



JOÃO PEDRO PEREIRA DA SILVA

**VISÃO COMPUTACIONAL APLICADA AOS
VEÍCULOS INTELIGENTES – CONCEITOS
GERAIS E ANÁLISE BIBLIOMÉTRICA**

LAVRAS – MG

2023

JOÃO PEDRO PEREIRA DA SILVA

**VISÃO COMPUTACIONAL APLICADA AOS VEÍCULOS
INTELIGENTES – CONCEITOS GERAIS E ANÁLISE
BIBLIOMÉTRICA**

Trabalho de conclusão de curso apresentado à
Universidade Federal de Lavras como parte das
exigências do Curso de Engenharia de Controle e
Automação, para a obtenção do título de bacharel.

Prof. Dr. Danilo Alves de Lima
Orientador

LAVRAS – MG

2023

AGRADECIMENTOS

Agradeço imensamente a Deus pela oportunidade de chegar até aqui. Sem Ele, nada disso teria acontecido. Mais um sonho sendo realizado, e não posso deixar de agradecer também aos meus pais Glória e Paulo, por sempre acreditarem em mim e me apoiarem. À minha mãe, em especial, agradeço por muitas vezes abdicar de suas vontades para que eu chegasse até aqui. Ao meu irmão, Paulo Ricardo, por ser inspiração e sempre estar comigo. A José Benedito, que, mesmo não estando mais aqui, sempre me apoiou a correr atrás dos meus estudos.

À entidade NLMT, meu muito obrigado por toda experiência vivida e pelos laços de amizade criados. Certamente, contribuiu muito para a minha formação pessoal e profissional.

Por fim, à Universidade Federal de Lavras, agradeço a oportunidade de me tornar Bacharel em Engenharia de Controle e Automação e por todo suporte oferecido durante os anos da graduação. Ao meu orientador, Danilo, que auxiliou e me deu suporte nesta última etapa da graduação. A todos os meus amigos, obrigado por compartilharem momentos de tristeza e alegria desde o início da jornada acadêmica.

Muito obrigado!

O correr da vida embrulha tudo, a vida é assim: esquenta e esfria, aperta e daí afrouxa, sossega e depois desinquieta. O que ela quer da gente é coragem.

(João Guimarães Rosa)

RESUMO

Nos últimos anos, notáveis avanços ocorreram na área da robótica móvel, especialmente no que diz respeito aos veículos inteligentes. Eles apresentam-se como a melhor alternativa para suprir problemas econômicos, acessibilidade, congestionamento e segurança viária. Porém, para que esses veículos entrem em circulação é preciso desenvolver técnicas robustas, ágeis e confiáveis para garantir o funcionamento seguro e eficiente. Dessa maneira, a utilização de câmeras para a percepção do ambiente destaca-se como uma alternativa viável, sendo também de baixo custo. Nesse contexto, este trabalho apresenta um estudo bibliométrico para identificar e analisar as tendências no campo da visão computacional aplicada aos veículos inteligentes. Para isso, foram extraídos dados da *Web of Science*, e a partir dessas informações, foram gerados mapas em formato de redes utilizando o software *VOSviewer*. Os resultados revelam que as pesquisas nessa área estão em constante crescimento ao longo dos anos. Além disso, abordagens envolvendo métodos de inteligência artificial aparecem como uma forte tendência para oferecer soluções aos principais desafios relacionados ao ambiente de direção.

Palavras-chave: Veículos inteligentes. Visão computacional. Bibliometria

ABSTRACT

Over the past few years, notable advancements have occurred in the field of mobile robotics, especially with respect to Intelligent Vehicles (IVs). They emerge as the optimal solution to address economic challenges, accessibility issues, traffic congestion, and road safety. However, for these vehicles to be deployed effectively, it is essential to develop robust, agile, and reliable techniques to ensure safe and efficient operation. In this context, the use of cameras for environmental perception stands out as a viable and cost-effective alternative. This study presents a bibliometric analysis to identify and examine trends in the field of computer vision applied to intelligent vehicles. Data were extracted from the Web of Science, and network maps were generated using VOSviewer software based on this information. The results reveal that research in this area has been steadily growing over the years. Additionally, approaches involving artificial intelligence methods emerge as a strong trend to provide solutions to the key challenges related to the driving environment.

Keywords: Intelligent Vehicles. Computer Vision. Bibliometrics.

LISTA DE FIGURAS

Figura 2.1 – Níveis de automação definidos pela norma SAE.	19
Figura 2.2 – Exemplo da segmentação de imagem do semáforo.	21
Figura 2.3 – Exemplo de câmera monocular da MindVision (MV-SUA505GC). 23	
Figura 2.4 – Modelo de câmera de visão estéreo Bumblebee2 da empresa Flir.	24
Figura 2.5 – Câmera de Tempo de Voo (ToF) Helios2 da LUCID Vision Labs Inc.	25
Figura 2.6 – Modelo de câmera RGBD da Orbbec (Atra Pro).	26
Figura 3.1 – Etapas da metodologia da pesquisa.	30
Figura 4.1 – Quantidade publicações por ano com base nos dados WoS. . .	31
Figura 4.2 – Representação de coocorências das palavras-chave.	33
Figura 4.3 – Representação temporal das palavras-chave.	34
Figura 4.4 – Relação de publicações por países (top 15).	36
Figura 4.5 – Densidade de publicações por países (top 15).	37

LISTA DE TABELAS

Tabela 2.1 – Níveis de automação de Veículos Inteligentes definidos pela SAE.	18
--	----

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivos	16
1.2	Estrutura do texto	16
2	CONCEITOS GERAIS	17
2.1	Veículos Inteligentes	17
2.2	Visão computacional	20
2.2.1	Câmeras monoculares	23
2.2.2	Câmeras estereoscópicas	24
2.2.3	Time of flight - ToF	25
2.2.4	RGBD	25
2.3	Bibliometria	26
3	METODOLOGIA	29
3.1	Extração de dados bibliométricos	29
4	RESULTADOS	31
4.1	Análise temporal das publicações	31
4.2	Análise de coocorrências das palavras-chave	32
4.3	Análise temporal das palavras-chave	33
4.4	Análise das publicações por países	35
4.5	Tendências de pesquisas futuras	38
5	CONCLUSÃO	41
	REFERÊNCIAS	43

1 INTRODUÇÃO

Máquinas que executam ações inteligentes sem supervisão humana são um dos objetivos dos pesquisadores que estudam a Inteligência Artificial (AI - do inglês *artificial intelligence*) e estão rapidamente se aproximando da realidade. Casas inteligentes, supercomputadores, videoconferências e até mesmo robôs falantes, eram apenas coisas para filmes de ficção científica. Em 1968, o filme de ficção “Se Meu Fusca Falasse”, abordava a história de Herbie, um veículo capaz de trafegar de maneira autônoma, e hoje pode-se observar que essa idealização já é uma realidade, com a previsão de que os veículos inteligentes (IV - do inglês *intelligent vehicles*) sejam amplamente utilizados para o transporte individual de passageiros, transporte público e de mercadorias (FAYYAD et al., 2020).

Atualmente, os veículos convencionais são amplamente utilizados no dia a dia de muitas pessoas. No entanto, a grande circulação desses veículos também aumenta o número de acidentes de trânsito, congestionamentos, a poluição e ocupação excessiva do espaço urbano (YAO et al., 2023). A empresa Waymo, que é umas das pioneiras no desenvolvimento de veículos inteligentes, estima que cerca de 94% dos acidentes de trânsito ocorrem devido a falha humana (WAYMO, 2021). Além disso, aproximadamente 50 milhões de pessoas sofrem ferimentos graves em acidentes de trânsito anualmente, resultando em mais de 1,25 milhão de fatalidades em todo o mundo (PAVEL; TAN; ABDULLAH, 2022).

Nesse sentido, os veículos inteligentes representam uma das maiores inovações tecnológicas da indústria automotiva e têm o potencial de revolucionar a mobilidade terrestre (GAO et al., 2018). Esses veículos são capazes de tomar decisões independentes e executar ações inteligentes sem a necessidade de supervisão humana. No entanto, para que isso seja possível, é essencial que esses veículos possuam sistemas avançados de visão computacional (ARNOLD et al., 2019).

A visão computacional é a área que trabalha com a extração de informações, a partir de imagens digitais, para diversos fins de análise e assim possi-

bilitar a aplicação em diferentes campos de interesse (KRISHNA, 2017). Sistemas de visão computacional geralmente seguem uma sequência de etapas, que incluem a aquisição de imagem, filtragem, segmentação e a identificação de padrões (QUINTANAR-SOTELO et al., 2019). As aplicações são feitas para diferentes tipos de câmeras, que incluem as monoculares, estereoscópicas, tempo de voo (ToF - do inglês *time-of-flight*) e RGBD (do inglês *red, green, blue, and depth*), aliadas aos contínuos avanços nas aplicações de IA (Inteligência Artificial), é possível integrar essas tecnologias para aprimorar os sistemas de percepção, localização, planejamento e controle dos veículos inteligentes. (SALIH; OLAWOYIN, 2020).

1.1 Objetivos

Este trabalho tem por objetivo investigar a produção científica relacionada ao campo da visão computacional direcionada para aplicações em veículos inteligentes, para identificar e discutir as abordagens mais exploradas nessa área por meio de uma análise bibliométrica.

Os objetivos específicos compreendem:

- I. Apresentar conceitos gerais de visão computacional e veículos inteligentes;
- II. Coletar dados de uma plataforma indexadora de documentos científicos para realizar uma análise bibliométrica;
- III. Identificar as tendências de pesquisas futuras no campo da visão computacional aplicada a veículos inteligentes.

1.2 Estrutura do texto

O presente trabalho traz em sua organização os conceitos gerais, descrito no Capítulo 2, que apresenta uma introdução dos conceitos de veículos inteligentes, visão computacional e bibliometria. O Capítulo 3 aborda a metodologia utilizada para o desenvolvimento. Nos Capítulos 4 e 5, apresentam-se, respectivamente, os resultados e as conclusões.

2 CONCEITOS GERAIS

Neste capítulo são abordados conceitos importantes a cerca dos veículos inteligentes, visão computacional e inteligência artificial.

2.1 Veículos Inteligentes

Dado que a inteligência de um veículo e sua capacidade de ser autônomo são conceitos muito complexos e podem gerar margens a diversas interpretações, a SAE (2021) (do inglês - *Society of Automotive Engineers*) criou a definição de sistema automatizado de condução (ADS - do inglês *automated driving system*), sendo o veículo capaz de executar parte ou toda a tarefa de condução dinâmica (DDT - do inglês *Dynamic Driving Task*) de forma sustentada, independente das condições impostas pelo domínio de design operacional (ODD - do inglês *Operational Design Domain*). Assim, podendo o veículo ser composto de nenhuma automação de direção (nível 0) à completa automação de direção (nível 5), conforme apresentado na Tabela 2.1 e ilustrado na Figura 2.1.

É atribuído ao DDT o papel de desempenhar todas as funções operacionais e táticas em tempo real para manter operante um veículo, excluindo as funções estratégicas. Enquanto o ODD define as condições operacionais para o qual um sistema é projetado para funcionar. Além disso, existe o conceito de DDT fallback, que é a resposta do usuário para realizar as DDT ou atingir a condição de risco mínimo decorrente de uma falha no sistema, ou após a saída do ODD, ou a resposta ADS para atingir a condição de risco mínimo, dadas as mesmas circunstâncias (SAE, 2021).

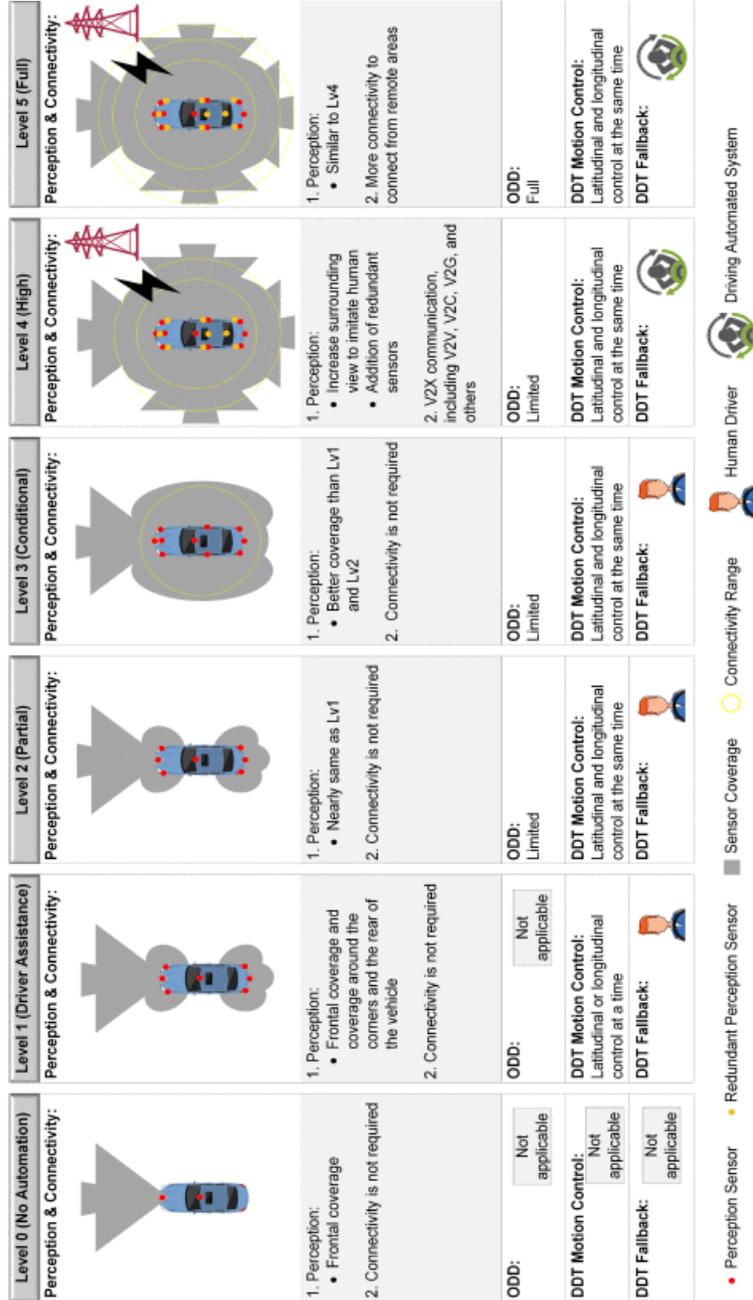
Os veículos inteligentes precisam ser capazes de perceber e compreender o ambiente em tempo real, assim enfrentam o desafio de coletar e processar grandes quantidades de informações provenientes de diversos tipos de sensores, como câmeras, radares e lasers (ZHU et al., 2017). O objetivo principal é a extração

Tabela 2.1 – Níveis de automação de Veículos Inteligentes definidos pela SAE.

Nível	Descrição do nível	Papel do usuário	Papel do sistema de automação de direção (ADS)
0	Sem automação	- DDT realizado o tempo todo;	- Não executa qualquer parte do DDT.
1	Assistência ao motorista	- Responsável pelo restante do DDT não executado pelo ADS; - Supervisiona o ADS e faz intervenções.	- DDT executa subtarefas de movimentos longitudinal ou lateral; - Desativa imediatamente mediante solicitação do usuário.
2	Automação parcial	- Responsável pelo restante do DDT não executado pelo ADS; - Supervisiona o ADS e faz intervenções.	- DDT executa subtarefas de movimento longitudinal e lateral; - Desativa imediatamente mediante solicitação do usuário.
3	Automação condicional	- Executa o DDT fallback; - Determina como atingir condição de risco mínimo; - Responsável pelo DDT após desativação do ADS.	- DDT executado o tempo todo dentro de seu ODD; - Determina se o ODD será excedido; - Desativa imediatamente mediante solicitação do usuário.
4	Automação elevada	- Não é necessário executar o DDT ou DDT fallback; - Torna-se passageiro quando o ADS está ativo; - Pode realizar o DDT após o ADS atingir seu limite ODD; - Pode solicitar que o ADS seja desativado e assumir o DDT.	- DDT executado o tempo todo dentro de seu ODD; - Desativa somente se, atingir uma condição de risco mínimo ou caso o usuário esteja realizando o DDT; - Pode atrasar o desligamento quando solicitado pelo usuário.
5	Automação completa	- Não é necessário executar o DDT ou DDT fallback; - Torna-se passageiro quando o ADS está ativo; - Pode solicitar que o ADS seja desativado e assumir o DDT.	- DDT executado o tempo todo; - Desativa somente se, atingir uma condição de risco mínimo ou caso o usuário esteja realizando o DDT; - Pode atrasar o desligamento quando solicitado pelo usuário.

Fonte: Adaptado (SAE, 2021)

Figura 2.1 – Níveis de automação definidos pela norma SAE.



Fonte: (SAE, 2021)

de dados relevantes do seu entorno, incluindo estradas, faixas, sinais de trânsito, pedestres e outros veículos (CHEN; CHENG; HE, 2020).

2.2 Visão computacional

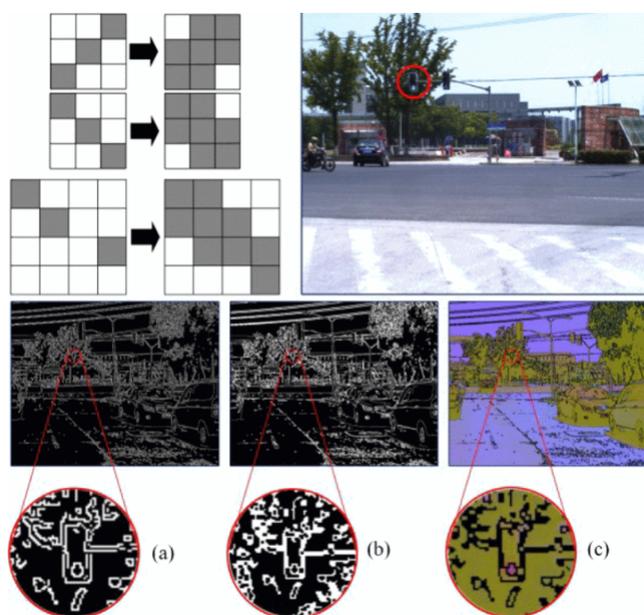
A visão computacional tem se destacado no sistema de percepção de IV, devido a duas principais razões. Primeiro, todo sistema viário, com suas marcas de faixa, limites da estrada, etc., é projetado para ser visível para o sistema de visão humano, o que torna o uso de câmeras uma escolha lógica para um IV (MÜLLER, 2017). Além disso, as câmeras são atualmente a modalidade de sensores para percepção com custo mais baixo e robustas para aplicações automotivas, com a maturidade da produção em massa de módulos e grandes investimentos na área de visão computacional, permitindo que soluções eficazes sejam alcançadas com uma excelente relação custo benefício (HILLEL et al., 2014).

Como sensores base da visão computacional e componentes essenciais nos principais sistemas de veículos inteligentes, as câmeras desempenham importantes funções. Por meio das medições capturadas por esses dispositivos, é viabilizada a obtenção de localização e mapas simultâneos (SLAM - do inglês *Simultaneous Localization and Mapping*) (CHGHAF; RODRIGUEZ; OUARDI, 2022). Funções do sistema de controle são executadas de maneira adequada e automática para percorrer trajetos específicos (NISHIMURA et al., 2015). Além disso, elas desempenham um papel essencial no sistema de percepção e navegação, permitindo a prevenção de colisões e a geração de trajetórias viáveis (KLASER; OSÓRIO; WOLF, 2013).

Utilizando métodos clássicos de processamento de imagens, é possível empregar técnicas de segmentação para realizar tarefas essenciais, incluindo a detecção de bordas, objetos e cores. Essa abordagem tem como objetivo identificar conjuntos de pixels e áreas na imagem que compartilham semelhanças e que devem ser agrupadas (KRISHNA, 2017), ou seja, é a simplificação da imagem,

permitindo uma representação mais homogênea. Por exemplo, a segmentação é importante para aplicações de identificação de sinalizações de trânsito (ZONG; CHEN, 2014), como ilustrado na Figura 2.2, onde nas cenas (a), (b) e (c) é possível identificar as etapas de extração dos traços de interesse para obter apenas a representação do semáforo. Já a detecção de bordas é útil na identificação de obstáculos próximos aos veículos, como meio-fios ou calçadas (PANEV et al., 2018).

Figura 2.2 – Exemplo da segmentação de imagem do semáforo.



Fonte: (ZONG; CHEN, 2014)

Por outro lado, as evoluções no campo da computação, apresentando sofisticados e ricos recursos (ELMQUIST; NEGRUT, 2021), possibilitaram a utilização de técnicas avançadas para análise de imagens (VACHMANUS et al., 2021). Dessa maneira, os métodos de aprendizado de máquina (ML - do inglês *machine learning*) e aprendizado profundo (DL - do inglês *deep learning*), que incluem as redes neurais convolucionais (CNN - do inglês *convolutional neural network*), aparecem como algumas das abordagens mais destacadas na literatura (MA et al., 2020). Apesar dessas técnicas terem alcançado sua ascensão na atualidade, seus

conceitos já foram criados em 1943, quando McCulloch e Walter Pitts desenvolveram algoritmos computacionais baseados no funcionamento de neurônios (MC-CULLOCH; PITTS, 1943). Na década de 1980, muitos algoritmos já estavam em desenvolvimento, porém as aplicações foram inviabilizadas devido as limitações computacionais (MACHADO; MUNDIM, 2022).

Os algoritmos de aprendizado de máquina dependem do treinamento de dados para aprender (HINA; SOUKANE; RAMDANE-CHERIF, 2019), ou seja, são algoritmos inteligentes criados para identificar padrões (GIRDHAR; HONG; MOORE, 2023), porém a sua implementação pode ser um desafio, devido a sua complexidade, que muitas vezes apresenta uma quantidade elevada de parâmetros para serem analisadas (TUNCALI et al., 2020). No entanto, modelos com menos dados também podem oferecer desempenho significativo, isso porque é viável utilizar cerca de 500 imagens para o reconhecimento de pedestres (ÖZTÜRK et al., 2020) e, além disso, é possível realizar sua classificação, diferenciando adultos e crianças, por meio de descritores de aparência em substituição de medições relativas (WARD; RASHAD; ELGAZZAR, 2023).

As CNN são amplamente utilizadas devido à sua capacidade de associar áreas de pixels e identificar características de alta dimensão, como bordas e regiões. Definida pelo empilhamento de camadas convolucionais, essa abordagem pode ser aplicada em tarefas de segmentação semântica e reconhecimento de padrões (ELMQUIST; NEGRUT, 2021). No contexto de navegação segura de veículos em ambientes desconhecidos, os modelos contemporâneos utilizam abordagens baseadas em processos gaussianos, ou seja, essas abordagens permitem a geração de trajetórias adaptativas em cenários complexos, incluindo interações dinâmicas com outros veículos, demonstrando uma capacidade de resposta e adaptação às variáveis do ambiente (AGNIHOTRI; SARAF; BAPNAD, 2019).

Nesse contexto, ambas as abordagens podem ser complementares, com as técnicas clássicas sendo empregadas em tarefas em que o custo de *hardware*

e *software* é mais baixo, enquanto as técnicas avançadas são aplicadas em cenários mais complexos. Dessa forma, os avanços na computação e na tecnologia de sensores, aliados à crescente demanda na navegação autônoma por maior desempenho na detecção e precisão, têm aberto caminho para a substituição das abordagens clássicas pela implementação de tecnologias ligadas à inteligência artificial (VACHMANUS et al., 2021).

2.2.1 Câmeras monoculares

Os sistemas de visão monoculares empregam uma única câmera e exploram a geometria da cena, juntamente com informações sobre o tamanho dos objetos, para estimar a distância longitudinal (MÜLLER, 2017). Ainda assim, podem fornecer informações de alta resolução por meio das intensidades dos pixels, que, em uma escala ampliada, revelam características da forma e textura dos objetos na cena. Porém, são limitadas devido à falta de informações de profundidade, que são necessárias para definir o tamanho dos objetos e estimativa de posição (ARNOLD et al., 2019). Na Figura 2.3, é apresentado um exemplo de câmera monocular.

Figura 2.3 – Exemplo de câmera monocular da MindVision (MV-SUA505GC).



Fonte: (MINDVISION, 2023)

A utilização de câmera monocular é considerada uma alternativa viável devido à facilidade de manuseio e ao baixo custo associado (DAMIAN et al., 2019). Além disso, apresentam outras vantagens notáveis, como a redução da sobrecarga de dados e a simplificação de problemas complexos de sincronização e calibração

que frequentemente surgem em configurações de câmeras estéreo (GADAGKAR; UMANAND, 2020). Entretanto, a tarefa de estimar informações tridimensionais a partir de uma única câmera monocular é desafiadora, principalmente devido a problemas relacionados à ambiguidade na escala da cena, que resulta da falta de informações que normalmente seriam obtidas por meio de múltiplas câmeras.

2.2.2 Câmeras estereoscópicas

O sistema de visão estéreo é composto por duas ou mais câmeras monoculares posicionadas a uma distância fixa e conhecida, como ilustrado na Figura 2.4. Essas câmeras simulam a visão binocular humana e possuem campos de visão que se sobrepõem, ou seja, permitem a captura de imagens de uma cena a partir de dois pontos de vista ligeiramente diferentes. Entretanto, apresentam as desvantagens do alto custo associado, baixo alcance de detecção e a difícil implementação (PIDURKAR; SADAKALE; PRAKASH, 2019).

A estimativa da profundidade da cena pode ser obtida por meio de correspondência e triangulação. A distância entre as câmeras monoculares, chamada de linha de base, juntamente com a distância focal e a resolução das câmeras, estabelecem um limite para a faixa máxima de profundidade estimada. Assim, quanto maior a linha de base, maior a precisão na estimativa da profundidade, embora isso seja acompanhado de uma redução no campo de visão nas áreas onde as câmeras se sobrepõem (CHGHAF; RODRIGUEZ; OUARDI, 2022).

Figura 2.4 – Modelo de câmera de visão estéreo Bumblebee2 da empresa Flir.



Fonte: (FLIR, 2023)

2.2.3 Time of flight - ToF

O tempo de voo é um método que utiliza uma câmera especial para coletar dados de nuvens de pontos tridimensionais. Essa câmera ativa extrai informações de profundidade de uma cena 3D ao analisar as mudanças de fase dos sinais de luz. Essas mudanças de fase são causadas pelos diferentes tempos de viagem da luz no espaço, quando ela reflete nos objetos e retorna à câmera (PANEV et al., 2018). Na Figura 2.5, é apresentado um exemplo de câmera ToF.

Em contextos automotivos, o ToF desempenham um papel importante em sistemas de assistência ao motorista e segurança, desempenhando funções como o reconhecimento de pedestres e o sistema anticolisão. Porém, apresentam uma limitação crucial em relação à resolução, já que seu alcance é limitado a 10 metros (MÜLLER, 2017).

Figura 2.5 – Câmera de Tempo de Voo (ToF) Helios2 da LUCID Vision Labs Inc.



Fonte: (PHOTONICS, 2023)

2.2.4 RGBD

As câmeras RGBD (*red, green, blue, and depth*), conforme representada na Figura 2.6, oferecem uma vantagem significativa ao fornecer informações de profundidade dos pixels, permitindo a obtenção da estrutura tridimensional do ambiente em tempo real. Essas câmeras utilizam tecnologias como visão estéreo, luz estruturada ou ToF para determinar a escala dos objetos. Combinando propriedades de visão monocular e estereoscópica, as câmeras RGBD são consideradas

sensores visuais completos, fornecendo não apenas informações de textura, mas também suporte ativo de projetores de luz. Além disso, essas câmeras são compactas e podem ser integradas com uma unidade de medição inercial (IMU - do inglês *Inertial Measurement Unit*). No entanto, é importante ressaltar que, devido à sua faixa limitada e sensibilidade à luz solar (GAO et al., 2018), as câmeras RGBD são mais adequadas para aplicações de navegação em ambientes internos (CHGHAF; RODRIGUEZ; OUARDI, 2022).

Figura 2.6 – Modelo de câmera RGBD da Orbbec (Atra Pro).



Fonte: (ORBEC, 2023)

2.3 Bibliometria

O conceito de bibliometria, inicialmente proposto por Pritchard no final da década de 1960 (CHUEKE; AMATUCCI, 2015), pode ser definido como a utilização de métodos estatísticos e quantitativos para analisar e mensurar a produção científica e o impacto das publicações e dos autores (ARAÚJO, 2006).

O volume de publicações em pesquisa científicas está em crescimento exponencial em diferentes instituições. Dessa maneira, existe uma demanda crescente por ferramentas bibliométricas que possam oferecer suporte às políticas de pesquisa. Portanto, é essencial desenvolver soluções para lidar com as grandes bases de dados (GUTIÉRREZ-SALCEDO et al., 2018).

Dessa forma, o programa *VOSviewer* apresenta-se como uma ferramenta especializada no desenvolvimento e visualização de mapas bibliométricos. Esses mapas são criados e explorados por meio de conexões ou links, onde a importân-

cia de um link é determinada pelo tamanho de seu rótulo e círculo. Um link mais destacado indica uma relação mais relevante. A força de uma conexão pode representar diversos fatores, como o número de referências compartilhadas entre dois artigos (acoplamento bibliográfico), a quantidade de colaborações entre dois autores (coautoria) ou a frequência com que dois termos são mencionados nos artigos (coocorrência).

Por meio da análise de coocorrência, coautoria, redes de colaboração e outras métricas, a bibliometria pode oferecer uma compreensão profunda da estrutura e da dinâmica do conhecimento científico (SILVA; SILVA; ALMEIDA, 2023). Além disso, as suas aplicações se estendem para o âmbito institucional, permitindo a avaliação do desempenho de universidades e instituições de pesquisas (COSTA et al., 2012).

Portanto, a análise bibliométrica pode contribuir para a organização das pesquisas realizadas em um campo específico do conhecimento e aponta para questões que podem ser exploradas em investigações futuras (CHUEKE; AMATUCCI, 2015). Isso ajuda a mapear as origens dos conceitos existentes, destacar as principais abordagens teóricas utilizadas em estudos e identificar as metodologias empregadas em pesquisas anteriores.

3 METODOLOGIA

A pesquisa foi conduzida ao longo do período compreendido entre os meses de julho e setembro de 2023, adotando uma abordagem descritiva. O objetivo central foi investigar as principais tendências na área da visão computacional, com ênfase no campo dos veículos inteligentes. Por meio dessa abordagem, busca-se analisar os avanços que moldam a área que está em constante evolução, proporcionando uma compreensão das inovações e direções das pesquisas.

3.1 Extração de dados bibliométricos

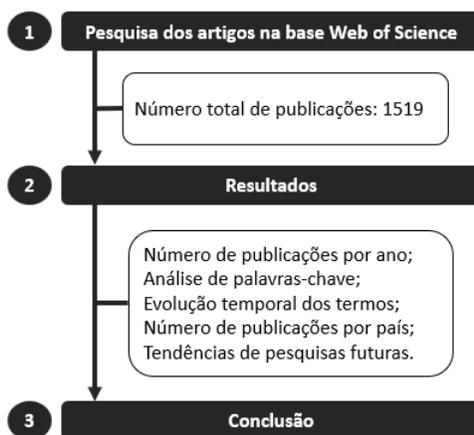
A extração dos dados bibliométricos foi executada a partir dos artigos indexados na base de dados *Web of Science* (WoS) da *Clarivate Analytics PLC*. Em seguida, os dados passaram por análise utilizando o software *VOSviewer* (versão 1.6.16, desenvolvido pela *Universiteit Leiden, Holanda*), que tem a capacidade de gerar redes que exploram associações em coautoria, palavra chave, citação, acoplamento bibliográfico e cocitações. Além disso, foi utilizado o *Excel 2016* para produção gráfica, retratando o número de publicações científicas ao longo dos anos.

Os artigos foram selecionados na base da WoS em uma única pesquisa, abrangendo o período de 1945 a 2023. A busca foi delimitada pelo campo Tópico, para englobar os títulos, resumos ou palavras-chave. Assim, os termos foram inseridos entre aspas e combinados com operadores booleanos da seguinte forma: ("*stereo*" OR "*monocular*" OR "*time_of_flight*" OR "*RGBD*" OR "*vision*" OR "*camera*" OR "*intelligent_vehicle*") AND ("*autonomous_vehicle*"). Após a extração dos dados, foi realizado o refinamento dos resultados, unificando termos repetidos ou com significados similares, resultando na combinação de palavras em uma única representação. Por exemplo, *autonomous driving* foi condensado para *autonomous vehicle* e *peoples r china* foi convertido como apenas *china*.

Além da busca descrita anteriormente, foram realizadas outras duas pesquisas. No entanto, o número de publicações encontradas foi menor em comparação com o modelo final. Seguindo os mesmos filtros estabelecidos anteriormente e alterando somente as palavras-chave, na primeira tentativa, foram utilizados os termos: ("computer_vision") AND ("autonomous_vehicle"), o que resultou em 292 artigos. Para a segunda busca, foram empregados os termos: ("stereo_vision" OR "monocular_vision" OR "time_of_flight" OR "RGBD" OR "vision" OR "camera" OR "intelligent_vehicle") AND ("autonomous_vehicle"), que forneceu 1467 documentos. Nessas buscas, os termos selecionados apresentam pouca diversificação, isso principalmente no primeiro caso. Portanto, foram incluídas mais palavras e generalizado seus significados, como por exemplo, reduzindo "stereo_vision" para apenas "stereo".

No *VOSviewer* foram importados dos dados coletados da WoS para criar gráficos que representam as coocorrências das palavras-chave, evolução temporal desses termos e as relações entre países. Em sequência, foram realizadas as análises dos resultados obtidos, discutindo as conexões e tendências identificadas. As etapas do estudo são apresentadas na Figura 3.1.

Figura 3.1 – Etapas da metodologia da pesquisa.



Fonte: Do autor

4 RESULTADOS

4.1 Análise temporal das publicações

Na Figura 4.1 é apresentado o número de publicações identificadas na base da WoS, relacionadas ao campo da visão computacional e veículos inteligentes ao longo dos anos. A busca resultou em 1519 documentos e registrou o início das publicações a partir de 1990. Durante as décadas de 1990 e 2000, observam-se variações anuais com uma tendência de crescimento.

Entretanto, a produção científica teve apenas expansão substancial e constante a partir de 2012, registrando 31 artigos, com exceção dos anos de 2015, 2020 e 2023 nos quais foram alcançando 43, 151 e 110 artigos, respectivamente. No entanto, em 2020 não houve queda, o mesmo número do ano anterior foi mantido (151), e em 2023, apenas os primeiros 9 meses do ano foram contabilizados, sendo destacada sua contribuição no gráfico em vermelho.

O primeiro artigo identificado foi publicado em 1990 e apresenta um sistema no qual informações de orientação são fornecidas para robôs manipuladores e veículos inteligentes (BLISSETT, 1990). Nesse sistema, dados tridimensionais são extraídos da cena, com base em aplicações que envolvem visão estéreo, possibilitando o reconhecimento do ambiente.

Figura 4.1 – Quantidade publicações por ano com base nos dados WoS.



Fonte: do Autor

4.2 Análise de coocorrências das palavras-chave

As coocorrências entre os termos é representada na Figura 4.2, com as palavras-chave organizadas em grupos distintos identificados por cores, denominados *clusters* ou agrupamentos, que são classificados de forma automática pelo programa *VOSviewer*. Observa-se que os círculos que indicam os termos variam em tamanho, sendo que essa dimensão reflete proporcionalmente a quantidade de documentos relacionados às palavras-chave nas pesquisas científicas.

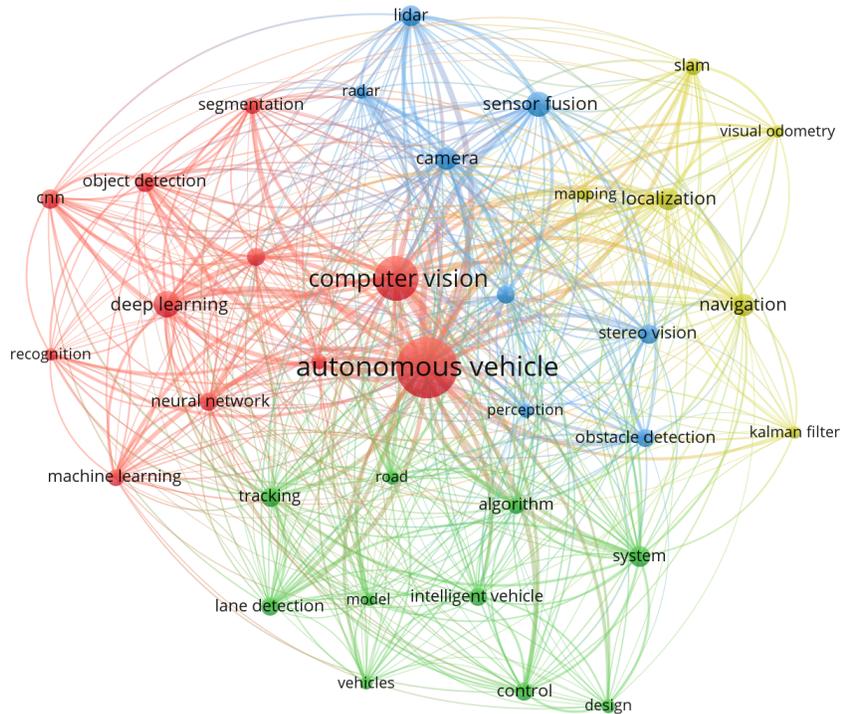
Para observar as interconexões dos termos com clareza, foi aplicado ao total das 3504 palavras-chave identificadas na pesquisa um critério de seleção, exigindo que cada uma delas tivesse no mínimo 26 ocorrências. Logo esse processo resultou na limitação de um conjunto de análise com 35 termos. Na Figura 4.2, foram gerados 4 *clusters*, representados pelas cores vermelho (11), verde (10), azul (8) e amarelo (6).

No *cluster* vermelho, os principais termos foram "*autonomous vehicle*" (654), "*computer vision*" (343) e "*deep learning*" (122). Dessa forma, é evidente a forte relação existente entre veículos inteligentes, visão computacional e elementos importantes ligados à inteligência artificial.

Para o *cluster* verde, destacaram-se os termos "*tracking*" (66), "*lane detection*" (55) e "*road*" (36). Esse conjunto de itens reflete a importância das pesquisas voltadas para o desenvolvimento de sistemas de detecção e rastreamento de elementos presentes no ambiente como, por exemplo, as estradas e as faixas (PANEV et al., 2018).

As palavras identificadas no *cluster* azul indicam elementos que são fundamentais para o sistema de percepção, como "*sensor fusion*" (108), "*camera*" (93) e "*lidar*" (82). Nesse contexto, as pesquisas enfatizam a utilização da fusão sensorial, já que elas podem garantir o aprimoramento das medições provenientes de duas ou mais fontes de sensores, com a atenuação da redundância e da incerteza das aferições (ROSIQUE et al., 2019).

Figura 4.2 – Representação de coocorrências das palavras-chave.



Fonte: do Autor

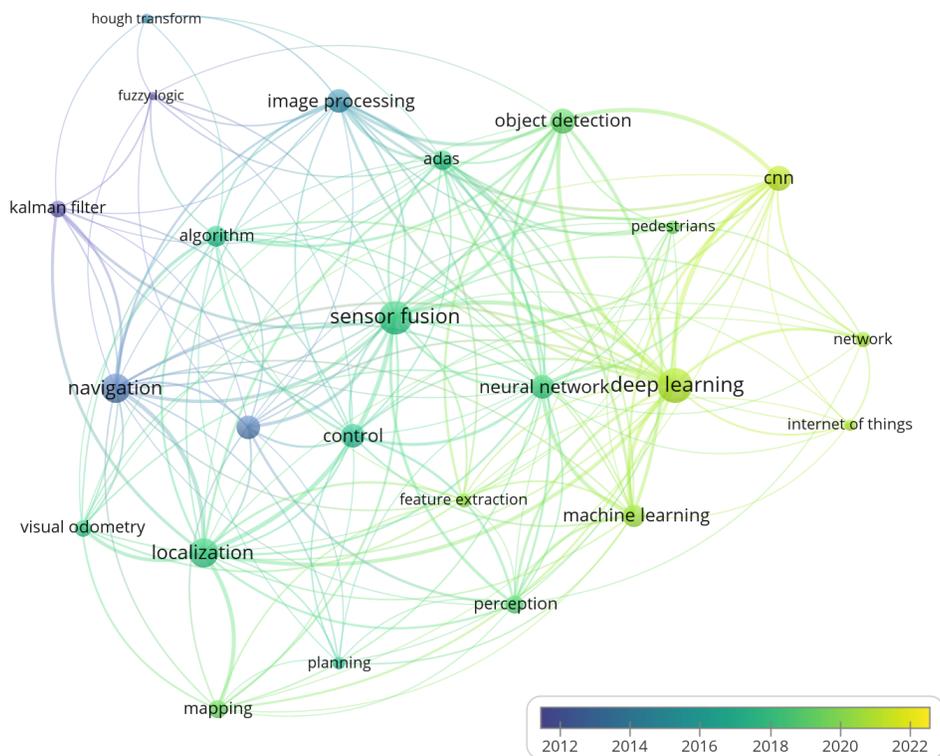
Por fim, o *cluster* amarelo é representado pelas palavras "*localization*" (90), "*navigation*" (85) e "*mapping*" (32). Essa ligação enfatiza a importância da combinação desses elementos para aprimorar a capacidade dos veículos inteligentes de determinar sua localização precisa, traçar rotas eficientes e criar mapas detalhados de seu ambiente por meio de técnicas de SLAM (CHGHAF; RODRIGUEZ; OUARDI, 2022).

4.3 Análise temporal das palavras-chave

Nesta etapa, as palavras-chave de entrada da pesquisa foram retiradas, juntamente com outras que apresentavam significados genéricos, como por exemplo

"road", "vehicles" e "model". Além disso, outros termos foram acrescentados conforme apresentado na Figura 4.3. Dessa forma, para análise da evolução temporal das palavras-chave, foram destacados os dados para o período em que foi observado o início do aumento no número de publicações relacionadas ao tema de pesquisa, que começou em 2012 e se estendeu até 2022. Os termos de tonalidade mais escura, como o azul, representam o período inicial e os tons mais claros, indicado pelo amarelo, refletem os temas mais atuais.

Figura 4.3 – Representação temporal das palavras-chave.



Fonte: do Autor

Dessa maneira, observa-se que, no início de 2012 até 2014, os termos "Hough transform", "Kalman filter" e "Fuzzy logic", apresentaram relevância nesse período, e são característicos de abordagens ligadas às metodologias clássicas do

processamento de imagens, sendo técnicas relacionadas ao campo da matemática, com princípios estatísticos e probabilísticos (FAYYAD et al., 2020). Por exemplo, a transformada de Hough é empregada na detecção de linhas em imagens, ou seja diretamente relacionada com a segmentação. O filtro de Kalman, por sua vez é utilizado para estimar o estado de sistemas dinâmicos a partir de observações ruidosas, sendo fundamental em aplicações com câmeras para rastreamento de objetos. Por fim, a lógica Fuzzy é aplicada para interpretar os dados da imagem, tratando incertezas e imprecisões na descrição de objetos.

A partir de 2018, devido aos desenvolvimentos na área da computação e na tecnologia de sensores, foi observado um avanço nas pesquisas envolvendo técnicas de inteligência artificial, como refletido pelas palavras "*deep learning*", "*CNN*" e "*machine learning*". Isso indica que a IA se tornou um componente essencial nos veículos inteligentes para realizar a percepção do ambiente circundante e na tomada de decisões. Como resultado, muitas pesquisas estão sendo conduzidas nesse campo com o objetivo de aprimorar e oferecer soluções para a área (MA et al., 2020).

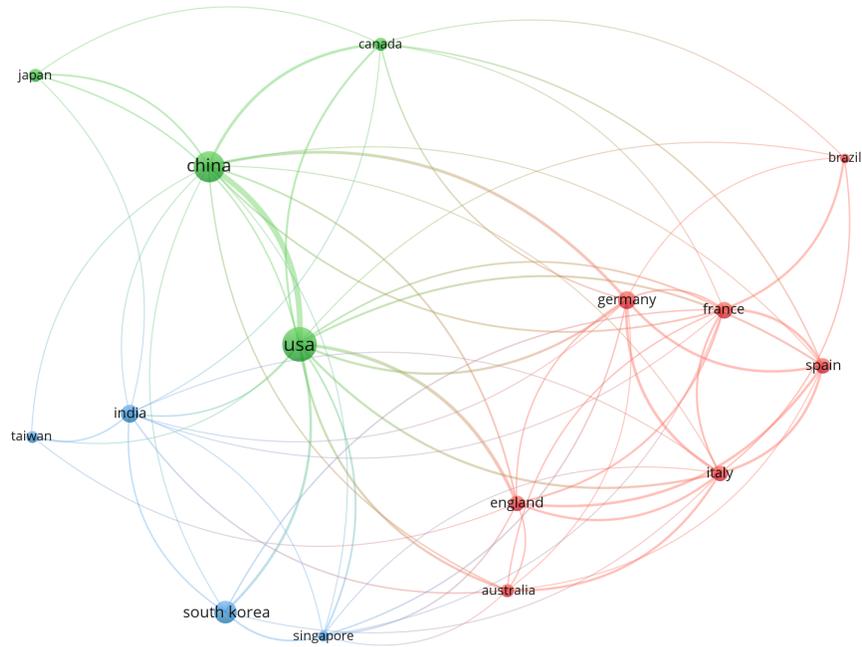
Diante disso, o aprendizado de máquina e as técnicas baseadas em aprendizado profundo, especialmente as CNNs, estão progressivamente substituindo as metodologias tradicionais de visão computacional, por apresentarem maior confiabilidade e capacidade de lidar com grandes volumes de dados. Além disso, elas se destacam na extração de informações visuais a partir de câmeras, possibilitando tarefas importantes como a compreensão da cena, reconhecimento de objetos, segmentação semântica e estimativa de movimento.

4.4 Análise das publicações por países

Na Figura 4.4, é apresentada a interconexão de citações entre países, sendo estabelecido como critério de seleção o número mínimo de publicações por país de

26 trabalhos. Dessa forma, foram obtidos os 15 países mais citados, considerando a base de dados levantada, de um total de 77.

Figura 4.4 – Relação de publicações por países (top 15).

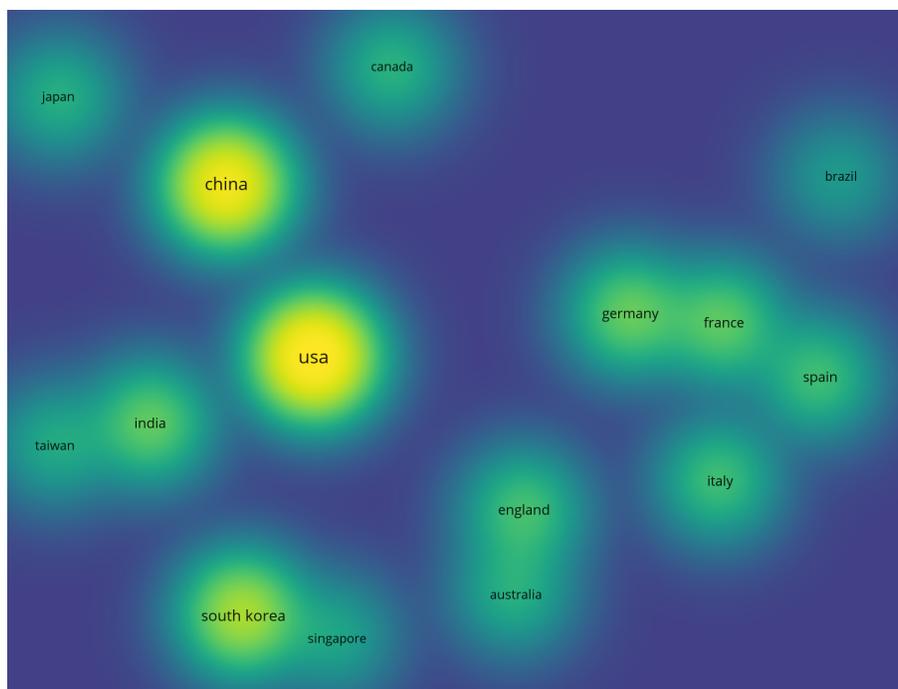


Fonte: do Autor

Já na Figura 4.5, é possível visualizar a densidade representativa de cada país. Sendo que, os Estados Unidos apresentaram 325 publicações, seguidos pela China com 257. A Coreia do Sul figurou com 143 publicações, enquanto a Alemanha surgiu como o primeiro país europeu, com 89 publicações. O Brasil foi o único representante da América Latina nesse recorte, contribuindo com 29 publicações.

A posição dos Estados Unidos, é justificada pelo fato das empresas de tecnologia e automobilísticas liderarem os avanços na tecnologia de veículos inteligentes. Empresas como a Tesla, a Waymo e a General Motors estão investindo fortemente em pesquisa e desenvolvimento na área (GIRDHAR; HONG; MOORE, 2023). Além disso, o governo americano foi o primeiro país a regular os testes de

Figura 4.5 – Densidade de publicações por países (top 15).



Fonte: do Autor

veículos inteligentes nas suas ruas e estradas. Posteriormente, outros países como a China, Japão, Coreia do Sul, Singapura, França, Alemanha também passaram a apoiar a criação de legislação para regulamentar os testes em seus territórios (ROSIQUE et al., 2019).

O Brasil tem feito suas contribuições de pesquisa e desenvolvimento, lideradas por suas instituições acadêmicas. Um dos primeiros projetos nessa área foi o CADU, conduzido na Universidade Federal de Minas Gerais (UFMG) (LIMA, 2010). Posteriormente, surgiram outras iniciativas notáveis, como os projetos CaRINA I e CaRINA II na Universidade de São Paulo (USP) (FERNANDES et al., 2014), e o projeto IARA na Universidade Federal do Espírito Santo (UFES) (BADUE et al., 2021). Em ambos os casos, os pesquisadores integraram sistemas de hardware e software em veículos convencionais para a realização de testes em ambientes reais. Na indústria houve avanços, quando em 2017, foi fundada a Hitech

Electric, uma empresa brasileira especializada no desenvolvimento de uma linha de veículos elétricos e inteligentes (HITECH-E, 2023).

4.5 Tendências de pesquisas futuras

Até este ponto, esta pesquisa apresentou uma visão geral dos estudos relacionados ao campo da visão computacional e veículos inteligentes. Embora tenham sido feitos progressos significativos nessas áreas, existem desafios em aberto e há espaço para inovação. Alguns dos desafios e direções de pesquisas futuras estão descritos abaixo.

Para a detecção de objetos com base na visão computacional, geralmente é desafiador obter informações precisas de profundidade a partir de uma única câmera, porém existem estudos promissores em andamento para aprimorar a estimativa de profundidade com câmeras monoculares utilizando abordagens de aprendizado profundo (CHOI; KEE, 2023). Embora as câmeras estéreo apresentem um desempenho superior nesse aspecto, suas capacidades podem ser comprometidas em condições climáticas ou de iluminação adversas, portanto, trabalhos futuros devem abordar essas limitações, visando aprimorar os sistemas de visão estéreo (YAO et al., 2023).

As aplicações que fazem uso de CNNs estão em constante evolução, demandando uma grande quantidade de dados para serem treinadas de forma eficaz, e as pesquisas atuais buscam aprimorar tanto a precisão quanto a velocidade dessas redes, explorando a adição de camadas convolucionais adicionais. Uma tendência emergente é a integração de redes adversariais generativas (GANs - do inglês *Generative Adversarial Networks*) para gerar dados sintéticos, aprimorando o treinamento das CNNs (NAIK et al., 2022). Espera-se que, as CNNs sejam combinadas com tecnologias como *LiDAR* e radar para oferecer uma análise mais precisa e abrangente do ambiente de direção (GAO et al., 2018).

Embora as pesquisas tenham apresentado grandes avanços em métodos preditivos e na detecção de pessoas e objetos, a utilização de modelos de aprendizado de máquina deve enfrentar desafios na estimativa do estado dos pedestres e na previsão de seus movimentos. Por exemplo, é importante que o sistema antecipe a probabilidade de um pedestre entrar na estrada, dependendo de certos eventos. Portanto, as pesquisas devem considerar variações nas dimensões do corpo humano para diferenciar adultos e crianças, além de lidar com a presença de pessoas ou veículos em anúncios presentes nas vias (WARD; RASHAD; ELGAZZAR, 2023).

5 CONCLUSÃO

Neste trabalho, foi apresentando a importância do sistema visão computacional aplicado aos veículos inteligentes. Além disso, foi evidenciado que a produção científica nesse campo teve um crescimento substancial a partir de 2012, refletindo o papel crucial da tecnologia na aceleração das pesquisas. Inicialmente, técnicas clássicas de processamento de imagens desempenharam um papel fundamental na visão computacional. No entanto, a partir de 2018, o avanço na computação e na tecnologia de sensores impulsionou o uso de técnicas de inteligência artificial, como o aprendizado de máquina e o aprendizado profundo que incluem as redes neurais convolucionais (CNNs), as quais dominam o cenário de pesquisas. Essas abordagens oferecem maior confiabilidade e capacidade de lidar com grandes volumes de dados, impulsionando o desenvolvimento de veículos inteligentes.

Por meio da interconexão de citações entre países, identificou-se os principais contribuidores para a pesquisa em veículos inteligentes. Os Estados Unidos lideram com um grande número de publicações, seguidos pela China, Coreia do Sul, Alemanha e, notavelmente, o Brasil como o único representante da América Latina, muito em função das contribuições desenvolvidas no meio acadêmico. Os Estados Unidos mantêm uma posição proeminente devido ao investimento significativo de empresas e ao apoio governamental na regulamentação dos veículos inteligentes.

As tendências de pesquisas futuras buscam, por meio da inteligência artificial, oferecer soluções para os diversos desafios envolvendo a obtenção de informações por meio de câmeras, dessa maneira problemas como a falta de profundidade ou interferências do ambiente, como variações de luminosidade, devem ser estudadas. O contínuo aprimoramento das CNNs para lidar com grandes volumes de dados e a previsão de eventos são áreas propensas a apresentarem mais resultados. Por fim, a fusão sensorial surge como uma promissora abordagem para

proporcionar soluções mais robustas diante da complexidade do ambiente de direção.

A pesquisa apresentou limitações na obtenção de uma quantidade maior de documentos na *Web of Science*, devido à utilização do operador *booleano AND* e à pouca diversificação nas palavras-chave escolhidas. Assim, o trabalho não reflete, de forma quantitativa, a totalidade das publicações disponíveis na área dos veículos inteligentes. Sugere-se, em futuros projetos, a realização de comparações entre dois ou mais indexadores de documentos científicos. Além disso, recomenda-se ampliar a variedade de termos no campo de busca dos portais para obter resultados mais abrangentes.

REFERÊNCIAS

- AGNIHOTRI, A.; SARAF, P.; BAPNAD, K. R. A convolutional neural network approach towards self-driving cars. In: IEEE. **2019 IEEE 16th India Council International Conference (INDICON)**. [S.l.], 2019. p. 1–4.
- ARAÚJO, C. A. Bibliometria: evolução histórica e questões atuais. **Em questão**, v. 12, n. 1, p. 11–32, 2006.
- ARNOLD, E. et al. A survey on 3d object detection methods for autonomous driving applications. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 20, n. 10, p. 3782–3795, 2019.
- BADUE, C. et al. Self-driving cars: A survey. **Expert Systems with Applications**, Elsevier, v. 165, p. 113816, 2021.
- BLISSETT, R. Retrieving 3d information from video for robot control and surveillance. **Electronics & communication engineering journal**, IET, v. 2, n. 4, p. 155–164, 1990.
- CHEN, K.-H.; CHENG, K.-S.; HE, J.-Y. Perception module design of self-driving vehicles for navigation in people-rich environments. In: IEEE. **2020 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-Taiwan)**. [S.l.], 2020. p. 1–2.
- CHGHAF, M.; RODRIGUEZ, S.; OUARDI, A. E. Camera, lidar and multi-modal slam systems for autonomous ground vehicles: a survey. **Journal of Intelligent & Robotic Systems**, Springer, v. 105, n. 1, p. 2, 2022.
- CHOI, Y.-H.; KEE, S.-C. Monocular depth estimation using a laplacian image pyramid with local planar guidance layers. **Sensors**, MDPI, v. 23, n. 2, p. 845, 2023.
- CHUEKE, G. V.; AMATUCCI, M. O que é bibliometria? uma introdução ao fórum. **Internext**, v. 10, n. 2, p. 1–5, 2015.
- COSTA, T. et al. A bibliometria e a avaliação da produção científica: indicadores e ferramentas. **BAD**, 2012.
- DAMIAN, C. et al. Using mono and stereo camera system for static and moving objects detection. In: **2019 International Conference on Electromechanical and Energy Systems (SIELMEN)**. [S.l.: s.n.], 2019. p. 1–5.
- ELMQUIST, A.; NEGRUT, D. Modeling cameras for autonomous vehicle and robot simulation: An overview. **IEEE Sensors Journal**, v. 21, n. 22, p. 25547–25560, 2021.

FAYYAD, J. et al. Deep learning sensor fusion for autonomous vehicle perception and localization: A review. **Sensors**, MDPI, v. 20, n. 15, p. 4220, 2020.

FERNANDES, L. C. et al. Carina intelligent robotic car: architectural design and applications. **Journal of Systems Architecture**, Elsevier, v. 60, n. 4, p. 372–392, 2014.

FLIR. **Bumblebee2 FireWire**. [S.l.], 2023. Disponível em: <<https://www.flir.com.br/support/products/bumblebee2-firewire/#Overview>>.

GADAGKAR, A. V.; UMANAND, L. A novel monocular camera obstacle perception algorithm for real-time assist in autonomous vehicles. In: **IEEE. 2020 IEEE International Symposium on Smart Electronic Systems (iSES)(Formerly iNiS)**. [S.l.], 2020. p. 196–201.

GAO, H. et al. Object classification using cnn-based fusion of vision and lidar in autonomous vehicle environment. **IEEE Transactions on Industrial Informatics**, IEEE, v. 14, n. 9, p. 4224–4231, 2018.

GIRDHAR, M.; HONG, J.; MOORE, J. Cybersecurity of autonomous vehicles: A systematic literature review of adversarial attacks and defense models. **IEEE Open Journal of Vehicular Technology**, v. 4, p. 417–437, 2023.

GUTIÉRREZ-SALCEDO, M. et al. Some bibliometric procedures for analyzing and evaluating research fields. **Applied intelligence**, Springer, v. 48, p. 1275–1287, 2018.

HILLEL, A. B. et al. Recent progress in road and lane detection: a survey. **Machine vision and applications**, Springer, v. 25, n. 3, p. 727–745, 2014.

HINA, M. D.; SOUKANE, A.; RAMDANE-CHERIF, A. Machine learning techniques for cognition of driving context. In: **2019 27th Mediterranean Conference on Control and Automation (MED)**. [S.l.: s.n.], 2019. p. 380–385.

HITECH-E. [S.l.], 2023. Disponível em: <<https://hitech-e.com.br/outros-veiculos/>>.

KLASER, R. L.; OSÓRIO, F. S.; WOLF, D. F. Simulation of an autonomous vehicle with a vision-based navigation system in unstructured terrains using octomap. In: **2013 III Brazilian Symposium on Computing Systems Engineering**. [S.l.: s.n.], 2013. p. 177–178.

KRISHNA, R. Computer vision: Foundations and applications. In: **Stanford University**. [s.n.], 2017. p. 1–213. Disponível em: <http://vision.stanford.edu/teaching/cs131_fall1718/files/cs131-class-notes.pdf>.

LIMA, D. A. de. Navegação segura de um carro autônomo utilizando campos vetoriais e o método da janela dinâmica. Universidade Federal de Minas Gerais, 2010.

MA, Y. et al. Artificial intelligence applications in the development of autonomous vehicles: A survey. **IEEE/CAA Journal of Automatica Sinica**, IEEE, v. 7, n. 2, p. 315–329, 2020.

MACHADO, H. G.; MUNDIM, K. Revisão das tecnologias de inteligência artificial e machine/deep learning: Restrições, oportunidades, estado da arte e desafios. **Revista Processos Químicos**, v. 16, n. 32, p. 9–22, 2022.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, p. 115–133, 1943.

MINDVISION. **MV-SUA505GC Industrial Camera**. [S.l.], 2023. Disponível em: <https://www.mindvision.com.cn/cpzx/info_62.aspx?itemid=4597&parent&lcid=101>.

MÜLLER, F. de P. Survey on ranging sensors and cooperative techniques for relative positioning of vehicles. **Sensors**, MDPI, v. 17, n. 2, p. 271, 2017.

NAIK, G. B. et al. Convolutional neural network based on self-driving autonomous vehicle (cnn). In: **Innovative Data Communication Technologies and Application: Proceedings of ICIDCA 2021**. [S.l.]: Springer, 2022. p. 929–943.

NISHIMURA, T. et al. Intelligent control method and self-position-azimuth correction method for autonomous vehicle. In: ATLANTIS PRESS. **2015 Joint International Mechanical, Electronic and Information Technology Conference (JIMET-15)**. [S.l.], 2015. p. 648–655.

ORBEC. **Astra Series**. [S.l.], 2023. Disponível em: <<https://www.orbec.com/products/structured-light-camera/astra-series/>>.

PANEV, S. et al. Road curb detection and localization with monocular forward-view vehicle camera. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 20, n. 9, p. 3568–3584, 2018.

PAVEL, M. I.; TAN, S. Y.; ABDULLAH, A. Vision-based autonomous vehicle systems based on deep learning: A systematic literature review. **Applied Sciences**, MDPI, v. 12, n. 14, p. 6831, 2022.

PHOTONICS. **Time-of-Flight Camera**. [S.l.], 2023. Disponível em: <https://www.photonics.com/Products/Time-of-Flight_Camera/pr65475>.

PIDURKAR, A.; SADAKALE, R.; PRAKASH, A. Monocular camera based computer vision system for cost effective autonomous vehicle. In: **2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)**. [S.l.: s.n.], 2019. p. 1–5.

QUINTANAR-SOTELO, C. et al. Self-localization and positioning vehicle navigation system based on computer vision and pid control. In: IEEE. **2019 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)**. [S.l.], 2019. p. 1–6.

ROSIQUE, F. et al. A systematic review of perception system and simulators for autonomous vehicles research. **Sensors**, mdpi, v. 19, n. 3, p. 648, 2019.

SAE. **Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles J3016_202104**. [S.l.], 2021. Disponível em: <https://saemobilus.sae.org/content/J3016_202104>.

SALIH, S.; OLAWOYIN, R. Intelligent performance analysis of automated steering systems for autonomous vehicles. In: IEEE. **2020 IEEE International Conference on Electro Information Technology (EIT)**. [S.l.], 2020. p. 200–205.

SILVA, L. B.; SILVA, L. L.; ALMEIDA, L. A. Análise das capacidades estatais municipais na literatura acadêmica: Construção e visualização de mapas bibliométricos com vosviewer e citnetexplorer. **Cadernos Gestão Pública e Cidadania**, v. 28, p. e88046–e88046, 2023.

TUNCALI, C. E. et al. Requirements-driven test generation for autonomous vehicles with machine learning components. **IEEE Transactions on Intelligent Vehicles**, v. 5, n. 2, p. 265–280, 2020.

VACHMANUS, S. et al. Multi-modal sensor fusion-based semantic segmentation for snow driving scenarios. **IEEE Sensors Journal**, v. 21, n. 15, p. 16839–16851, 2021.

WARD, T.; RASHAD, S.; ELGAZZAR, H. Machine learning based pedestrian detection and tracking for autonomous vehicles. In: IEEE. **2023 IEEE 13th Annual Computing and Communication Workshop and Conference (CCWC)**. [S.l.], 2023. p. 1294–1299.

WAYMO. **Waymo Safety Report**. [S.l.], 2021. Disponível em: <<https://downloads.ctfassets.net/sv23gofxcuiz/4gZ7ZUxd4SRj1D1W6z3rpR/2ea16814cdb42f9e8eb34cae4f30b35d/2021-03-waymo-safety-report.pdf>>.

YAO, S. et al. Radar-camera fusion for object detection and semantic segmentation in autonomous driving: A comprehensive review. **arXiv preprint arXiv:2304.10410**, 2023.

ZHU, H. et al. Overview of environment perception for intelligent vehicles. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 18, n. 10, p. 2584–2601, 2017.

ZONG, W.; CHEN, Q. Traffic light detection based on multi-feature segmentation and online selecting scheme. In: **2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)**. [S.l.: s.n.], 2014. p. 204–209.

ÖZTÜRK, G. et al. Recognition of vehicles, pedestrians and traffic signs using convolutional neural networks. In: **2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)**. [S.l.: s.n.], 2020. p. 1–8.