vantagem da análise de dados através de sensores exteroceptivos é que o monitoramento da segurança no trânsito não se limitará apenas aos veículos. Isto é observado nos nossos resultados, onde diversas interações com pedestres e veículos de duas rodas (estáticos ou em movimento) aconteceram de forma aleatória. Isso é importante considerando que além do comportamento ao dirigir, também é possível estabelecer quais são as prioridades do sistema autônomo na tomada de decisões. Portanto, a análise de segurança em AVs é mais relevante levando-se em consideração práticas de responsabilidade e regulamentações de trânsito, onde no futuro o ser humano terá uma contribuição passiva para o sistema autônomo, o que é um cenário desafiador na avaliação de risco.

## 6. Conclusões

Este estudo explora o potencial do uso de dados de AVs para a identificação de eventos de risco no trânsito por meio de SSMs. Um processo detalhado de análise dos dados é apresentado neste estudo. É possível observar o potencial do AV em termos de capacidade de detecção e processamento para fazer observações detalhadas do ambiente externo através dos sensores exteroceptivos como o LiDAR e a câmera. Assim, neste trabalho foi apresentada uma análise de segurança baseada em métricas SSMs tradicionais, como o TTC, a DRAC e o PET, que são métricas que podem mostrar alguns padrões de comportamento de condução do sistema autônomo. O conjunto de dados foi enriquecido com dados da infraestrutura rodoviária, a fim de monitorar como comporta-se o AV em relação às regulamentações de trânsito. Por outro lado, apesar de não haver dados sobre a taxa de acidentes das cidades aonde o AV coletou dados, é possível analisar todas as interações que podem representar algum risco para o AV.

Como desafios futuros, a implementação de um algoritmo para reduzir o processamento de dados dos sensores exteroceptivos no AV torna-se importante para diminuir a sobrecarga gerada pelo volume de dados na amostragem para a análise de segurança. Por exemplo, diminuir o fluxo de dados de objetos estáticos detectados, estimar quais eventos podem ser mais relevantes (como cruzamentos, faixas de pedestres, entre outros). Isto é importante para a transmissão e o compartilhamento de dados com outros veículos, seja por um dispositivo de prateleira, em comunicação V2X ou celular.

## 7. Agradecimentos

Este trabalho foi parcialmente financiado pelas agências de fomento CAPES - Código 001, CNPq, FAPERJ, e pelo processo nº 15/24494-8, da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP).

## Referências

- Alghodhaifi, H. e Lakshmanan, S. (2020). Simulation-based model for surrogate safety measures analysis in automated vehicle-pedestrian conflict on an urban environment. Em *Auton. Syst.: Sens. Process. Secur. Veh. Infrastruct.*, volume 11415, p. 8–21.
- Allen, B. L., Shin, B. e Cooper, P. J. (1978). Analysis of traffic conflicts and collisions. *Transp. Res. Rec.*
- Almqvist, S., Hydén, C. e Risser, R. (1991). Use of speed limiters in cars for increased safety and a better environment. *Transp. Res. Rec.*
- Aycard, O., Baig, Q., Bota, S., Nashashibi, F., Nedevschi, S., Pantilie, C., Parent, M., Resende, P. e Vu, T. (2011). Intersection safety using lidar and stereo vision sensors. Em *IEEE Intell. Veh. Symp. (IV)*, p. 863–869.
- Bellet, T., Cunneen, M., Mullins, M., Murphy, F., Pütz, F., Spickermann, F., Braendle, C. e Baumann, M. F. (2019). From semi to fully autonomous vehicles: New emerging risks and ethico-legal challenges for human-machine interactions. *Transp. Res. Part F: Traffic Psychol. Behav.*, 63:153–164.
- Betz, J., Heilmeyer, A., Wischnewski, A., Stahl, T. e Lienkamp, M. (2019). Autonomous driving—a crash explained in detail. *Appl. Sci.*, 9(23).

- Caesar, H., Bankiti, V., Lang, A. H., Vora, S., Liong, V. E., Xu, Q., Krishnan, A., Pan, Y., Baldan, G. e Beijbom, O. (2020). nuScenes: A multimodal dataset for autonomous driving. Em *IEEE Conf. Comput. Vision Pattern Recognit. (CVPR)*, p. 11618–11628.
- Campbell, K. (2012). *The SHRP 2 Naturalistic Driving Study: Addressing Driver Performance and Behavior in Traffic Safety*. Transp. Res. Board.
- Dingus, T. A., Klauer, S. G., Neale, V. L., Petersen, A., Lee, S. E., Sudweeks, J., Perez, M. A., Hankey, J., Ramsey, D., Gupta, S. et al. (2006). The 100-car naturalistic driving study, Phase II-results of the 100-car field experiment. Relatório técnico, NHTSA.
- Hayward, J. C. (1972). Near-miss determination through use of a scale of danger. *Highway Res. Rec.*
- He, Z., Qin, X., Liu, P. e Sayed, M. A. (2018). Assessing surrogate safety measures using a safety pilot model deployment dataset. *Transp. Res. Rec.*, 2672(38):1–11.
- Hydén, C. (1996). Traffic conflicts technique: state-of-the-art. *Traffic Safety Work with Video Processing*, 37:3–14.
- Hydén, C. (1987). *The Development of a Method for Traffic Safety Evaluation: The Swedish Traffic Conflicts Technique*. PhD thesis, Lund University, Sweden.
- Johnsson, C., Laureshyn, A. e Ceunynck, T. D. (2018). In search of surrogate safety indicators for vulnerable road users: a review of surrogate safety indicators. *Transp. Rev.*, 38(6):765–785.
- Kilicarslan, M. e Zheng, J. Y. (2019). Predict vehicle collision by TTC from motion using a single video camera. *IEEE Trans. Intell. Transp. Syst.*, 20(2):522–533.
- Li, Y., Lu, J. e Xu, K. (2017). Crash risk prediction model of lane-change behavior on approaching intersections. *Discrete Dyn. Nat. Soc.*, 2017.
- Nodine, E., Stevens, S., Lam, A., Jackson, C., Najm, W. G. et al. (2015). Independent evaluation of light-vehicle safety applications based on vehicle-to-vehicle communications used in the 2012-2013 safety pilot model deployment. Relatório técnico, NHTSA.
- Ortiz, F. M., Sammarco, M., Costa, L. H. M. K. e Detyniecki, M. (2020). Vehicle telematics via exteroceptive sensors: A survey. *arXiv:2008.12632*.
- SAE (2018). SAE standard J3016: Taxonomy and definitions for terms related to on-road motor vehicles. Relatório técnico, Society of Automotive Engineers (SAE).
- Tarko, A., Davis, G., Saunier, N. e Sayed, T. (2009). Surrogate measures of safety. *Safe Mobility: Challenges, Method. Solutions*, 11:383–405.
- Virdi, N., Grzybowska, H., Waller, S. T. e Dixit, V. (2019). A safety assessment of mixed fleets with connected and autonomous vehicles using the surrogate safety assessment module. *Accid. Anal. Prev.*, 131:95–111.
- Xie, K., Yang, D., Ozbay, K. e Yang, H. (2019). Use of real-world connected vehicle data in identifying high-risk locations based on a new surrogate safety measure. *Accid. Anal. Prev.*, 125:311–319.
- Zhang, J., Wu, K., Cheng, M., Yang, M., Cheng, Y. e Li, S. (2020). Safety evaluation for connected and autonomous vehicles' exclusive lanes considering penetrate ratios and impact of trucks using surrogate safety measures. *J. Adv. Transp.*, 2020:1–16.