

CENÁRIOS CRÍTICOS NO TRÂNSITO BRASILEIRO: AVALIAÇÃO DA CRITICIDADE A PARTIR DA INTERSECÇÃO DE NORMAS E ALGORITMOS DE SEGURANÇA PARA VEÍCULOS AUTÔNOMOS

Felipe Pires dos Santos, Pietro Lo Presti Campos, Johannes von Lochter e Lester de Abreu Faria
Centro Universitário Facens, Brasil

RESUMO

Os sistemas de assistência ao condutor estão se popularizando cada vez mais no mercado, ajudando os motoristas na hora de tomar decisões nas mais diversas situações. Para que esses sistemas funcionem da melhor maneira possível, surgiram normas e modelos que são capazes de avaliar a segurança por meio de dados coletados em tempo real. O presente trabalho propõe avaliar a criticidade de cenários de trânsito, avaliando os limites da norma ISO 17387:2008 para sistemas de alerta ao condutor, em conjunto com o algoritmo *Responsibility-Sensitive Safety* (RSS), a fim de determinar o momento exato para alertar o condutor. Para isso, optou-se pela testagem dos algoritmos em simulações, por meio do simulador CARLA, os quais apontaram resultados promissores na utilização de ambos os métodos quando aplicados em conjunto na avaliação de criticidade.

PALAVRAS-CHAVE

Assistência ao Condutor, Análise de Criticidade, ISO 17387, *Responsibility-Sensitive Safety*

1. INTRODUÇÃO

No Brasil, segundo dados do Ministério da Infraestrutura e da SENATRAN - Secretaria Nacional de Trânsito, em outubro de 2021, cerca de 27% da frota nacional era composta por veículos de usuário vulnerável (motocicleta, motoneta etc.) (BRASIL, 2021). Estes tipos de veículos são os que apresentam os maiores riscos no trânsito, seja por seu tamanho reduzido, seja por algum padrão de condução específico.

Paralelamente, uma das principais causas de acidente de trânsito com esses veículos está diretamente ligada ao ponto cego de visão dos motoristas, conforme mostra o relatório da EMDURB - Empresa Municipal de Desenvolvimento Urbano e Rural de Bauru, onde na cidade de Bauru, cerca de 40% dos acidentes ocorre pela oclusão de veículos durante manobras, como eventuais mudanças de faixa (Liborio, 2015).

Atualmente existem diferentes soluções para sistemas de assistência ao condutor, dos quais podem-se citar câmeras externas ou outros sensores, os quais são capazes de suprir parte dessa necessidade de monitoramento dos pontos cegos de veículos. Soluções visuais, baseadas em sensores do tipo “câmera”, possuem um custo relativamente baixo, contudo, possuem dificuldades em trabalhar com cenários de pouca luz ou baixa visibilidade (Pourhasan Nezhad et al, 2021).

Por outro lado, soluções não-visuais, baseadas principalmente em sensores radar, apresentam um custo mais elevado, entretanto podendo trabalhar em diversas condições ambientais, apesar de possuírem habilidades limitadas em situações complexas de trânsito (Zhao et al, 2019).

Além dos equipamentos de monitoramento, é necessária a utilização de algoritmos que forneçam uma avaliação da situação, estabelecendo o nível de periculosidade para a realização de manobras viáveis. Com a emergente variedade de veículos autônomos, surgiram também métodos para avaliar quando um cenário de trânsito se torna de alto risco, como é o caso do *Responsibility-Sensitive Safety* (RSS), o qual se mostra como um conjunto de regras semânticas traduzidas para o contexto matemático, a fim de encontrar a melhor resposta de direção para o veículo (Shalev-Shwartz, 2017).

Dessa forma, simultaneamente, diferentes normas e técnicas são criadas a fim de padronizar e estabelecer condições mínimas que os sistemas de assistência ao condutor devam atingir, a fim de garantir um incremento na segurança. Esse é o caso da norma ISO 17387:2008, que trata especificamente de sistemas de assistência ao condutor para mudanças de faixa (ISO, 2008).

Dessa forma, o presente estudo buscou realizar um comparativo entre os métodos de análise de criticidade, como o RSS e a ISO 17387:2008, em situações de trânsito, a fim de estabelecer os pontos-chaves de cada um, bem como desenvolver um novo modelo para possíveis aplicações em sistemas de assistência ao condutor, voltados principalmente para o monitoramento das zonas de ponto-cego. As seções estarão distribuídas da seguinte maneira: a Seção 2 apresentará uma revisão da literatura com os principais conceitos dos métodos de avaliação de criticidade utilizados no trabalho, enquanto a Seção 3 descreverá a aplicação das metodologias selecionadas. Por fim, as seções 4 e 5 apresentarão os resultados obtidos e as respectivas conclusões, além de sugestões para futuros trabalhos.

2. REVISÃO DA LITERATURA

A dificuldade na determinação da criticidade no tráfego aumenta proporcionalmente a complexidade da situação. A complexidade de situações de trânsito é uma função complexa de diversos fatores, que vão desde o cenário, como a curvatura do trecho, largura da pista e intensidade do tráfego, até fatores psicológicos, como a carga emocional do condutor (ROMMERSKIRCHEN et al. 2013).

Segundo Minderhoud e Bovy (2001), em situações de trânsito, quanto maior a velocidade dos veículos, maior será o estresse ao qual o condutor está submetido, afetando diretamente a análise de risco de situações, como a troca de faixa.

2.1 ISO 17387:2008

A ISO 17387, “Sistemas de transporte inteligente — Sistemas de ajuda à decisão de mudança de faixa — Requisitos de performance e procedimentos de testes”, é responsável por regulamentar os sistemas de assistência ao condutor ligados a manobras como mudança de faixa, ajudando na tomada de decisão na direção.

Para isso, a norma estabelece “zonas adjacentes” ao “veículo-sujeito”, ilustradas na Figura 1. Na primeira, chamada zona de ponto cego, ou *blind spot*, é regulamentada a área mínima que sistemas de monitoramento do ponto cego devem cobrir para atingir os requisitos estabelecidos, e o alerta deve ser dado ao condutor. Essas áreas possuem uma largura de 2,5 metros e estendem-se por 3 metros a partir da traseira do veículo, sendo representadas na Figura 1 pelas áreas mais escuras.

A segunda região é maior que a primeira, cobrindo a área entre seis metros (6m) a partir da lateral do veículo, e até 30 metros (30m) para trás. Esse é o espaço mínimo que um sistema de alerta para veículos se aproximando deve cobrir. A Norma especifica que na área de *blind spot* o aviso deve ser dado ao condutor, sempre, mas não especifica o momento certo em relação a área de veículos se aproximando, na qual o aviso pode ser dado.




Figura 1. Diagrama dos requerimentos de alerta
 Fonte: (International Organization for Standardization, 2008)

2.2 Responsibility-Sensitive Safety (RSS)

A norma ISO regulamenta a aplicação dos sistemas, mas ainda trata de forma generalizada diferentes velocidades. Fu e colaboradores (FU et al., 2020) destacam que, se as mesmas regras de alerta forem aplicadas em diferentes velocidades, a taxa de falsos alertas aumenta, o que diminui a aceitação do sistema pelo motorista. Uma possível alternativa é a utilização do modelo *Responsibility-Sensitive Safety* (RSS) (SHALEV-SHWARTZ et al., 2017).

O RSS, inicialmente, apresenta uma abordagem voltada para a aplicação em veículos autônomos, trabalhando em três planos: monitorar, planejar e agir. Todavia, o presente estudo atribui uma nova aplicação ao algoritmo, voltada para sistemas de assistência ao condutor, utilizando-se apenas do monitoramento e parte do planejamento para determinar o risco em situações de troca de faixa, por exemplo.

Dessa forma, a partir da física do movimento, o modelo traz duas equações, de distância mínima, longitudinal e lateral, as quais definem uma área de segurança entre os veículos. A primeira trata-se de uma formalização da regra "Não colidir com alguém por trás". Assim, baseado em fatores pré-estabelecidos, como tempo de resposta e picos de aceleração de ambos os veículos, é possível estabelecer uma distância para que no pior cenário possível de frenagem, não haja colisão entre eles.

A Equação que apresenta a forma como é calculada essa distância longitudinal mínima segura é dada pela Equação 1.

$$d_{min} = \left[v_r \rho + \frac{1}{2} a_{max} \rho^2 + \frac{(v_r + \rho a_{max})^2}{2\beta_{min}} - \frac{v_f^2}{2\beta_{max}} \right] \quad (1)$$

em que v_r e v_f representam as velocidades longitudinais dos veículos, traseiro e frontal, respectivamente, a_{max} a aceleração máxima que o veículo pode atingir, ρ o tempo de resposta do condutor, β_{min} e β_{max} as acelerações de frenagem, mínima e máxima, respectivamente.

Semelhantemente, a distância lateral mínima segura é uma representação da regra empírica "Não cortar abruptamente a pista", a qual funciona da mesma forma que a anterior, porém com os parâmetros laterais acrescidos de uma margem de flutuação μ , conforme descreve a Equação 2.

$$d_{min} = \mu + \left[\frac{(v_1 + v_{1\rho})}{2} \rho + \frac{v_{1\rho}^2}{2\beta_{1,lat,min}} - \left(\frac{(v_2 + v_{2\rho})}{2} \rho + \frac{v_{2\rho}^2}{2\beta_{2,lat,min}} \right) \right] \quad (2)$$

tal que: μ representa uma margem de flutuação lateral, v_1 e v_2 as velocidades laterais exercidas pelos veículos, $\beta_{1,lat,min}$ e $\beta_{2,lat,min}$, as acelerações de frenagem lateral. $v_{1\rho}$ e $v_{2\rho}$ é dado pela soma da respectiva velocidade com o produto entre o tempo de resposta e a aceleração lateral máxima.

Essas equações utilizam como variáveis apenas as velocidades de ambos os veículos, sendo os demais parâmetros constantes que definem o tipo do padrão de condução a ser adotado para os cálculos (Shalev-Shwartz et al., 2017).

2.3 Parametrização RSS

Os parâmetros constantes são o que conferem o nível de segurança ao modelo do RSS. Xu e colaboradores (Xu et al., 2021) destacam que qualquer mudança sutil nesses valores ocasiona um cálculo diferente da distância de segurança RSS, resultando em uma estratégia de decisão do veículo totalmente divergente.

O modelo do RSS unicamente aplicado, por trazer uma abordagem pensada para trabalhar com o único veículo e no pior caso possível, retorna uma resposta muito conservativa. Além disso, uma combinação inapropriada dos parâmetros pode atribuir ao RSS uma obstrução do fluxo de trânsito (Chai et al., 2020).

Pensando nisso, Rodionova et al. (2020) buscaram explorar os limites desses parâmetros, aplicando-os em um desafio de direção autônoma no simulador CARLA (DOSOVITSKIY et al, 2017) e registrando seus resultados. A partir de então, conseguiu extrair 3 variações de parâmetros que conferem diferentes tempos para completar o circuito. Os resultados obtidos podem ser observados na Tabela 1.

Tabela 1. Parâmetros RSS para experimento desafio CARLA

	ρ (s)	$a_{lon,max}$ (m/s ²)	$\beta_{lon,min}$ (m/s ²)	$\beta_{lon,max}$ (m/s ²)	$\beta_{lat,min}$ (m/s ²)	$a_{lat,max}$ (m/s ²)	μ (m)
Padrão	1,0	3,5	4,0	8,0	0,8	0,2	0,0
Conservativo	1,94	5,91	4,13	9,50	0,86	0,45	0,07
Agressivo	0,53	4,10	4,64	8,03	0,96	0,43	0,07

Fonte: (RODIONOVA et al 2020).

Os Autores do presente trabalho concluem que os três resultados evitam colisões com outros veículos, mas trazem comportamentos divergentes. O padrão agressivo foi capaz de cobrir maiores distâncias, ao custo de ficar a uma distância próxima de outros veículos. Enquanto isso, o padrão conservativo apresentou uma distância mais segura dos demais agentes, porém custou mais tempo para percorrer o caminho (RODIONOVA et al., 2020).

3. METODOLOGIA

A realização de testes de segurança veicular em um cenário real possui um custo, logístico e de reparação, relativamente alto. Por conta disso, para garantir o máximo de segurança no desenvolvimento de tecnologias automotivas, uma alternativa é a utilização complementar de testes realizados em softwares de simulação (BELBACHIR et al, 2012).

CARLA (Car Learning to Act) é um simulador de código aberto destinado ao uso em pesquisas acadêmicas na área de direção autônoma, fornecendo recursos para o treinamento, verificação e validação de sistemas de condução urbana (DOSOVITSKIY et al, 2017). Além de sua alta fidelidade com o ambiente real, ele também traz a possibilidade de um robusto sistema de customização do ambiente, possibilitando milhares de aplicações.

Os experimentos foram conduzidos, portanto, no simulador Carla. Neste caso, foram definidos cenários em que motocicletas se aproximam do veículo principal. Para isso, foi utilizado um computador com as seguintes configurações e softwares:

- Processador Intel Core i7-10750H;
- Placa de vídeo GeForce RTX 2060;
- 16 GB memória RAM;
- Sistema operacional 64 bits Ubuntu 18.04.
- CARLA *Simulator* 0.9.11

A partir delas, o simulador foi ajustado para trabalhar em uma frequência de atualização de 83 frames por segundo (FPS), valor utilizado para a medição de tempo em simulação, posteriormente convertido em segundos.

3.1 Catálogo de Cenários

A fim de padronizar os principais testes a serem realizados, inicialmente foi elaborado um catálogo de cenários, o qual contém um compilado de 9 acidentes de trânsito envolvendo motociclistas e veículos de quatro rodas. Os cenários foram extraídos de relatórios fornecidos pela parceria com o Grupo Bosch, com dados da Empresa Municipal de Desenvolvimento de Campinas (EMDEC). Todos os acidentes catalogados aconteceram na malha urbana da cidade de Campinas, em São Paulo, Brasil.

Com as informações disponibilizadas, foram escolhidas diferentes localizações em mapas, nativos do *CARLA Simulator*, para a reconstrução de cada cenário. Os locais não são totalmente idênticos ao real, contudo, servem de base para a análise, assim como os veículos envolvidos, que foram selecionados da biblioteca disponibilizada pelo simulador. As condições de reprodução dos cenários reais levaram em conta, principalmente, a velocidade e os tipos de manobras realizadas pelos envolvidos.

Com isso, foram adicionados aos códigos os cálculos de segurança do RSS que viriam a ser utilizadas na avaliação da criticidade em cada cenário. Também era necessário um método rápido de validação de valores dos algoritmos, tendo-se optado então pela utilização de indicadores visuais, como a utilização de caixas delimitadoras, as quais fornecerão a noção de quando o veículo alvo estará inserido em alguma região de interesse.

O primeiro conjunto de caixas delimitadoras representam as áreas definidas pela ISO 17387, onde a região de *blind spot* será tratada como a zona de perigo, ou *danger zone*, e a região de monitoramento de veículos que se aproximam receberá o tratamento de zona de atenção, ou *warning zone*. Todas essas regiões possuem um tamanho fixo, conforme a norma estabelece, e podem ser visualizadas conforme a Figura 3.



Figura 3. Visualização das caixas delimitadoras ISO 17387

Fonte: Elaborado pelo autor

Simultaneamente, houve a construção de uma caixa delimitadora das regiões estipuladas pelo RSS, essa, porém, não possuindo tamanho fixo, sendo ajustada de acordo com cada valor retornado pelo algoritmo, definindo o comprimento da região a partir da distância mínima longitudinal, enquanto a largura é dada pela equação de distância mínima lateral.

4. RESULTADOS E DISCUSSÕES

A primeira hipótese analisada foi a relação entre os espaços definidos pelo algoritmo RSS e a norma ISO 17387, a fim de determinar quando a situação se torna crítica para o veículo em cada um dos algoritmos. Para este caso, foi utilizado um cenário em que ocorre uma manobra de mudança de faixas, na qual o veículo principal executa a manobra em uma velocidade aproximada de 16,66 m/s (60 km/h), enquanto uma motocicleta se aproxima com cerca de 22,22 m/s (80 km/h). Os parâmetros de condução do RSS permaneceram inalterados e padrão.

O resultado pode ser observado pela Figura 4, em que há quatro gráficos da relação entre o tempo (em segundos) e a velocidade relativa entre ambos os veículos. O primeiro gráfico representa o estado do veículo de acordo com a ISO, assim como o segundo e terceiro representam a situação de segurança de acordo com o RSS, longitudinal e lateral. Por fim, o último apresenta a análise geral do RSS, que mescla os dois gráficos anteriores.

Nos gráficos, velocidades acima de zero representam a motocicleta se afastando, enquanto as velocidades abaixo representam a motocicleta se aproximando. Observa-se que, durante a maior parte da simulação, a ISO determina a situação como atenção, ao passo que o RSS só começa a estabelecer um estado de atenção quando o alvo começa a se aproximar com alta velocidade.

A segunda hipótese estudada avalia o impacto da velocidade na avaliação de criticidade. No primeiro caso, a motocicleta se aproximava a uma velocidade média relativamente alta, o que resultou em uma janela de atenção e perigo de aproximadamente 3,7 segundos.

O segundo teste, portanto, ocorrerá no mesmo cenário, reproduzindo as mesmas manobras, entretanto, agora o veículo-sujeito executa a manobra em uma velocidade aproximada de 8,33 m/s (30 km/h), enquanto o alvo se aproxima com a cerca de 13,89 m/s (50 km/h).

A Figura 5 apresenta os gráficos comparativos dessa simulação, na qual é possível notar que a janela de atenção/perigo possui um valor menor, representando um tempo aproximado de 1,7 segundos.

A última verificação trata do impacto da alteração dos parâmetros na avaliação de criticidade e no tempo de alerta ao condutor. Para isso, os parâmetros do RSS foram alterados, de acordo com a Tabela 1, para as velocidades já usadas anteriormente. O tempo de alerta é determinado a partir do momento em que a situação passa de segura para atenção, indo até o fim da simulação, onde ocorre a colisão. Os resultados podem ser observados conforme a Tabela 2, onde a velocidade média/alta para o motociclista é de 22,22 m/s, e para o carro é de 16,66 m/s. Velocidade baixa: motociclista = 13,89 m/s, carro = 8,33m/s.

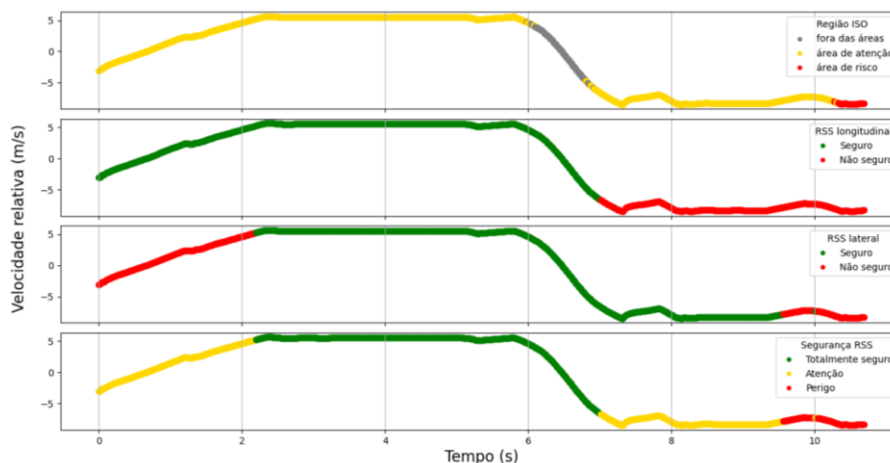


Figura 4. Relação entre as metodologias de análise de criticidade
Fonte: Elaborado pelo autor

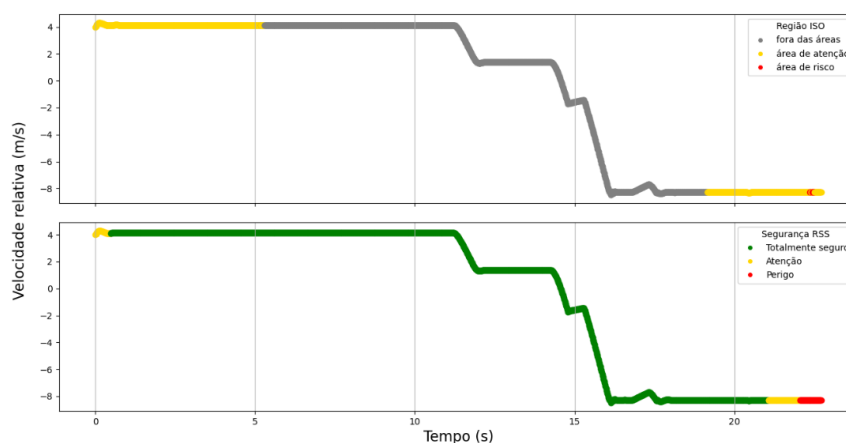


Figura 5. Relação entre as metodologias de análise de criticidade
 Fonte: Elaborado pelo autor

Tabela 2. Impacto da alteração de parâmetros no tempo de alerta

Parâmetros / modelo	Velocidade	tempo de alerta (s)
ISO	média/alta	3.6
ISO	baixa	3.8
Padrão	média/alta	3.7
Padrão	baixa	1.7
Conservativo	média/alta	4.2
Conservativo	baixa	4.2
Agressivo	média/alta	3.6
Agressivo	baixa	1.7

Fonte: Elaborado pelo autor

5. CONCLUSÃO

Este trabalho apresenta um estudo sobre metodologias de análise de riscos de segurança no trânsito, capaz de identificar possíveis cenários críticos e enviar um alerta prévio ao condutor, para aplicações viáveis em sistemas de assistência ao condutor. O estudo aborda, principalmente, a intersecção entre duas metodologias existentes: a avaliação dada pela norma ISO 17387:2008, e a visão da situação por meio do algoritmo *Responsibility-Sensitive Safety* (RSS).

A partir dos testes realizados, é possível observar que o modelo proposto pela ISO, quando singularmente aplicado em um sistema, torna imprecisa a determinação do momento exato para fornecer um alerta ao condutor, tendo em vista que, nem sempre que um veículo está na zona de atenção ele realmente representa um perigo, como em casos em que o alvo está se afastando.

Assim, a ISO pode ser utilizada como a base para um sistema de avaliação da criticidade, entretanto, adquire maior confiabilidade e representatividade quando usada com uma mesclagem com algoritmos como o RSS. A figura 5 foi capaz de demonstrar que a mescla de ambos os algoritmos se mostra capaz de estimar, com valores aceitáveis, um tempo para o alerta ao condutor.

Além disso, o RSS se provou eficiente em mostrar diferentes resultados para diferentes velocidades. A diferença entre os tempos, descritos na seção anterior, valida o conceito de que, quanto maior a velocidade, mais tempo é necessário para o condutor reagir corretamente mantendo o controle do veículo. A alteração dos

parâmetros, no entanto, mostrou ainda que padrões conservativos não causam uma diferença significativa no tempo de alerta.

Por fim, o estudo traz apenas algumas das possibilidades de análise da criticidade de um sistema, podendo haver outras maneiras que também se adequem aos objetivos. O estudo ainda deixa em aberto a aplicação de sistemas de sensoriamento mais robustos, bem como um estudo minucioso dos padrões de condução brasileiro, para a aplicação dos parâmetros de direção do algoritmo RSS em uma gama maior de cenários.

Conclui-se, portanto, que a intersecção entre os métodos avaliativos da ISO e o RSS torna-se admissível em aplicações de sistemas de alerta ao condutor, atingindo o principal objetivo da pesquisa e melhorando a qualidade de direção. Contudo, esse modelo ainda carece de aplicações em cenários reais.

AGRADECIMENTOS

Este trabalho é fruto do financiamento da Fundação de Desenvolvimento da Pesquisa (FUNDEP), por meio do programa Rota 2030. Agradecemos, portanto, à toda equipe do projeto Rota 2030 do Centro Universitário Facens, bem como aos pesquisadores do Instituto Tecnológico de Aeronáutica (ITA) e do *Center of Automotive Research on Integrated Safety Systems and Measurement Area (CARISSMA)*. Por fim, agradecemos ao grupo BOSCH e ao grupo Stellantis pela parceria e apoio ao projeto.

REFERÊNCIAS

- Belbachir, Assia et al. Simulation-driven validation of advanced driving-assistance systems. *Procedia-Social and Behavioral Sciences*, v. 48, p. 1205-1214, 2012.
- Brasil. Ministério da Infraestrutura. Secretaria Nacional de Trânsito. Frota de Veículos – 2021. Brasília, 2021. 1 p.
- Chai, Chen et al. Safety evaluation of responsibility-sensitive safety (RSS) on autonomous car-following maneuvers based on surrogate safety measurements. In: 2019 IEEE Intelligent Transportation Systems Conference (ITSC). IEEE, 2019. p. 175-180.
- Dosovitskiy, Alexey et al. CARLA: An open urban driving simulator. In: Conference on robot learning. PMLR, 2017. p. 1-16.
- Fu, Rui et al. Research on the Influence of Vehicle Speed on Safety Warning Algorithm: A Lane Change Warning System Case Study. *Sensors*, v. 20, n. 9, p. 2683, 2020.
- ISO - International Organization for Standardization. ISO 17387:2008: Intelligent transport systems — Lane change decision aid systems (LCDAS) — Performance requirements and test procedures. Geneva: ISO, 2008, 49 p.
- Liborio, M. "Pontos cegos" causam 40% dos acidentes, estima Emdurb. *Jornal da Cidade NET*, Bauru, ano 48, n. 16.538, 24 jul. de 2015. Disponível em: <https://www.jcnet.com.br/noticias/geral/2015/07/443504--pontos-cegos--causam-40--dos-acidentes--estima-emdurb.html>. Acesso em: 8 jan. 2022.
- Minderhoud, Michiel M.; Bovy, Piet HL. Extended time-to-collision measures for road traffic safety assessment. *Accident Analysis & Prevention*, v. 33, n. 1, p. 89-97, 2001.
- Pourhasan Nezhad, Arash; Ghatee, Mehdi; Sajedi, Hedieh. Blind Spot Warning System based on Vehicle Analysis in Stream Images by a Real-Time Self-Supervised Deep Learning Model. 2021.
- Rodionova, Alëna et al. How safe is safe enough? Automatic safety constraints boundary estimation for decision-making in automated vehicles. In: 2020 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2020. p. 1457-1464.
- Rommerskirchen, Christoph; Helmbrecht, Magnus; Bengler, Klaus. Increasing complexity of driving situations and its impact on an ADAS for anticipatory assistance for the reduction of fuel consumption. In: 2013 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2013. p. 573-578.
- Shalev-Shwartz, Shai; Shammah, Shaked; Shashua, Amnon. On a formal model of safe and scalable self-driving cars. arXiv preprint arXiv:1708.06374, 2017.
- Sligar, Arien P. Machine learning-based radar perception for autonomous vehicles using full physics simulation. *IEEE Access*, v. 8, p. 51470-51476, 2020.
- Xu, Xiaoyan et al. Calibration and evaluation of the Responsibility-Sensitive Safety model of autonomous car-following maneuvers using naturalistic driving study data. *Transportation research part C: emerging technologies*, v. 123, p. 102988, 2021.
- Zhao, Yiming et al. Camera-based blind spot detection with a general purpose lightweight neural network. *Electronics*, v. 8, n. 2, p. 233, 2019.