

VEÍCULOS AUTÔNOMOS: REVISÃO BIBLIOGRÁFICA DA INTEGRAÇÃO ENTRE ANÁLISE DE DADOS E ESTATÍSTICA NA TOMADA DE DECISÃO EM TEMPO REAL

AUTONOMOUS VEHICLES: A LITERATURE REVIEW OF THE INTEGRATION
OF DATA ANALYSIS AND STATISTICS IN REALTIME DECISION-MAKING

Ciências Exatas e da Terra, Engenharias • 11/06/2026

REGISTRO DOI: [10.70773/revistatopicos/781158911](https://doi.org/10.70773/revistatopicos/781158911)

Henrique Adriano Rodrigues Do Nascimento¹

Siomara Dias da Rocha²

RESUMO

Os veículos autônomos representam uma das mais expressivas convergências contemporâneas entre engenharia mecatrônica, ciência de dados e estatística aplicada. Este artigo discute como métodos estatísticos clássicos (filtros de Kalman, inferência bayesiana e modelos probabilísticos) convivem e se integram com algoritmos modernos de aprendizado profundo (redes convolucionais, redes recorrentes e transformadores) para sustentar a tomada de decisão em tempo real em sistemas de condução automatizada. Por meio de revisão bibliográfica narrativa abrangendo o período de 2018 a 2024 e da análise de estudos de caso nacionais e internacionais, examinam-se os principais desafios técnicos, regulatórios e éticos do setor. Os resultados indicam que a integração robusta entre estatística inferencial e aprendizado de máquina constitui fator decisivo para a segurança operacional, evidenciada pela redução de 80% em colisões com lesão observada na frota da empresa Waymo em comparação com motoristas humanos. Conclui-se que o Brasil, apesar de possuir competência científica reconhecida internacionalmente, enfrenta lacuna regulatória e de infraestrutura que limita a adoção da tecnologia em larga escala.

Palavras-chave: Veículos autônomos; análise de dados; estatística; aprendizado de máquina; fusão sensorial.

ABSTRACT

Autonomous vehicles represent one of the most significant contemporary convergences between mechatronic engineering, data science and applied statistics. This article discusses how classical statistical methods — Kalman filters, Bayesian inference and probabilistic models — coexist and integrate with modern deep learning algorithms (convolutional networks, recurrent networks and transformers) to support real-time decision-making in

automated driving systems. Through a narrative literature review covering the 2018 to 2024 period and the analysis of national and international case studies, the main technical, regulatory and ethical challenges of the sector are examined. The results indicate that robust integration between inferential statistics and machine learning is a decisive factor for operational safety, evidenced by the 80% reduction in injury crashes observed in the Waymo fleet compared to human drivers. It is concluded that Brazil, despite having internationally recognized scientific competence, faces a regulatory and infrastructure gap that limits large-scale adoption of the technology.

Keywords: Autonomous vehicles; Data Analysis; Statistics; Machine Learning; Sensor Fusion.

1. INTRODUÇÃO

O automóvel, símbolo do desenvolvimento tecnológico do século XX, vem sendo profundamente redefinido pela quarta revolução industrial. A convergência entre sensores embarcados de alta densidade, capacidade de processamento heterogêneo, conectividade celular e algoritmos de inteligência artificial materializa o conceito de veículo autônomo, sistemas capazes de perceber, interpretar e atuar no ambiente viário com mínima ou nenhuma intervenção humana (Li et al., 2022; Badue et al., 2021).

Tal mudança paradigmática não se restringe a um avanço de engenharia: ela reorganiza cadeias produtivas, lança questionamentos éticos inéditos e impõe à estatística e à ciência de dados o papel de espinha dorsal da segurança operacional. A motivação social do tema é evidente. Segundo o Atlas da Violência 2025, o Brasil registrou 34.881 mortes em sinistros de trânsito no ano

de 2023, com taxa de 16,2 óbitos por 100 mil habitantes, o que representa um aumento de 2,9% em relação ao ano anterior (Ipea; FBSP, 2025).

A Administração Nacional de Segurança no Tráfego Rodoviário dos Estados Unidos identificou que o erro do motorista foi reportado como fator crítico em mais de 94% das colisões investigadas, sobre uma amostra estimada em 2.046.000 colisões de veículos leves (Singh, 2015).

A hipótese central que justifica o investimento global em veículos autônomos é, portanto, de natureza estatística: substituir um decisor cognitivamente limitado e propenso a vieses por um sistema computacional cujo comportamento, embora imperfeito, é mensurável, reproduzível e continuamente otimizável (Pham; Stack, 2018; Israelsen, 2025).

Entretanto, conduzir um automóvel em ambiente urbano é uma das tarefas cognitivas mais complexas executadas rotineiramente por seres humanos. Trata-se de um problema de tomada de decisão sequencial sob incerteza, com horizonte temporal variável, espaço de estados de altíssima dimensionalidade e função-custo não trivial, que envolve simultaneamente segurança, conforto, eficiência energética e respeito a normas sociais não escritas (Delgado et al., 2019; Ghasemaghaei, 2019).

Resolver esse problema exige integrar, em milissegundos, dados oriundos de sensores heterogêneos, sistemas de detecção por luz, câmeras, radar, sistemas de posicionamento global e unidades inerciais em representações coerentes do mundo, sobre as quais

algoritmos de planejamento e controle possam operar de modo confiável.

Diante disso, a integração entre análise de dados e estatística transcende seu papel como mero recurso técnico ou operacional. Ela constitui um arcabouço conceitual fundamental que permite aos sistemas digitais autônomos compreender padrões complexos, lidar eficientemente com incertezas inerentes ao ambiente real e responder de maneira adaptativa a situações imprevisíveis (Sparrow et al., 2025; Israelsen, 2025).

Os veículos autônomos exemplificam de forma paradigmática essa integração, ao processarem continuamente grandes volumes de dados para identificar obstáculos em movimento, prever comportamentos de pedestres e de outros veículos e selecionar rotas otimizadas em tempo real.

Este artigo tem por objetivo discutir, sob óptica científica, como métodos estatísticos clássicos e técnicas de aprendizado de máquina se complementam para viabilizar a tomada de decisão em tempo real em veículos autônomos. Especificamente, busca-se: (i) descrever os fundamentos teóricos da fusão sensorial e dos filtros bayesianos recursivos; (ii) caracterizar as principais arquiteturas de aprendizado profundo empregadas em percepção e planejamento; (iii) discutir o estado da arte brasileiro, com ênfase nos projetos universitários de maior destaque; e (iv) analisar as implicações éticas, jurídicas e regulatórias da tecnologia no contexto nacional, à luz do Marco Legal da Inteligência Artificial e do projeto de regulamentação de veículos autônomos em tramitação no Congresso Nacional.

2. FUNDAMENTAÇÃO TEÓRICA

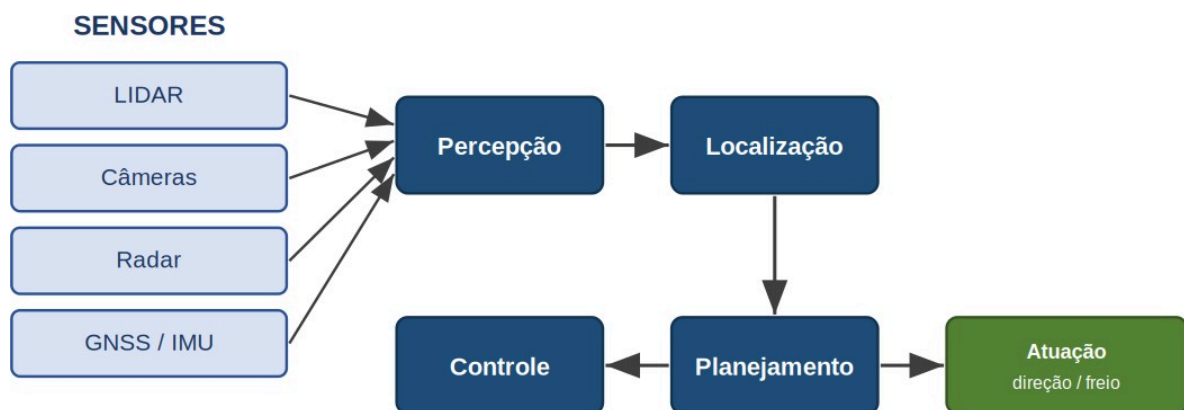
2.1. Conceitos e Princípios dos Veículos Autônomos

A taxonomia de referência mundial para sistemas de condução automatizada é a norma SAE J3016, atualizada em 2021 pela SAE International, que define seis níveis mutuamente exclusivos de automação. O Nível 0 corresponde à ausência de automação; o Nível 1 à assistência ao condutor, com controle de uma única função; o Nível 2 à automação parcial, com controle simultâneo de direção e aceleração ou frenagem sob supervisão humana; o Nível 3 à automação condicional, em que o sistema pode assumir todas as tarefas em condições específicas, mas exige retomada humana quando solicitado; o Nível 4 à automação alta, com operação autônoma em domínio operacional definido, sem necessidade de motorista; e o Nível 5 à automação completa, com operação irrestrita (SAE International, 2021). Essa taxonomia foi adotada pelo Departamento de Transportes dos Estados Unidos como referência regulatória oficial.

Os veículos comercialmente disponíveis no mercado de varejo encontram-se majoritariamente no Nível 2, a exemplo de sistemas como o Autopilot, da Tesla, o Super Cruise, da General Motors, e o Drive Pilot, da Mercedes-Benz. Apenas um número restrito de operações comerciais opera efetivamente no Nível 4, como o serviço Waymo One, em diversas cidades dos Estados Unidos, e o Apollo Go, da empresa Baidu, na China. O Nível 5, por sua vez, permanece um objetivo teórico, ainda não alcançado em condições reais de tráfego (SAE International, 2021).

Do ponto de vista arquitetural, um veículo autônomo pode ser decomposto em quatro módulos funcionais interdependentes: percepção, responsável pela interpretação dos dados sensoriais; localização, encarregada da estimação da posição e orientação do veículo no mundo; planejamento, que define a trajetória e as manobras; e controle, que atua sobre direção, aceleração e freio. Cada módulo opera sob rigorosas restrições de tempo real, exigindo, tipicamente, latência total inferior a 100 milissegundos entre a aquisição sensorial e a atuação efetiva sobre o veículo (Badue et al., 2021; Qian et al., 2025). A Figura 1 ilustra essa arquitetura modular e o fluxo de informação entre seus componentes.

Figura 1: Arquitetura modular de um veículo autônomo.



Latência total típica do ciclo: inferior a 100 milissegundos

Fonte: elaborado pelo autor (2026).

2.2. Sensores e Fusão Sensorial

A percepção robusta do ambiente é prerequisite para qualquer sistema autônomo seguro. Nenhum sensor isoladamente fornece informação completa e confiável em todas as condições: cada modalidade possui pontos fortes e limitações específicas, o que motiva a estratégia de fusão sensorial a combinação probabilística de medições heterogêneas para produzir uma estimativa de estado

mais precisa e robusta do que a obtida por qualquer sensor individual (Yeong et al., 2021; Qian et al., 2025).

O sistema de detecção por luz, conhecido pela sigla LIDAR, é um sensor ativo que emite pulsos laser e mede o tempo de retorno para estimar distâncias, produzindo nuvens de pontos tridimensionais com precisão geométrica milimétrica. O sensor Velodyne HDL-64E S3, amplamente utilizado em pesquisa acadêmica, oferece alcance de até 120 metros, precisão de ± 2 cm, taxa de amostragem de até 2,2 milhões de pontos por segundo e campo de visão horizontal de 360° , operando em comprimento de onda de 903 nm (Velodyne, 2018). Suas principais limitações são o alto custo e o desempenho degradado em chuva forte, neblina e neve.

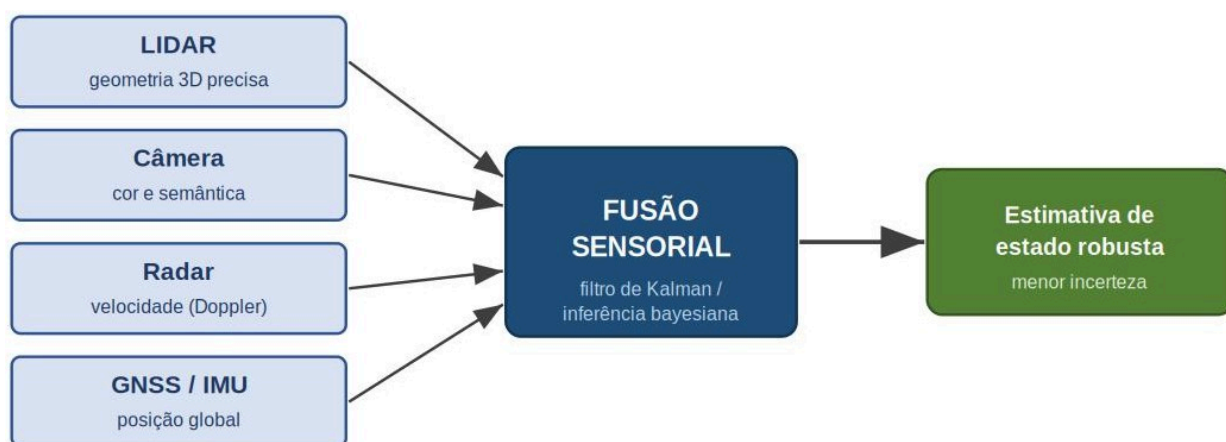
As câmeras de alta resolução são sensores passivos que capturam informação bidimensional rica em textura, cor e semântica, essencial para a leitura de placas, sinais, faixas e semáforos. Configurações estéreo permitem estimar profundidade por triangulação. A empresa Tesla utiliza exclusivamente um conjunto de câmeras em seu sistema de condução autônoma, apostando que redes neurais profundas podem extrair informação geométrica suficiente sem o uso de LIDAR. As limitações das câmeras incluem a sensibilidade a baixa luminosidade, ofuscamento, oclusões e degradação por condições climáticas adversas.

O radar, por sua vez, é um sensor ativo que opera em frequências de micro-ondas, geralmente 77 GHz em aplicações automotivas, e fornece medição direta de velocidade radial por efeito Doppler, mantendo bom desempenho em chuva, neblina e baixa visibilidade. Sua resolução angular, contudo, é tipicamente inferior à do LIDAR. Complementarmente, o sistema global de navegação por satélite

fornece localização absoluta com precisão típica de um a cinco metros, enquanto as unidades de medição inercial suprem o veículo de dados de aceleração e velocidade angular em alta frequência, especialmente em ambientes com bloqueio de sinal, como túneis (Qian et al., 2025).

A literatura reconhece três paradigmas dominantes de fusão sensorial: a fusão precoce, realizada no nível dos dados sensoriais brutos; a fusão intermediária, no nível das características extraídas; e a fusão tardia, no nível das decisões (Qian et al., 2025). Pesquisas comparativas demonstram ganhos substanciais com a fusão. O trabalho de Farag (2021) comprovou que a fusão entre LIDAR e radar, por meio do filtro de Kalman não perfumado, reduziu o erro quadrático médio em 29% em relação ao uso isolado do LIDAR e em 38% em relação ao radar isolado, superando o filtro de Kalman estendido em todas as variáveis de estado avaliadas. A Figura 2 representa esquematicamente esse processo de integração.

Figura 2: Esquema da fusão sensorial multimodal.



A redundância entre modalidades reduz a variância do estimador e mitiga falhas isoladas.

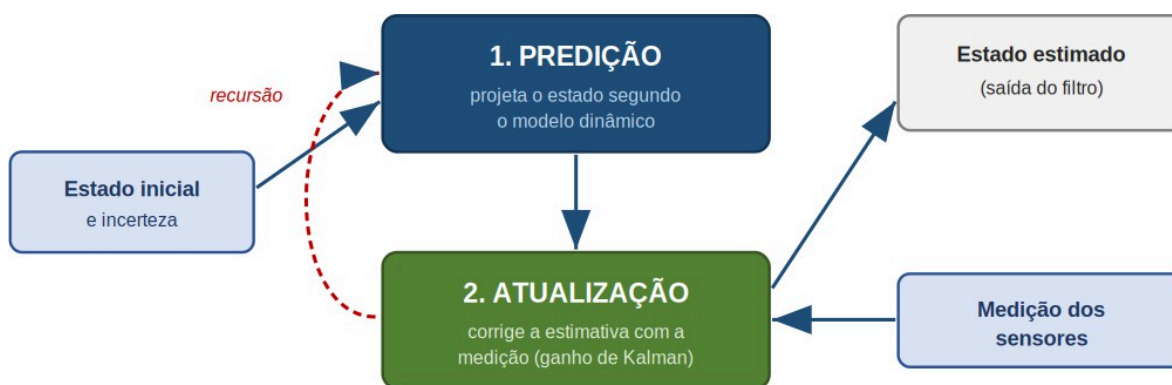
Fonte: elaborado pelo autor com base em Yeong et al. (2021).

2.3. Métodos Estatísticos Aplicados

A condução autônoma é, em sua essência, um problema de estimação de estado e de tomada de decisão sob incerteza. Por essa razão, os métodos estatísticos clássicos permanecem centrais, especialmente quando interpretabilidade e garantias formais de desempenho são necessárias.

O filtro de Kalman é um estimador recursivo ótimo sob as hipóteses de linearidade da dinâmica e de ruído gaussiano. Em cada iteração, executa-se uma etapa de predição, com a propagação da estimativa segundo o modelo dinâmico, seguida de uma etapa de atualização, com a incorporação da medição por meio do ganho de Kalman. Para sistemas não lineares, utilizam-se variantes: o filtro de Kalman estendido lineariza o sistema em torno da estimativa corrente por expansão de Taylor de primeira ordem; o filtro de Kalman não perfumado propaga pontos representativos por meio da transformação não linear, capturando momentos estatísticos com maior fidelidade, conforme demonstrado empiricamente por Farag (2021). A Figura 3 esquematiza o ciclo recursivo de predição e atualização que fundamenta esse método.

Figura 3: Ciclo recursivo de predição e atualização do filtro de Kalman.



O ciclo predição–atualização repete-se a cada novo conjunto de medições, em tempo real.

Fonte: elaborado pelo autor (2026).

Os filtros de partículas constituem um método sequencial de Monte Carlo que representa a distribuição posterior por meio de um conjunto de amostras ponderadas, sem assumir gaussianidade. São apropriados para distribuições multimodais e dinâmicas altamente não lineares, servindo de base para algoritmos de mapeamento e localização simultâneos amplamente utilizados em robótica móvel. A inferência bayesiana e as redes bayesianas, por sua vez, fornecem o arcabouço unificado para a fusão de evidências, permitindo combinar conhecimento prévio com observações sensoriais para obter distribuições posteriores sobre o estado do mundo.

Os modelos ocultos de Markov e suas extensões são empregados no reconhecimento de manobras e na previsão de comportamento de outros usuários da via. Já os métodos de Monte Carlo mostram-se essenciais para a avaliação de risco em horizontes temporais futuros, possibilitando a projeção estocástica de trajetórias de pedestres, ciclistas e veículos próximos, o que viabiliza um planejamento que minimize a probabilidade de colisão (Mathoho; Pillay, 2021).

2.4. Aprendizado de Máquina e Aprendizado Profundo Aplicados

A virada do ano de 2012, com o sucesso da arquitetura AlexNet, inaugurou a era do aprendizado profundo aplicado à percepção computacional. Atualmente, as redes neurais convolucionais constituem o estado da arte para a detecção de objetos em imagens automotivas, alcançando acurácia de classificação superior a 97% em conjuntos de dados de tráfego urbano (Riyanto et al., 2024). Arquiteturas otimizadas atingem dezenas de quadros por segundo com modelos compactos, viabilizando a inferência diretamente no hardware embarcado do veículo.

Para a predição de comportamento de agentes dinâmicos, as redes recorrentes em especial as redes de memória de longo e curto prazo capturam dependências temporais, sendo mais recentemente sobrepujadas por arquiteturas baseadas em mecanismos de atenção. Os transformadores, originalmente concebidos para o processamento de linguagem natural, vêm sendo adaptados com sucesso para a condução autônoma. Modelos que aprendem representações em vista panorâmica a partir de múltiplas câmeras, bem como arquiteturas que unificam detecção, rastreamento, predição e planejamento em uma única estrutura, representam a fronteira atual da pesquisa (Li et al., 2024; Jia et al., 2025).

Em decisões táticas, como mudança de faixa, ultrapassagem e gestão de cruzamentos, o aprendizado por reforço profundo emerge como alternativa a abordagens baseadas em regras fixas. Algoritmos dessa família aprendem políticas que maximizam recompensas de longo prazo, modelando o problema como um processo de decisão de Markov (Hoel; Wolff; Laine, 2020). Trabalhos recentes propõem variantes bayesianas desses algoritmos com o objetivo de quantificar a incerteza nas ações recomendadas, característica crítica para sistemas de segurança.

A disputa entre arquiteturas modulares, em que cada componente é treinado e validado separadamente, e arquiteturas de ponta a ponta, em que uma única rede mapeia dados sensoriais diretamente a comandos de controle, divide a indústria. Observa-se, contudo, que a fronteira entre os paradigmas é mais permeável do que sugere a literatura comercial, uma vez que sistemas de ponta tendem a combinar redes treinadas de ponta a ponta com módulos dedicados de fusão sensorial para cenários de latência crítica (Costa; Santos; Ferreira, 2020).

2.5. Aspectos Éticos, Legais e Regulatórios

A discussão ética em torno dos veículos autônomos foi popularizada pela transposição do clássico dilema do bonde: diante de uma colisão inevitável, como o sistema deve distribuir o dano? O experimento Moral Machine, conduzido por pesquisadores de instituição norte-americana de referência, coletou cerca de 40 milhões de decisões oriundas de milhões de pessoas em 233 países e territórios, evidenciando consensos transculturais, como a preferência por proteger seres humanos em detrimento de animais e por salvar o maior número de vidas, bem como diferenças regionais marcantes (Awad et al., 2018). Críticas filosóficas, contudo, apontam que cenários desse tipo são raros na condução real e desviam a atenção de questões mais imediatas, como a percepção robusta, a comunicação entre homem e máquina e a privacidade (Cunneen et al., 2019).

No plano regulatório brasileiro, a Lei nº 14.599, de 2013, permite ao Conselho Nacional de Trânsito autorizar, em caráter experimental, a circulação de veículos em condições não previstas no Código de Trânsito Brasileiro (Tavares, 2024). O Projeto de Lei nº 1.317, de 2023, aprovado na Comissão de Viação e Transportes da Câmara dos Deputados em 2024, regulamenta a circulação de veículos autônomos, exigindo seguro total, homologação pelo órgão de trânsito competente e realização de testes em território nacional, além de classificar como infração gravíssima o tráfego sem autorização (Câmara dos Deputados, 2024).

O Projeto de Lei nº 2.338, de 2023, denominado Marco Legal da Inteligência Artificial, foi aprovado por unanimidade no Senado Federal em dezembro de 2024 e adota o modelo europeu de

classificação por grau de risco, com sanções financeiras expressivas e a criação de um sistema nacional de regulação e governança da inteligência artificial (Senado Federal, 2024). Complementarmente, a Lei Geral de Proteção de Dados, em vigor desde 2020, impõe requisitos rigorosos ao tratamento dos dados pessoais gerados por veículos conectados, como geolocalização e padrões de condução, exigindo consentimento explícito, finalidade declarada e observância do princípio da minimização (Brasil, 2018).

A cibersegurança constitui dimensão crítica e ainda pouco regulamentada. Revisão sistemática recente identificou que perturbações imperceptíveis aos olhos humanos, aplicadas a placas de trânsito ou a imagens captadas pelas câmeras, podem induzir o sistema de percepção a classificações errôneas, com consequências potencialmente letais (Boltachev, 2024). A questão da responsabilidade civil por acidentes envolvendo veículos autônomos, por fim, permanece como área de intenso debate jurídico, prevalecendo o entendimento de que a responsabilização deve recair sobre fabricantes e proprietários, e não sobre o sistema computacional em si (Pinheiro; Borges; Mello, 2019).

2.6. Contexto Brasileiro de Veículos Autônomos

O Brasil possui presença consolidada na pesquisa internacional sobre veículos autônomos, ainda que comercialmente esteja distante da fronteira tecnológica. Dois projetos universitários merecem destaque. O Projeto CaRINA, sigla para Carro Robótico Inteligente para Navegação Autônoma, coordenado no Laboratório de Robótica Móvel do Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo, em São Carlos, realizou, em 2013, a primeira demonstração pública de navegação autônoma

em ruas públicas da América Latina, utilizando um veículo de passeio adaptado com LIDAR, câmera estéreo e sistemas de posicionamento e inerciais (Fernandes et al., 2014).

O Projeto IARA, sigla para Automóvel Robótico Autônomo Inteligente, do Laboratório de Computação de Alto Desempenho da Universidade Federal do Espírito Santo, realizou, em maio de 2017, a primeira viagem autônoma de longa distância da América Latina, percorrendo 74 quilômetros entre a cidade de Vitória e a praia de Meaípe, em Guarapari, em 105 minutos, com velocidade média de 42 quilômetros por hora. O percurso incluiu avenidas urbanas, uma ponte de grande extensão, rodovias com semáforos, lombadas e pedágios (Ufes, 2017). O artigo de revisão produzido por esse grupo de pesquisa tornou-se referência mundial sobre o tema (Badue et al., 2021).

Os desafios da implementação no Brasil, contudo, são significativos. Apenas cerca de 34% da malha rodoviária pavimentada principal apresenta condições adequadas para o funcionamento de sistemas avançados de assistência à condução, e a sinalização horizontal é, frequentemente, apagada ou inexistente (Edenred, 2024). Soma-se a isso o fato de o país registrar mais de 90 mortes diárias em sinistros de trânsito, o que reforça, simultaneamente, a necessidade e a complexidade da adoção de soluções automatizadas (Abramet, 2024).

3. METODOLOGIA

A presente pesquisa caracteriza-se como revisão narrativa de literatura, com abordagem qualitativa e caráter exploratório, seguindo os preceitos metodológicos descritos por Costa, Santos e

Ferreira (2020) e por Tavares, Ribeiro e Machado (2021) para o estudo de tecnologias emergentes. A coleta de dados foi realizada em bases científicas internacionais, como IEEE Xplore, ScienceDirect, Springer Link, Nature e PubMed Central, e em bases e repositórios nacionais, incluindo a SciELO e os repositórios institucionais das principais universidades brasileiras.

Foram utilizados como descritores, isolados ou combinados pelo operador booleano *And*, os termos: autonomous vehicles, self-driving cars, veículos autônomos, sensor fusion, Kalman filter, deep learning autonomous driving e ethics autonomous vehicles. Adotaram-se como critérios de inclusão as publicações realizadas entre 2018 e 2024, com flexibilização para obras seminais anteriores, redigidas em português ou inglês, revisadas por pares ou oriundas de instituições oficiais. Foram excluídas a literatura sem rastreabilidade e as fontes comerciais desprovidas de suporte técnico.

Adicionalmente, foram analisados documentos regulatórios brasileiros, como resoluções do Conselho Nacional de Trânsito, os Projetos de Lei nº 1.317 e nº 2.338, ambos de 2023, e a Lei Geral de Proteção de Dados, bem como relatórios técnicos e estudos de segurança publicados por operadoras comerciais de veículos autônomos em parceria com pesquisadores independentes.

4. RESULTADOS E DISCUSSÕES

A revisão da literatura científica revelou um consenso crescente entre os pesquisadores quanto à relevância da integração entre análise de dados e estatística para o desenvolvimento de veículos autônomos mais seguros e eficientes. As publicações analisadas

destacam que a combinação de técnicas estatísticas, aprendizado de máquina e metodologias de fusão sensorial possibilita ganhos significativos em precisão preditiva, tempo de resposta e confiabilidade operacional dos sistemas (Li et al., 2022; Pham; Stack, 2018; Costa; Santos; Ferreira, 2020).

4.1. Eficácia Comparativa: Sistemas Autônomos Versus Motoristas Humanos

A evidência empírica mais robusta sobre a segurança de veículos autônomos provém da operação comercial da empresa Waymo. Em estudo publicado em 2024, Kusano et al. analisaram 7,14 milhões de milhas em operação sem motorista de segurança, comparando os resultados com referências humanas derivadas de dados policiais ajustados estatisticamente.

Os resultados mostram redução estatisticamente significativa de 80% na taxa de colisões com qualquer lesão reportada e de 55% nas colisões reportadas à polícia (Kusano et al., 2024). Atualização recente desse estudo, ampliando a base para 56,7 milhões de milhas, demonstrou redução de 85% em colisões com suspeita de lesões graves e de 96% em colisões em interseções (Kusano et al., 2025).

Os tempos de reação fornecem outra dimensão de análise. Estudos demonstram que motoristas humanos jovens levam, em média, 388 milissegundos entre a detecção de um perigo e a decisão de agir, valor que pode ultrapassar 600 milissegundos entre motoristas mais velhos (Wolfe et al., 2019). Análises clássicas da engenharia de tráfego brasileira apontam mediana de 1,1 a 1,3 segundos para a frenagem em condições alertadas. Os sistemas autônomos, em contraste, operam tipicamente em latências inferiores a 100 milissegundos na

malha que vai do sensor à atuação (Badue et al., 2021). Essa diferença de ordem de grandeza explica, em parte, a superioridade estatística observada nos estudos de campo. Conforme a norma SAE J3016, os veículos autônomos são classificados em diferentes níveis de automação, variando desde a ausência de automação até a condução totalmente autônoma. A Tabela 1 sintetiza essa classificação e destaca as principais características associadas a cada nível de automação veicular.

Tabela 1: Níveis de automação veicular segundo a norma SAE J3016.

Nível	Denominação	Característica principal
0	Sem automação	Condução inteiramente humana; sistemas apenas de alerta.
1	Assistência ao condutor	Automação de uma única função (direção ou velocidade).
2	Automação parcial	Controle simultâneo de direção e velocidade sob supervisão humana constante.
3	Automação condicional	Sistema assume a condução em condições definidas; exige retomada humana quando solicitado.
4	Automação alta	Operação autônoma em domínio operacional definido, sem necessidade de motorista.
5	Automação completa	Operação autônoma irrestrita em qualquer condição. Ainda teórico.

Fonte: elaborado pelo autor com base em SAE International (2021).

4.2. Estado da Arte em Fusão Sensorial

A revisão conduzida por Qian et al. (2025) classificou as estratégias de fusão sensorial em três níveis e identificou como tendência dominante a fusão intermediária em representações de vista panorâmica processadas por transformadores. Essas arquiteturas alcançam desempenho estado da arte em conjuntos de dados de referência amplamente reconhecidos pela comunidade. O trabalho de Liu, Wu e Wang (2023) apresentou uma rede capaz de fundir dados de LIDAR e de câmera em tempo real, com gargalo de processamento inferior a 50 milissegundos em hardware embarcado, demonstrando a viabilidade prática da fusão multimodal de baixa latência.

A controvérsia técnica mais visível na indústria opõe a aposta da empresa Tesla na visão computacional pura, baseada exclusivamente em câmeras, à abordagem multimodal da empresa Waymo, que combina múltiplos LIDARs, radares e câmeras. Sob perspectiva estatística, a redundância sensorial reduz a variância dos estimadores de estado e mitiga falhas de modalidade específica, um princípio bem estabelecido na teoria de fusão de dados (Qian et al., 2025). A Tabela 2 sintetiza as principais características das modalidades sensoriais empregadas.

Tabela 2: Comparativo das principais modalidades sensoriais em veículos autônomos.

Sensor	Vantagens	Limitações	Dado principal
LIDAR	Precisão geométrica 3D; medição direta de distância.	Alto custo; degrada em chuva, neblina e neve.	Nuvem de pontos 3D
Câmera	Riqueza semântica; leitura de cor, placas	Sensível à luz e ao clima;	Imagem 2D

	e faixas.	profundidade inferida.	
Radar	Robusto ao clima; mede velocidade por efeito Doppler.	Baixa resolução angular; dados esparsos.	Velocidade radial
GNSS / IMU	Localização global; alta frequência inercial.	Imprecisão métrica; bloqueio de sinal em túneis.	Posição e atitude

Fonte: Elaborado pelo Autor com base em Yeong et al. (2021) e Qian et al. (2025).

4.3. Síntese Comparativa do Impacto da Integração Estatística

Antes da adoção integrada dessas metodologias, os sistemas de navegação autônoma baseavam-se predominantemente em dados isolados de sensores e em regras determinísticas, o que limitava sua capacidade de adaptação a cenários complexos e incertos. Após a incorporação de técnicas estatísticas avançadas, como os filtros de Kalman, a inferência bayesiana e os modelos probabilísticos de comportamento, observa-se uma evolução substancial na capacidade dos veículos de interpretar padrões ambientais e tomar decisões em tempo real de forma mais assertiva (Delgado et al., 2019; Rodrigues; Mendes; Albuquerque, 2022). A Tabela 3 sintetiza as principais vantagens observadas nos estudos revisados.

Tabela 3: Comparativo de critérios antes e depois da integração estatística em veículos autônomos.

Critério	Antes da integração	Depois da integração estatística e analítica
Fusão de dados	Processamento isolado por tipo de	Integração probabilística multissensorial, aumentando a

sensoriais	sensor.	precisão da percepção ambiental.
Tomada de decisão	Regras fixas e determinísticas.	Modelos preditivos e bayesianos, permitindo decisões adaptativas em tempo real.
Tratamento de incertezas	Pouca capacidade de lidar com ruídos ou falhas sensoriais.	Uso de modelos probabilísticos e filtros para reduzir incertezas.
Eficiência operacional	Respostas lentas em cenários complexos.	Processamento otimizado com algoritmos estatísticos, reduzindo o tempo de reação.
Segurança e confiabilidade	Alta dependência de intervenção humana.	Maior autonomia com protocolos estatísticos de validação e detecção de anomalias.
Capacidade preditiva	Limitada a dados históricos.	Previsão de cenários futuros com base em análise estatística avançada.

Fonte: Elaborado pelo Autor (2026).

4.4. Tendências Tecnológicas e Limitações Identificadas

A próxima geração de veículos autônomos transcende o paradigma do veículo isolado. A comunicação entre o veículo e todos os elementos do ambiente, conhecida pela sigla V2X, permite a troca de informações em tempo real com outros veículos, com a infraestrutura viária, com pedestres e com a rede. Combinada com redes de quinta geração de latência ultrabaixa e com o processamento de borda, essa arquitetura habilita aplicações como o aviso cooperativo de colisão e a formação de comboios de veículos. No Brasil, contudo, segundo dados da agência reguladora de

telecomunicações, ao final de 2024 a tecnologia de quinta geração estava disponível em 748 municípios, representando apenas 16,4% das conexões de banda larga móvel, o que evidencia a dependência de investimentos coordenados em infraestrutura (Anatel, 2025).

Apesar dos avanços, persistem desafios técnicos significativos. Entre eles, destacam-se o desempenho degradado em condições climáticas adversas, a generalização limitada para domínios operacionais não vistos durante o treinamento, a vulnerabilidade a ataques adversariais e o elevado custo computacional e energético das pilhas de processamento que combinam fusão sensorial e aprendizado profundo. A esses fatores soma-se a persistência de lacunas regulatórias e a ausência de padrões internacionais consolidados para a validação formal conforme apontado de modo recorrente pela literatura analisada (Boltachev, 2024; Sparrow et al., 2025).

5. CONSIDERAÇÕES FINAIS

A presente pesquisa teve como objetivo analisar a integração entre análise de dados e estatística como fundamento para a tomada de decisão em tempo real em veículos autônomos. Os resultados evidenciaram que essa integração constitui um eixo estruturante para o avanço dos sistemas autônomos, permitindo ganhos significativos em precisão preditiva, capacidade adaptativa, eficiência operacional e segurança. Os filtros de Kalman e suas variantes permanecem indispensáveis para o rastreamento de objetos e a fusão sensorial, comprovadamente reduzindo erros em mais de um quinto em relação a abordagens não filtradas. Sobre essa espinha dorsal probabilística, as redes neurais agregam

capacidade semântica e de generalização que sistemas puramente analíticos não alcançam.

Os dados empíricos disponíveis, especialmente os provenientes da operação comercial da empresa Waymo, sustentam a hipótese de que veículos autônomos podem ser significativamente mais seguros do que motoristas humanos em domínios operacionais bem definidos. A redução de 80% em colisões com lesão é um achado de magnitude relevante. Todavia, essa evidência é específica a contextos urbanos cartografados de cidades estrangeiras e não pode ser extrapolada acriticamente para a realidade brasileira, na qual a infraestrutura viária, a sinalização e o comportamento dos demais usuários da via apresentam características distintas.

O Brasil possui competência científica reconhecida, atestada pelos projetos universitários CaRINA e IARA e por publicações de alto impacto, mas carece de marcos regulatórios consolidados, de infraestrutura adequada e de um ecossistema industrial doméstico que lhe permita participar competitivamente da cadeia de valor global. A tramitação dos projetos de lei sobre veículos autônomos e sobre a inteligência artificial representa avanço necessário, cuja efetividade dependerá de regulamentação detalhada, de harmonização com a legislação de proteção de dados e de investimento público sustentado.

Como agenda de pesquisa futura, recomenda-se o desenvolvimento de métodos de quantificação formal de incerteza em modelos de aprendizado profundo, a validação de segurança baseada em cenários simulados representativos das tipologias viárias brasileiras, a construção de conjuntos de dados nacionais devidamente anotados e a realização de estudos sobre os impactos

socioeconômicos. da transição tecnológica sobre a categoria profissional de motoristas. Conclui-se que a integração entre estatística e aprendizado de máquina em veículos autônomos não constitui mera curiosidade técnica, mas um caso paradigmático de como métodos quantitativos podem contribuir para a redução de mortes evitáveis no trânsito.

REFERÊNCIAS BIBLIOGRÁFICAS

ABRAMET. Associação Brasileira de Medicina do Tráfego. Estatísticas e segurança viária no Brasil. São Paulo: Abramet, 2024. Disponível em: <https://abramet.com.br>. Acesso em: 12 mar. 2026.

ANATEL. Agência Nacional de Telecomunicações. Panorama da conectividade e expansão do 5G no Brasil. Brasília, DF: Anatel, 2025. Disponível em: <https://www.gov.br/anatel>. Acesso em: 10 abr. 2026.

AWAD, E. et al. The Moral Machine experiment. *Nature*, Londres, v. 563, n. 7729, p. 59–64, 2018. Disponível em: <https://www.nature.com/articles/s41586-018-0637-6>. Acesso em: 15 mar. 2026.

BADUE, C. et al. Self-driving cars: a survey. *Expert Systems with Applications*, v. 165, 113816, 2021. Disponível em: <https://doi.org/10.1016/j.eswa.2020.113816>. Acesso em: 18 mar. 2026.

BOLTACHEV, A. Adversarial attacks and cybersecurity challenges in autonomous vehicles: a systematic review. 2024. Disponível em: <https://scholar.google.com>. Acesso em: 22 abr. 2026.

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). *Diário Oficial da União*: Brasília, DF, 15

ago. 2018. Disponível em: <https://www.planalto.gov.br>. Acesso em: 20 fev. 2026.

CÂMARA DOS DEPUTADOS. Projeto de Lei nº 1.317, de 2023. Regulamenta a circulação de veículos autônomos no Brasil. Brasília, DF: Câmara dos Deputados, 2024. Disponível em: <https://www.camara.leg.br>. Acesso em: 12 mar. 2026.

COSTA, A.; SANTOS, B.; FERREIRA, C. Tecnologias emergentes e inteligência artificial aplicada à mobilidade autônoma. 2020. Acesso em: 12 mar. 2026.

CUNNEEN, M. et al. Autonomous vehicles and embedded ethical dilemmas. *Transportation Research Part C: Emerging Technologies*, v. 105, p. 116–129, 2019. Disponível em: <https://doi.org/10.1016/j.trc.2018.12.004>. Acesso em: 16 mar. 2026.

DELGADO, R. et al. Technologies and trends in autonomous driving systems. *Transportation Research Procedia*, v. 40, p. 1115–1122, 2019. Disponível em: <https://doi.org/10.1016/j.trpro.2019.07.155>. Acesso em: 21 mar. 2026.

EDENRED. Panorama da infraestrutura rodoviária e mobilidade no Brasil. São Paulo: Edenred, 2024. Disponível em: <https://www.edenred.com.br>. Acesso em: 18 abr. 2026.

FARAG, W. Sensor fusion using unscented Kalman filter for autonomous vehicle perception. *Sensors*, v. 21, n. 12, 2021. Disponível em: <https://www.mdpi.com>. Acesso em: 20 mar. 2026.

FERNANDES, L. C. et al. CaRINA intelligent robotic car: architectural design and applications. *Journal of Systems Architecture*, v. 60, n. 4,

p. 372–392, 2014. Disponível em: <https://doi.org/10.1016/j.sysarc.2013.12.003>. Acesso em: 18 mar. 2026.

GHASEMAGHAEI, M. Understanding the impact of artificial intelligence on decision-making processes. *Journal of Decision Systems*, v. 28, n. 2, p. 1–17, 2019. Disponível em: <https://www.tandfonline.com>. Acesso em: 11 abr. 2026.

HOEL, C. J.; WOLFF, K.; LAINE, L. Tactical decision-making in autonomous driving by reinforcement learning. *IEEE Transactions on Intelligent Vehicles*, v. 5, n. 2, p. 294–303, 2020. Disponível em: <https://ieeexplore.ieee.org>. Acesso em: 25 mar. 2026.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA (IPEA); FÓRUM BRASILEIRO DE SEGURANÇA PÚBLICA (FBSP). Atlas da Violência 2025. Brasília, DF: Ipea; FBSP, 2025. Disponível em: <https://www.ipea.gov.br>. Acesso em: 10 mar. 2026.

ISRAELSEN, P. Artificial intelligence, uncertainty and autonomous systems. 2025. Acesso em: 10 mar. 2026.

JIA, X. et al. Transformer-based autonomous driving architectures and integrated planning systems. 2025. Acesso em: 12 mar. 2026.

KUSANO, K. D. et al. Comparison of Waymo rider-only crash data to human benchmarks at 7.1 million miles. *Traffic Injury Prevention*, v. 25, n. 1, p. S66–S77, 2024. Disponível em: <https://doi.org/10.1080/15389588.2024.2380786>. Acesso em: 20 abr. 2026.

KUSANO, K. D. et al. Waymo safety performance update and severe injury crash analysis. 2025. Disponível em: <https://waymo.com>. Acesso

em: 22 abr. 2026.

LI, Y. et al. Autonomous driving perception and intelligent transportation systems: advances and challenges. 2022. Acesso em: 22 abr. 2026.

LI, Z. et al. End-to-end transformer architectures for autonomous driving systems. 2024. Acesso em: 17 abr. 2026.

LIU, H.; WU, Y.; WANG, Z. Real-time multimodal sensor fusion for autonomous vehicles using LiDAR and camera integration. IEEE Access, v. 11, p. 20245–20260, 2023. Disponível em: <https://ieeexplore.ieee.org>. Acesso em: 14 abr. 2026.

MATHOHO, M.; PILLAY, N. Monte Carlo and probabilistic methods in autonomous navigation systems. Applied Sciences, v. 11, n. 15, 2021. Disponível em: <https://www.mdpi.com>. Acesso em: 16 mar. 2026.

PHAM, Q.; STACK, J. How data analytics and machine learning support autonomous vehicle systems. International Journal of Engineering and Technology, v. 7, n. 4, p. 201–210, 2018. Acesso em: 22 abr. 2026.

PINHEIRO, P.; BORGES, L.; MELLO, R. Responsabilidade civil e inteligência artificial: implicações jurídicas dos veículos autônomos. Revista Jurídica, v. 21, n. 3, p. 45–62, 2019. Acesso em: 25 abr. 2026.

QIAN, Y. et al. Sensor fusion strategies and multimodal perception for autonomous vehicles: a review. IEEE Transactions on Intelligent Transportation Systems, 2025. Disponível em: <https://ieeexplore.ieee.org>. Acesso em: 18 abr. 2026.

RIYANTO, A. et al. Deep learning approaches for object detection in autonomous driving environments. *Sensors*, v. 24, n. 2, 2024. Disponível em: <https://www.mdpi.com>. Acesso em: 20 abr. 2026.

RODRIGUES, F.; MENDES, A.; ALBUQUERQUE, R. Modelos estatísticos e inteligência artificial aplicados à mobilidade autônoma. *Revista Brasileira de Computação Aplicada*, v. 14, n. 2, p. 55–71, 2022. 20 abr. 2026.

SAE INTERNATIONAL. Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles: SAE J3016. Warrendale, PA: SAE International, 2021. Disponível em: <https://www.sae.org>. Acesso em: 15 mar. 2026.

SENADO FEDERAL. Projeto de Lei nº 2.338, de 2023. Dispõe sobre o uso da inteligência artificial no Brasil. Brasília, DF: Senado Federal, 2024. Disponível em: <https://www25.senado.leg.br>. Acesso em: 22 fev. 2026.

SINGH, S. Critical reasons for crashes investigated in the National Motor Vehicle Crash Causation Survey. Washington, DC: National Highway Traffic Safety Administration, 2015. Disponível em: <https://crashstats.nhtsa.dot.gov>. Acesso em: 20 mar. 2026.

SPARROW, R. et al. Ethics, governance and risk in autonomous artificial intelligence systems. 2025. Acesso em: 20 mar. 2026.

TAVARES, R. Regulamentação de veículos autônomos no Brasil: desafios jurídicos e institucionais. *Revista de Direito e Tecnologia*, v. 12, n. 1, p. 33–49, 2024. Acesso em: 12 mar. 2026.

TAVARES, R.; RIBEIRO, M.; MACHADO, P. Metodologias de revisão narrativa aplicadas a tecnologias emergentes. *Revista Científica Interdisciplinar*, v. 9, n. 2, p. 80–96, 2021. Acesso em: 12 mar. 2026.

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO (UFES). Projeto IARA realiza primeira viagem autônoma de longa distância da América Latina. Vitória: Ufes, 2017. Disponível em: <https://www.ufes.br>. Acesso em: 12 maio. 2026.

VELODYNE LIDAR. HDL-64E S3 datasheet and technical specifications. San Jose, CA: Velodyne, 2018. Disponível em: <https://velodynelidar.com>. Acesso em: 14 mar. 2026.

WOLFE, B. et al. Driver reaction time and age-related performance in traffic environments. *Human Factors*, v. 61, n. 4, p. 617–630, 2019. Acesso em: 22 maio. 2026.

YEONG, D. J. et al. Sensor and sensor fusion technology in autonomous vehicles: a review. *Sensors*, v. 21, n. 6, 2021. Disponível em: <https://www.mdpi.com>. Acesso em: 18 mar. 2026.

¹ Discente do Curso Superior de Engenharia da Computação da Fundação Centro de Análise, Pesquisa e Inovação Tecnológica-FUCAPI, Manaus-AM. E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Docente do Curso Superior de Engenharia da Computação da Fundação Centro de Análise, Pesquisa e Inovação Tecnológica-FUCAPI, Manaus-AM. E-mail: [acesse o artigo original para visualizar o e-mail](#)

