

Pesquisa bibliográfica sobre aprendizado de máquina aplicado à condução veicular autônoma: Uma revisão

Renato França de Almeida

Universidade Federal de Goiás – Goiás

RESUMO

Este trabalho tem o objetivo de explorar as diversas iniciativas industriais e de pesquisa acerca da aplicação de técnicas de Inteligência Artificial (IA) à condução veicular autônoma. Particularmente, destaca-se no estudo acerca de veículos autônomos (VA) que a transição para uma era de abundância de dados demanda uma mudança de paradigma dos modelos baseados em física para métodos guiados por IA, capazes de prever dinâmicas de tráfego futuras e auxiliar na formulação de políticas de trânsito otimizadas, cujo potencial reside em fatores como a redução de erros de natureza humana e na resposta rápida a acidentes em tempo real, fatores estes que justificam o estudo apresentado. A condução autônoma transcende os padrões de tráfego tradicionais ao realizar tarefas como o reconhecimento proativo de eventos críticos, planejamento dos movimentos seguintes, tomada de decisões e realização de tarefas de controle visando garantir a segurança e o conforto dos passageiros em ambientes de tráfego dinâmicos. São apresentados os níveis de automação veicular e concentra-se nos métodos guiados por IA focados em estruturas Ponta a Ponta em detrimento de estruturas pipeline, explorando detalhes acerca das arquiteturas de Redes Neurais MLP (Multi-Layer Perceptron) e KAN (Kolmogorov–Arnold Networks), os principais conceitos e estratégias que guiam essas técnicas, bem como desafios futuros relacionados a VAs. Conclui-se, portanto, que tecnologias como aprendizado de máquina, aprendizado profundo, aprendizado por reforço, bem como o uso conjunto destas, são essenciais para a implementação de sistemas de controle de VAs que promovam a evolução do sistema de transporte.

Palavras-chave: Aprendizado de máquina, Aprendizado por reforço, Aprendizado profundo, Inteligência Artificial, Machine learning, Veículos autônomos, Veículos inteligentes.

1 INTRODUÇÃO

Numerosas iniciativas industriais e de pesquisa foram realizadas para melhorar a segurança dos veículos, prevenir acidentes e prever os resultados de acidentes rodoviários e de veículos. Dentre as estratégias, o uso de veículos autônomos se destaca pelo seu potencial de prevenir erros humanos e responder prontamente a acidentes em tempo real [1]. A condução autônoma transcende os padrões de tráfego convencionais, reconhecendo proativamente eventos críticos com antecedência, garantindo a segurança dos passageiros e proporcionando-lhes um transporte confortável, especialmente em ambientes de tráfego altamente estocásticos e variáveis [2]. Tecnologias baseadas em aprendizado de máquina, aprendizado profundo, e inteligência artificial são vitais para carros autônomos. A razão pela qual a Inteligência Artificial (IA) está sendo rapidamente implantada em uma série de indústrias é que ela tem a capacidade de aprender e resolver problemas de forma solitária [3]. Em carros autônomos, as aplicações de IA podem ser implantadas em conjunto com inovações tecnológicas avançadas, como GPS, radar, câmera,



serviços em nuvem e sinais de controle [4]. Está ocorrendo a transição de uma era de escassez de dados para uma era rica em dados (*big data*) e, por consequência, é preciso urgentemente de uma mudança de paradigma metodológico de modelos baseados em física para métodos guiados por IA, que possam projetar futuras dinâmicas de tráfego compostas por VAs trafegando ao lado de veículos movidos por humanos (VH) e auxiliar na formulação de políticas socialmente otimizadas [5]. Modelos baseados na física referem à todas as hipóteses científicas sobre o movimento de carros ou fluxo de tráfego, enquanto métodos guiados por IA refletem modelos de ponta que imitam a inteligência humana, incluindo redes neurais profundas, aprendizado por reforço, aprendizado por imitação e outros métodos avançados de aprendizagem de máquina [5]. Este trabalho tem foco em métodos guiados por IA e aplica uma metodologia de revisão dos principais pontos que circundam o tema proposto.

2 OBJETIVO

Este trabalho tem o objetivo de explorar as diversas iniciativas industriais e de pesquisa acerca da aplicação de técnicas de IA à condução veicular autônoma. A transição para uma era de abundância de dados demanda uma mudança de paradigma dos modelos baseados em física para métodos guiados por IA, capazes de prever dinâmicas de tráfego futuras e auxiliar na formulação de políticas de trânsito otimizadas, cujo potencial reside em fatores como a redução de erros de natureza humana e na resposta rápida a acidentes em tempo real, fatores estes que justificam o estudo apresentado.

3 METODOLOGIA

Neste artigo trazemos uma visão holística sobre os principais princípios de IA e suas aplicações no contexto de veículos autônomos, dissertando sobre o padrão internacional de níveis de automação veicular e concentrando-se nos métodos de IA aplicados a estruturas Ponta a Ponta (*Frameworks End-to-End*), guiadas por aprendizado de máquina, em detrimento de estruturas Pipeline. Exploramos também detalhes acerca das arquiteturas de Redes Neurais MLP (*Multi-Layer Perceptron*) e KAN (*Kolmogorov–Arnold Networks*), os principais conceitos e estratégias que guiam essas técnicas, bem como limitações dessas arquiteturas. Por fim elencamos alguns dos principais desafios e perspectivas futuras retirados desta pesquisa, tanto do ponto de vista de pesquisa científica quanto de mercado, dentre outros aspectos relacionados à Aprendizagem de Máquina (*Machine Learning, ML*), Aprendizagem Profundo (*Deep Learning, DL*), Aprendizagem por Reforço (*Reinforcement Learning, RL*), bem como o uso conjunto destas na implantação de VAs.



4 DESENVOLVIMENTO

A condução autônoma transcende os padrões de tráfego tradicionais ao realizar tarefas como o reconhecimento proativo de eventos críticos, planejamento dos movimentos seguintes, tomada de decisões e realização de tarefas de controle visando garantir a segurança e o conforto dos passageiros em ambientes de tráfego dinâmicos. Nas seções seguintes nos aprofundaremos no contexto da aplicação de IA à condução autônoma.

4.1 CONDUÇÃO VEICULAR AUTÔNOMA

A pesquisa sobre Sistemas de Condução Autônoma está ganhando importância nas últimas décadas, revolucionando enormemente a indústria automotiva [6]. Os sistemas de IA fazem uso de dados e algoritmos para personificar as funções cognitivas do cérebro humano [3]. A IA está tornando nossa vida diária mais conveniente e eficiente, sendo essencialmente o esforço de produzir sistemas com comportamento cognitivo semelhante ao humano, como a capacidade de raciocinar, resolver um problema, descobrir significado e perceber experiências passadas e agir de modo coerente [4]. Há um interesse crescente neste campo, uma vez que a implantação de veículos autônomos nas estradas promete sistemas de transporte mais seguros e ecológicos [1]. O controle de veículos é um dos desafios mais críticos em veículos autônomos e veículos conectados e automatizados, e é fundamental na segurança dos veículos, no conforto dos passageiros, na eficiência do transporte e na economia de energia [7]. Os problemas dos automóveis convencionais, como a falta de segurança rodoviária, a baixa independência das pessoas com deficiência, os custos elevados, menos produtividade, congestionamento de tráfego, longo tempo de viagem e poluição ambiental podem ser evitados com a condução autônoma de carros por meio da aplicação de IA [4]. Grupos específicos de pessoas impossibilitadas de conduzir, como idosos, jovens ou pessoas com deficiência poderão desfrutar da mobilidade promovida por esta tecnologia. Outro aspecto relevante da aplicação de direção autônoma é que esta também pode ajudar a tornar a condução mais eficiente, reduzindo o consumo de combustível e, conseqüentemente, um menor impacto adverso sobre o meio ambiente [6]. Um ambiente de tráfego urbano consiste em entidades de tráfego, incluindo carros, semáforos, pedestres, ciclistas, scooters e outros usuários da estrada. Este ambiente de tráfego misto multimodal complica ainda mais o controle dos veículos autônomos que circulam ao lado de vários usuários da estrada [5]. Embora a automação de veículos já tenha levado a grandes conquistas no apoio ao motorista em diversas tarefas monótonas e desafiadoras, observa-se que, por exemplo, aumentar o nível de automação para uma condução totalmente automatizada é um problema extremamente desafiador. Isto se deve principalmente à complexidade dos ambientes do mundo real, incluindo evitar obstáculos e aspectos do comportamento humano ao dirigir [8]. Na era da autonomia mista, quando os VAs circulam ao lado de veículos dirigidos por humanos [5], de acordo com [9], o objetivo



principal dos carros autônomos é mitigar acidentes e erros humanos, aumentando assim a segurança rodoviária.

Ao buscar reduzir os erros humanos motivadores de acidentes como desatenção, distração ou embriaguez do motorista, a direção autônoma tem o potencial de salvar milhares de vidas, uma vez que veículos autônomos são projetados para executar manobras adequadas a fim, dentre outros, de eliminar o risco de acidentes [6]. Os humanos são propensos à fadiga, desatenção e sonolência. Além disso, o uso de tecnologias em veículos como smartphones, sistemas de entretenimento e navegação podem tirar a atenção do motorista e comprometer a segurança ao dirigir. Portanto, os custos dos acidentes rodoviários para a sociedade são elevados em termos de lesões humanas e perdas econômicas [1]. Conforme apontado em [10], aproximadamente 1,19 milhões de pessoas morreram em acidentes de trânsito em 2023 em todo o mundo. Ainda de acordo com a Organização Mundial da Saúde (OMS), 90% do total de mortes no trânsito ocorre em países de baixa e média renda, como são os casos de nações latino-americanas. Segundo o relatório [11], 392 mil pessoas morreram no Brasil em decorrência de acidentes de trânsito entre 2010 e 2019, um aumento de 13,5% em comparação com a década anterior. Corroborando esses dados, o relatório [11] do Observatório Nacional de Segurança Viária aponta que o Brasil terminou o ano de 2017 com 35.375 mortes, valor que custou aos cofres nacionais cerca de 62 bilhões de reais. Ainda segundo este último relatório, no total, as projeções estimam que os gastos com acidentes de trânsito até 2027 resultariam em um acumulado de 640 bilhões de reais e que 90% dos acidentes ocorrem por falhas humanas, que vão desde desatenção até desrespeito à legislação de trânsito. Deste modo, observa-se que a pesquisa relacionada a VAs justifica-se pelo seu potencial de proporcionar alternativas que visam garantir mais conforto e segurança aos usuários, além de facilitar a locomoção de grupos específicos de indivíduos e, conforme apresentado neste artigo, a IA figura como peça chave no contexto de controle de VAs.

4.2 CONTEXTUALIZANDO A CONDUÇÃO VEICULAR AUTÔNOMA

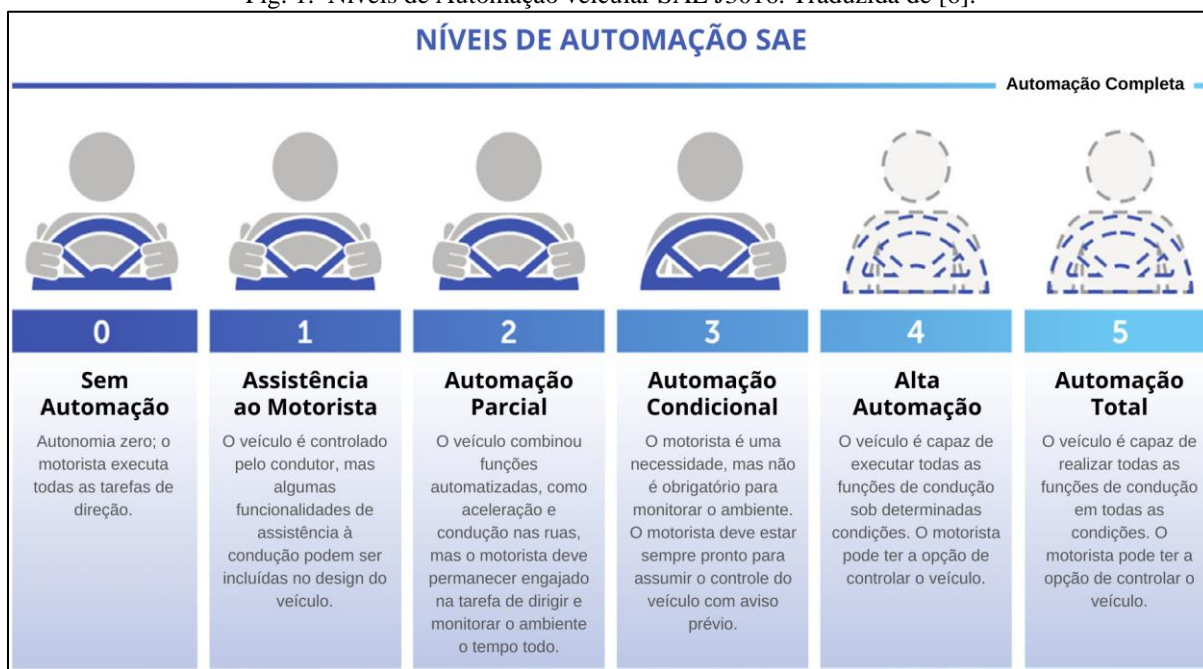
A condução autônoma refere-se à capacidade de um veículo circular parcial ou totalmente sem intervenção humana [2]. Com o surgimento de técnicas de IA computacionalmente poderosas, os veículos autônomos podem detectar seu ambiente com alta precisão, tomar decisões seguras em tempo real e operar de forma mais confiável sem intervenções humanas [13]. O estágio de implantação de VA pode ser dividido em quatro fases de diferentes complexidade de modelagem: os veículos conduzidos por humanos (VH) puros, os dominados por VH, os dominados por VA e os VAs puros, destacando que a modelagem destas fases abrangem teoria dos jogos, aprendizagem profunda e aprendizagem por imitação [5]. Através do grupo de trabalho conjunto entre a *Society of Automotive Engineers (SAE International)* e a *International Organization for Standardization (ISO)* denominada SAE/ISO, representantes de nove países trabalham colaborativamente em um documento normativo consistente para uso em toda a comunidade de mobilidade

global denominado SAE-J3016 [14] que, conforme apontado em [5, 6, 15], define uma taxonomia para seis níveis de automação de direção no contexto de veículos motorizados e sua operação nas estradas: do Nível 0 (sem automação de direção) ao Nível 5 (automação de direção total). Esses seis níveis de automação veicular SAE J3016 foram esquematizados em [15], do seguinte modo:

- a. Nível 0: O operador individual é responsável por todas as atividades operacionais (sem automação).
- b. Nível 1: O veículo é controlado por um motorista humano, mas o sistema de automação auxilia na operação (assistência aos motoristas).
- c. Nível 2: O veículo utiliza recursos automatizados, mas o controle e o ambiente do processo de direção requerem intervenção humana (condução parcialmente automatizada).
- d. Nível 3: O condutor humano deve estar pronto para assumir o controle do veículo a qualquer momento (condução condicional automatizada).
- e. Nível 4: Sob algumas condições, o sistema de automação pode dirigir o carro automaticamente, mas o operador humano ainda será capaz de controlá-lo (automação de direção de alto nível).
- f. Nível 5: Sob todas as condições, o sistema de automação pode dirigir o carro automaticamente, mas o operador humano será capaz de controlá-lo (carros sem motorista totalmente automatizados).

A Figura 1 [6] ilustra os níveis de automação veicular segundo a norma SAE J3016.

Fig. 1. Níveis de Automação veicular SAE J3016. Traduzida de [6].



Em [1] é feita a distinção entre os sistemas de segurança passivo e ativo, citando os cintos de segurança e os airbags como sistemas de segurança passiva e elucidando o fato de que esses sistemas

tornaram-se equipamentos de segurança padrão para veículos, mas que são soluções reativas, ou seja, aquelas utilizadas após a ocorrência de um acidente. Como resultado disso as tecnologias de segurança ativa estão se tornando assunto de discussão entre fabricantes de automóveis e pesquisadores. De acordo com [15], vários pesquisadores e organizações estão tentando atingir o nível 5 de automação e, dentre aquelas que desenvolvem pesquisa, as principais empresas: Google, Argo AI, Nvidia, Mercedes Benz, Ford, Volvo, Lyft e Aptiv, além de universidades e outras instituições voltadas à pesquisa.

A estrutura operacional para operação de veículos autônomos em cenários de tráfego dinâmicos e imprevisíveis necessita de uma orquestração meticulosa de coleta de dados e processamento através de uma série de camadas orientadas por software. Este processo engloba tarefas abrangentes: coleta e processamento de dados através de sensores, a fase de percepção, implicando o reconhecimento e interpretação das circunstâncias ambientais prevaletentes e a execução do planejamento de controle [9]. A Figura 2 [9] representa as tarefas *Sensing* (Sensoriamento), *Perception* (Percepção), *Planning* (Planejamento) e *Control* (Controle) no contexto de veículos autônomos, ilustrando camadas distintas de software que são únicas para o VA, característica esta ausente no domínio dos veículos convencionais.

Fig. 2. Tarefas em veículos autônomos. Traduzida de [9].



Dentro do domínio de sistemas de veículos autônomos, diferentes paradigmas de segurança são implementados e caracterizável em categorias distintas: a primeira categoria pertence à camada granular de nós, ferramentas e componentes dentro do sistema. Aqui as soluções são independentes de comunicação e de aproveitamento de conjunto de dados complexos. A segunda categoria investiga as considerações de segurança no sistema e níveis de comunicação. Esta examina meticulosamente os fatores críticos e formula soluções dentro das complexidades da rede e do sistema, sustentadas pelos dados existentes sobre segurança no trânsito [9]. Automação e conectividade são duas tecnologias distintas. Os VAs podem ou não ter conectividade, enquanto os veículos conectados podem ou não ter automação. Veículo conectado refere-se à tecnologia veicular que permite aos usuários se comunicarem entre si dentro dos ecossistemas de transporte de superfície [5].



As escolhas de condução dos veículos contêm três níveis: nível operacional (incluindo controle de pedal e frenagem), nível tático (compreendendo manutenção e mudança de faixa) e nível estratégico (incluindo roteamento). Os controles operacionais e táticos podem ainda ser categorizados em controle longitudinal (isto é, seguimento de carro, manutenção de faixa) e controle lateral (isto é, mudança de faixa), respectivamente [5, 15]. Este trabalho fornece uma visão holística sobre esses três níveis de condução.

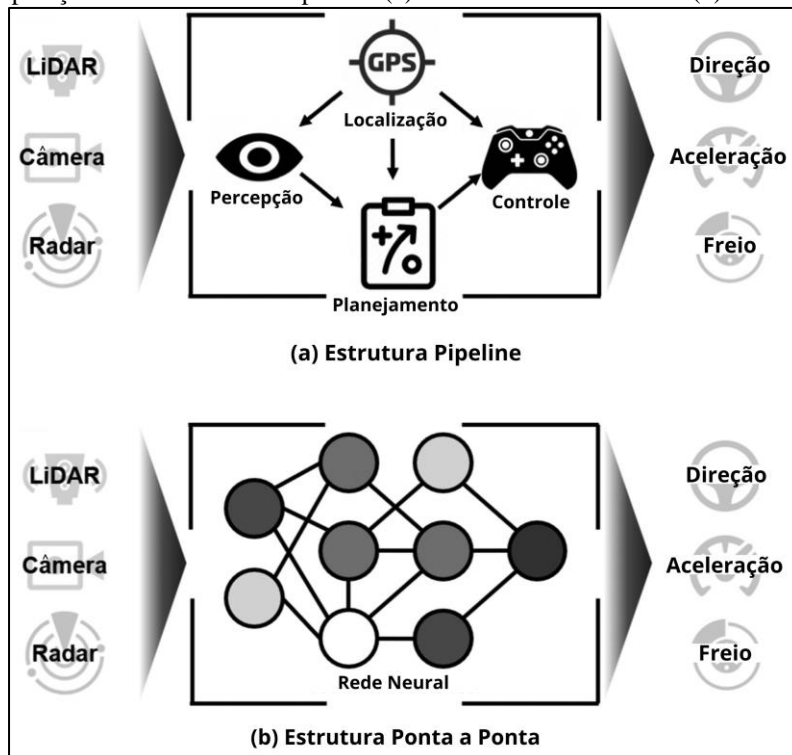
4.3 INTELIGÊNCIA ARTIFICIAL APLICADA A VEÍCULOS AUTÔNOMOS: CONCEITOS E ESTRATÉGIAS RELEVANTES

Antes de seguir o estudo sobre IA aplicada para VAs, deve-se atentar para duas estruturas (*Frameworks*) que, segundo [2, 16, 17], se destacam no contexto da pesquisa de condução autônoma de veículos: a estrutura Pipeline modular e a estrutura Ponta a Ponta (*Framework End-to-End*). A primeira consiste em vários submódulos, cada um como funcionalidade específicas, enquanto a segunda representa uma abordagem simplificada de módulo único (pipeline modular) [2]. No contexto de planejamento de movimento para condução autônoma, o método de planejamento de pipeline, também conhecido como método de planejamento baseado em regras, é uma categoria bem estabelecida de planejadores [16]. A arquitetura modular é amplamente utilizada em abordagens de sistemas de direção autônoma, que divide o pipeline de condução em subtarefas discretas. Esta arquitetura depende de sensores e algoritmos individuais para processar dados e gerar saídas de controle, abrangendo módulos interconectados, incluindo percepção, planejamento e controle, mas que, no entanto, tem certas desvantagens que impedem avanços adicionais na direção autônoma [2, 17]. Pipelines modulares geralmente envolvem redundância de cálculos, já que cada módulo é treinado para resultados específicos da tarefa, sendo uma limitação significativa da arquitetura de pipeline sua suscetibilidade à propagação de erros de um módulo para outro subsequente, o que pode levar a comportamentos inseguros. A complexidade do gerenciamento dos módulos interconectados e a inferência computacional do processamento dos dados em cada etapa representa desafios adicionais [2]. Uma vantagem significativa da estrutura de pipeline é sua interpretabilidade, permitindo a identificação de módulos defeituosos quando ocorrem mau funcionamento ou comportamento inesperado do sistema. Embora amplamente utilizado na indústria, o método de planejamento de pipelines requer recursos computacionais substanciais e inúmeras funções heurísticas [16]. A abordagem de Pipelines modulares envolve projetos sofisticados baseados em regras, que muitas vezes são ineficazes para lidar com o grande número de situações que ocorrem na estrada e, portanto, há uma tendência crescente para aproveitar dados em grande escala e utilizar o planejamento baseado na aprendizagem como uma alternativa viável [17], referindo-se a abordagem Ponta a Ponta.

A abordagem Ponta a Ponta possui uma arquitetura simplificada, que consiste em uma ou algumas redes e também oferece robustez superior e recursos em tempo real em comparação com a estrutura de

pipeline [16]. Em comparação com pipelines modulares, estruturas Ponta a Ponta se beneficiam da otimização conjunta de recursos para percepção e planejamento [17]. Esta abordagem é um paradigma promissor, pois contorna as desvantagens associadas aos sistemas modulares, como sua enorme complexidade e propensão à propagação de erros e visa superar as limitações da arquitetura modular, de modo a simplificar o sistema, melhorando a eficiência e a robustez, mapeando diretamente a entrada sensorial para controlar as saídas, de modo a otimizar o pipeline de condução [2]. A comunidade de condução autônoma tem testemunhado um rápido crescimento em abordagens que adotam uma estrutura de algoritmo de Ponta a Ponta, utilizando informações brutas de sensores para gerar planos de movimento de veículos, em vez de se concentrarem em tarefas individuais, como detecção e previsão de movimento [17]. Em uma abordagem Ponta a Ponta, ao invés de montar um sistema baseado em componentes que são ajustados individualmente, constrói-se o sistema e então ajusta seu desempenho em conjunto [18]. Os benefícios da condução autônoma Ponta a Ponta atraíram atenção significativa na comunidade de pesquisa [2]. No entanto, [16] aponta que, à medida que a pesquisa avança, a otimização Ponta a Ponta enfrenta um problema crítico de interpretabilidade. Sem resultados intermediários, rastrear a causa inicial de um erro e explicar por que o modelo chegou a comandos de controle ou trajetórias específicas torna-se mais desafiador. A abordagem Ponta a Ponta simplifica o sistema, melhorando a eficiência e a robustez através do mapeamento direto dos dados sensoriais de entrada para controlar as saídas [2]. A Figura 3 [16] representa as abordagens Pipeline modular e Ponta a Ponta.

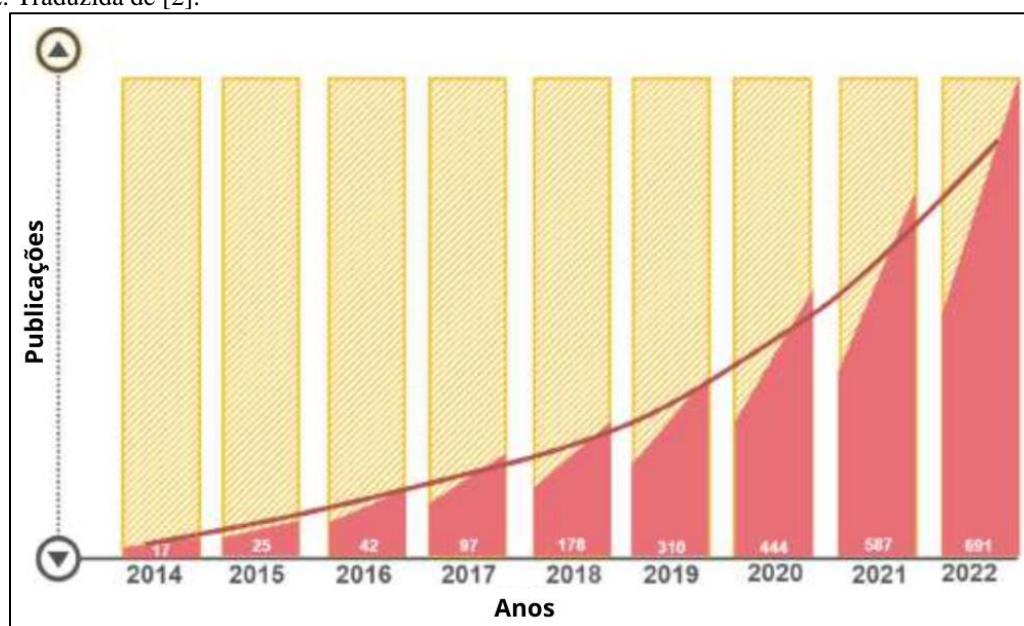
Fig. 3. Comparação entre a estrutura Pipelines (a) e estrutura Ponta a Ponta (b). Traduzida de [16].



A estrutura Pipeline para condução autônoma pode ser resumida como um conjunto de módulos interconectados, enquanto o método Ponta a Ponta trata todo o contexto como uma estrutura que pode ser aprendida [16]. Além da abordagem Ponta a Ponta visar superar as limitações da arquitetura modular, está em crescente tendência na comunidade de pesquisa [2], conforme o número de artigos na base de dados Web of Science contendo as palavras-chave “*End-to-End*” e “*Autonomous Driving*” ilustrado na Figura 4 [2].

Carros autônomos são essencialmente construídos com inteligência artificial [4]. No geral, foi demonstrado que várias abordagens de IA podem fornecer soluções promissoras para os VAs no reconhecimento do ambiente e na propulsão do veículo com tomadas de decisão adequadas [19]. Os pilares fundamentais da IA que sustentam a existência de carros autônomos são: Aprendizado de Máquina, Aprendizado Profundo, Internet das Coisas (*Internet of Things*, IoT), Visão Computacional e Capacidades Cognitivas [3]. Este trabalho concentra-se nos dois primeiros conceitos.

Fig. 4. Número de artigos na base de dados Web of Science contendo as palavras-chave “End-to-End” e “Autonomous Driving” de 2014 a 2022. Traduzida de [2].



4.4 APRENDIZADO DE MÁQUINA

Uma das principais tarefas de um Algoritmo de ML em um carro autônomo é a detecção contínua dos ambientes circundantes e o cálculo das possíveis mudanças nesses ambientes [3]. Todo aprendizado de máquina está relacionado com a extração de informações dos dados e normalmente requer trabalhar com grandes conjuntos de dados [18]. ML refere-se à capacidade de uma máquina de compreender e aprender uma tarefa específica e tomar decisões sem intervenção humana e, eventualmente, melhorar-se para executar a mesma tarefa a partir do ganho de experiência sem uso da programação explícita, podendo-se dividir o



aprendizado de máquina em dois tipos: Aprendizado Supervisionado (*Supervised Learning*, SL) e Aprendizado Não Supervisionado (*Unsupervised Learning*, US) [3].

O aprendizado supervisionado (SL) é resumido em [20] como o ato de aprender com um conjunto de exemplos de treinamento rotulados fornecidos por um supervisor externo qualificado. SL envolve a análise de um conjunto de dados e os resultados conhecidos [3]. Essa definição é reforçada por [18] ao afirmar que SL aborda a tarefa de prever labels com recursos de entrada, onde cada par recurso-rótulo é chamado de exemplo. A supervisão entra em jogo porque para a escolha dos parâmetros, os supervisores fornecem ao modelo um conjunto de dados consistindo em exemplos rotulados, onde cada exemplo é correspondido com o label verdade fundamental [18].

Por outro lado, o aprendizado não supervisionado (US) é usado no caso de dados não classificados e não rotulados [3]. Os termos aprendizagem supervisionada e aprendizagem não supervisionada parecem classificar exhaustivamente os paradigmas de aprendizagem de máquina, mas não o fazem e, portanto, consideramos a aprendizagem por reforço (RL) um terceiro paradigma de aprendizagem de máquina, juntamente com a aprendizagem supervisionada, a aprendizagem não supervisionada e talvez também outros paradigmas [20]. Este trabalho aborda os conceitos e paradigmas de ML mais relevantes para o campo de estudo voltado a autonomia veicular.

As abordagens de SL dependem fortemente de grandes quantidades de dados rotulados para serem capazes de generalizar e são basicamente treinadas em cada tarefa isoladamente, no entanto, obter uma grande quantidade de dados para cada tarefa individual na condução autônoma é dispendioso e demorado, sendo necessário um enorme trabalho humano para rotular esses dados e ainda assim pode não cobrir todas as situações complexas da condução no mundo real [21].

4.5 APRENDIZADO POR REFORÇO

Aprendizagem por Reforço (*Reinforcement Learning*, RL) é um campo de aprendizagem por tentativa e erro que tem sido aplicada com sucesso na condução de Ponta a Ponta quando combinada com SL [17]. RL é capaz de aprender por tentativa e erro e não requer rotulagem ou supervisão humana explícita em cada amostra de dados, em vez disso, precisa de uma função de recompensa bem definida para receber sinais de recompensa no seu processo de aprendizagem [21]. O objetivo do RL é expresso como funções de recompensa, e muitos algoritmos exigem que elas sejam densas e forneçam feedback em cada etapa do ambiente [17]. A recompensa é necessária em quase todos os algoritmos de aprendizagem por reforço e estima quão bem o agente executa uma ação em um determinado estado (ou quais são as coisas boas ou ruins para o agente) [22].

A execução de RL em VAs do mundo real é uma tarefa desafiadora [16]. Os algoritmos RL aprendem sentindo o ambiente diretamente e não têm acesso à dinâmica de transição (isto é, conhecimento prévio) do



ambiente explorado [13]. Na estrutura RL, um agente interage com o ambiente em uma sequência de ações (selecionadas seguindo uma política específica), observações e recompensas [8]. Os algoritmos RL visam aprender uma política, que é um mapa dos estados às ações, com base na resposta recebida da interação com o meio ambiente [23]. Métodos de RL são usados para manutenção e controle de vários aspectos dos veículos autônomos conectados, como definir posições angulares específicas para direção [15]. A cada passo de tempo t , o agente (VA) observa o estado do ambiente $s_t \in S$ e, com base em uma política específica, seleciona uma ação em $a_t \in A$, onde S é o espaço de estados e $A = \{1, \dots, K\}$ é o conjunto de ações disponíveis. Então, o agente observa o novo estado do ambiente, s_{t+1} , que é a consequência da aplicação da ação a_t no estado s_t , e um sinal de recompensa escalar r_t , que é uma medida de qualidade de quão bom é selecionar a ação a_t em estado s_t [8]. RL é diferente da aprendizagem supervisionada, o tipo de aprendizagem estudado na maioria das pesquisas atuais na área de aprendizado de máquina, bem como também é diferente do aprendizado não supervisionado, que normalmente trata de encontrar estruturas ocultas em coleções de dados não rotulados, ou seja, ainda que não se baseie em exemplos de comportamentos corretos, RL tenta maximizar um sinal de recompensa em vez de tentar encontrar uma estrutura oculta [20].

4.6 APRENDIZADO PROFUNDO

O Aprendizado Profundo (*Deep Learning*, DL) é uma solução para problemas mais intuitivos e complexos que não podem ser facilmente resolvidos usando métodos clássicos [3]. As abordagens de IA, predominantemente em termos de algoritmos de aprendizagem profunda, trouxeram melhorias consideráveis a muitos componentes essenciais (percepção, detecção de objetos, planejamento) da tecnologia de condução autônoma [13]. DL é profundo exatamente no sentido que seus modelos aprendem a partir de muitas camadas de transformações, onde cada camada oferece a representação em um nível [18], isto é, os modelos são treinados usando múltiplas camadas de dados de entrada [15].

O advento da aprendizagem profunda (DL) permitiu que muitos estudos abordassem diferentes questões desafiadoras em VAs, por exemplo, reconhecer e localizar com precisão obstáculos nas estradas, tomar decisões apropriadas (por exemplo, controlar o volante, aceleração/desaceleração), etc [19]. Os modelos de DL preferidos usados na tecnologia de carros autônomos incluem Aprendizado Ponta a Ponta (*End-To-End Learning*), Rede Neural Convolutiva (*Convolutional Neural Network*, CNN), Rede Neural Convolutiva Profunda (*Deep CNN*), Rede Totalmente Convolutiva (*Fully Convolutional Networks*, FCN), Redes Neurais Profundas (*Deep Neural Network*, DNN), Aprendizado por Reforço Profundo (*Deep Reinforcement Learning*, DRL), Máquinas Deep Boltzmann (*Deep Boltzmann Machine*, DBM), Redes de Crenças, e *Deep Autoencoders* [3]. Dentre as aplicações de DL no contexto de VAs, pode-se citar segundo [15], que DL permite que os VAs percebam um sinal de pare ou diferenciem um usuário de um poste

elétrico. Conforme [1], alguns estudos usaram implementações autônomas de aprendizagem profunda para problemas de detecção de faixas, enquanto algumas pesquisas concentram-se na fusão do aprendizado profundo com outras técnicas de aprendizado de máquina e metodologias clássicas.

As redes profundas mais simples são chamadas perceptrons multicamada, e eles consistem em várias camadas de neurônios cada um totalmente conectado àqueles na camada abaixo (do qual eles recebem contribuições) e aqueles acima (que eles, por sua vez, influenciam). Esta arquitetura é comumente chamada um perceptron multicamadas, frequentemente abreviado como MLP (*Multi-Layer Perceptron*) [18]. Utilizando o algoritmo backpropagation para treinamento, eles podem ser usados para uma ampla gama de aplicações, desde a aproximação funcional até a predição em diversos campos [24]. MLP adiciona uma ou várias camadas ocultas totalmente conectadas entre as camadas de saída e de entrada e transforma a saída da camada oculta por meio de uma função de ativação [18].

O perceptron multicamadas é o tipo de rede neural mais conhecido e usado com mais frequência. Na maioria das vezes, os sinais são transmitidos dentro da rede em uma direção: da entrada para a saída. Não há loop, a saída de cada neurônio não afeta o próprio neurônio. Perceptrons multicamadas (MLPs), também conhecidos como redes neurais feedforward [24] totalmente conectadas, são os blocos de construção fundamentais dos modelos atuais de aprendizagem profunda [25]. A Figura 5 [18] representa uma Rede MLP bem como suas camadas de entrada, saída e camada oculta.

O custo de parametrização de MLPs com camadas totalmente conectadas pode ser proibitivamente alto, o que pode motivar compensação entre o salvamento do parâmetro e a eficácia do modelo, mesmo sem alterar o tamanho de entrada ou saída [18]. Neste sentido, é proposto em [25] uma arquitetura de rede denominada KAN (*Kolmogorov–Arnold Networks*) com uma abordagem promissora, conforme comparativo entre redes MLP e redes KAN apresentado na Figura 6 [25].

A Rede KAN apresenta-se como uma nova arquitetura de rede neural projetada para substituir potencialmente os perceptrons multicamadas tradicionais [26]. Assim como os MLPs, os KANs possuem estruturas totalmente conectadas. No entanto, enquanto os MLPs colocam funções de ativação fixas em nós (“neurônios”), os KANs colocam funções de ativação que podem ser aprendidas nas bordas (“pesos”). Como resultado, os KANs não possuem nenhuma matriz de peso linear: em vez disso, cada parâmetro de peso é substituído por uma matriz de aprendizagem [25]. Ao contrário dos MLPs, que são inspirados no teorema da aproximação universal, os KANs aproveitam esse teorema de representação para gerar uma arquitetura diferente [26].

Fig. 5. Representação de uma Rede MLP na forma de um diagrama. Traduzida de [18].


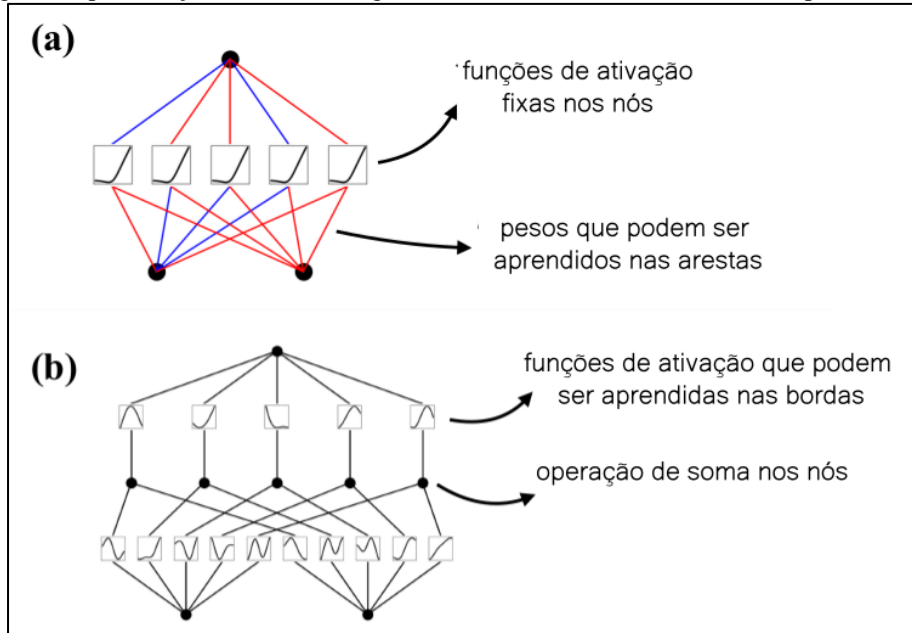


Fig. 6. Representação de modelos segunda as redes MLP (a) e KAN (b). Adaptada de [25].



4.7 APRENDIZADO POR REFORÇO PROFUNDO

O uso de algoritmos profundos em conjunto com outras técnicas mostrou resultados promissores [1], a exemplo do Aprendizado por Reforço Profundo (*Deep Reinforcement Learning, DRL*), onde é aplicado aprendizado profundo para problemas de aprendizagem de reforço [18]. A combinação de técnicas de DL e algoritmos de RL demonstraram o seu potencial para resolver algumas das tarefas mais desafiantes da condução autônoma [27]. O principal objetivo da RL é maximizar estatisticamente a recompensa a longo prazo [28]. DRL pode ser definido como uma combinação de DL e RL [3, 27, 28], surgindo como uma solução potencial para as limitações dos algoritmos de controle modernos de rastreamento de trajetória de VAs [7] e, conforme apontado por [18], sua aplicação vem se tornando popular DRL aprimora ainda mais o aprendizado por reforço usando o aprendizado profundo e redes neurais multicamadas [15].



As primeiras estratégias de tomada de decisão baseavam-se em regras, mas não eram adequadas para cobrir todos os cenários e, à medida que a tecnologia de aprendizagem profunda atinge a maturidade, a DRL, que apresenta grande representabilidade e capacidade de otimização, é promissora para o desenvolvimento de estratégias de tomada de decisão para veículos automatizados [29]. Ao implementar um algoritmo de aprendizagem por reforço profundo, os VAs aprendem uma política de controle ideal interagindo com o meio ambiente e utilizando os dados coletados [7]. Pode ser difícil para o algoritmo aprender com todos os estados e determinar o caminho da recompensa. Neste sentido, algoritmos baseados em DRL substituem métodos tabulares de estimativa de valores de estado (todos possíveis pares de estado e valor devem ser armazenados) por uma função de aproximação que permite ao VA generalizar o valor de estados que nunca viu antes, ou viu parcialmente, usando os valores de estados semelhantes [27]. O uso abrangente da convolução separável em profundidade juntamente com o transformador em arquiteturas baseadas em DRL para inferência de decisão de mudança de faixa pode gerar uma política ideal [30].

Geralmente, na estrutura DRL, o agente é capaz de dirigir em um ambiente incerto selecionando uma sequência de ações ao longo de vários passos de tempo contínuo. Posteriormente, concederá recompensas conforme o feedback da interação com o meio ambiente. Por fim, será escolhida uma estratégia com recompensa cumulativa máxima [30]. Os algoritmos de DRL incluem: *Deep Q-learning Network* (DQN), *Double-DQN*, Ator-Crítico (A2C, A3C), *Deep Deterministic Policy Gradient* (DDPG) e DDPG com Atraso Duplo (TD3) [27].

4.8 ALGORITMOS, ABORDAGENS TEÓRICAS E ESTRATÉGIAS DE APRENDIZADO DE MÁQUINA RELEVANTES

Os VAs surgiram como uma tecnologia promissora para melhorar a segurança e a mobilidade no trânsito. No entanto, projetar VAs envolve vários aspectos críticos, como requisitos de software e sistema, que devem ser cuidadosamente abordados [9]. A IA pode substituir completamente os humanos pela automação com melhor segurança e movimentação inteligente de veículos, de modo que softwares e ferramentas inteligentes são necessários para o design e desenvolvimento eficiente de VAs [15]. Os requisitos de software e sistema estão entre os aspectos que exigem consideração na criação de veículos. Embora estes aspectos tenham uma importância mínima nos veículos tradicionais, os carros autônomos podem potencialmente provocar danos, acidentes e comprometer a segurança [9]. O Sistema de Condução Autônoma envolve muitos subsistemas que precisam ser integrados como um sistema maior. Algumas das tarefas incluem planejamento de movimento, localização de veículos, detecção de pedestres, detecção de sinais de trânsito, detecção de marcações rodoviárias, estacionamento automatizado, segurança cibernética de veículos e diagnóstico de falhas do sistema [6]. Os últimos anos testemunharam o surgimento de abordagens e soluções que utilizam sensores de dados para coletar informações em tempo real do entorno



[9]. Estes sistemas antecipam eventos, preveem acidentes e avaliam as condições ambientais, permitindo assim a tomada de decisões automatizadas em vários níveis de condução autônoma.

A IA é uma tecnologia crítica para a funcionalidade eficiente dos veículos autônomos, que a utilizam em conjunto com tecnologias sensoriais e minimiza o risco. No campo da detecção de objetos, visão computacional e segmentação semântica, o aprendizado profundo tem sido muito eficaz [15]. Em softwares tradicionais, a lógica operacional é escrita manualmente e depois testada em uma série de casos de teste, enquanto no caso do software baseado em DNN, o software aprende e se adapta a determinadas situações com a ajuda de grandes conjuntos de dados [3]. A taxa de precisão de abordagens de IA, como DNN, atingiu o valor de 99,46% e superou o reconhecimento humano em alguns testes [19]. Redes Neurais avançadas são usadas para prever o mau funcionamento de sensores, como previsão, identificação e isolamento de sensores defeituosos [4]. A abordagem de DL tornou-se mais popular que ML devido ao seu desempenho eficaz tanto na classificação quanto na detecção, utilizando quadros de imagem como entrada para o algoritmo de rede [1]. 63% dos estudos revisados utilizam vários métodos de IA, sendo DL o mais prevalente (34%) [9].

Os algoritmos RL no contexto de controle têm sido usados principalmente para resolver a regulação e o rastreamento ótimos de sistemas monoagentes e multiagentes [23]. Abordagens automáticas de tomada de decisão, como RL, têm sido aplicadas para controlar a velocidade do veículo, dentre outras tarefas no contexto de VAs [22]. A maioria dos sistemas dinâmicos do mundo real, incluindo veículos não tripulados, são inerentemente não lineares. Encontrar a solução ótima para sistemas não lineares requer a resolução de uma equação diferencial parcial não linear, a saber, a equação de Hamilton-Jacobi-Bellman (HJB). Resolver explicitamente a equação HJB é geralmente muito difícil ou mesmo impossível. O aprendizado por reforço é uma das técnicas mais empregadas para aproximar a solução HJB, sendo portanto, amplamente utilizado em sistemas de veículos não tripulados [23].

4.9 PERCEPÇÃO, PLANEJAMENTO DE MOVIMENTO, TOMADA DE DECISÕES E CONTROLE

Quatro módulos significativos estão contidos em veículos autônomos: percepção, tomada de decisão, planejamento e controle [31]. É essencial que o veículo reconheça as suas próprias circunstâncias e se adapte a elas para poder conduzir automaticamente [22]. O módulo de geração de trajetória aproveita informações de percepção para calcular um conjunto de trajetórias futuras [16]. A percepção é considerada como uma ação de VA que usa sensores para escanear e monitorar continuamente o ambiente, de modo semelhante à visão humana e outros sentidos [19], indicando que os veículos autônomos conhecem as informações sobre os ambientes de condução com base nas de uma variedade de sensores, como Radar, LiDAR (*Light Detection and Ranging*) e Sistema de Posicionamento Global (*Global Positioning System*, GPS) [31]. No caso dos algoritmos atuais, os processos de percepção e planejamento são combinados para um planejamento consciente do comportamento, muitos dos quais dependem de aprendizado de máquina [6].



Os métodos de planejamento são responsáveis por calcular uma sequência de pontos de trajetória para o controlador de baixo nível do VA rastrear, normalmente consistindo em três funções: planejamento de rota global, planejamento de comportamento local e planejamento de trajetória local [16].

Algoritmos DRL têm sido amplamente empregados como planejamento de movimento independente ou módulos de controle para veículos autônomos [21]. Na área de planejamento de movimento, as recompensas finais do episódio são calculadas a partir do cumprimento ou fracasso da tarefa de direção [28]. O objetivo do planejamento para questões de trajetória geralmente é encontrar uma relação possível do estado original para atingir um estado alvo [6]. Foram desenvolvidas diversas abordagens para a camada de controle de um AV, que são comumente classificadas em controlador clássico e controladores baseados em IA. A diferença em termos de aplicabilidade entre esses controladores é que, enquanto as técnicas de controle puramente convencionais oferecem um comportamento determinístico, os controladores baseados em IA têm um comportamento estocástico devido ao fato de aprenderem com um determinado conjunto de recursos [27]. Um controlador define a velocidade, o ângulo de direção e as ações de frenagem necessárias em cada ponto do caminho obtido a partir de um mapa pré-determinado, como o Google Maps, ou registro de direção especializado dos mesmos valores em cada ponto de referência. O rastreamento de trajetória, em contraste, envolve um modelo temporal da dinâmica do veículo visualizando os pontos de referência sequencialmente ao longo do tempo [32].

O planejamento de trajetória é um módulo crucial no processo de condução autônoma. Dado um plano de nível de rota a partir de mapas HD ou mapas baseados em GPS, este módulo é necessário para gerar comandos de nível de movimento que orientam o agente [32]. Apesar de uma quantidade significativa de esforços de aprendizado de máquina dedicados à visão computacional, a inteligência dos AVs reside na sua tomada de decisão ideal na fase de planejamento de movimento [5]. A função de tomada de decisão que recebe as informações do ambiente e gera intenções de alto nível para VA é um componente crucial na elaboração da estratégia de direção [29]. A aprendizagem por reforço profundo tem demonstrado grande sucesso na área de tomada de decisões comportamentais de veículos, especialmente em cenários de rodovias e cruzamentos urbanos [21]. DRL une aproximação de funções e otimização de alvos, mapeando pares estado-ação para recompensas esperadas [27]. O controlador de tomada de decisão gerencia os comportamentos de direção dos veículos e esses comportamentos incluem aceleração, frenagem, mudança e manutenção de faixa e assim por diante [31].

4.10 DESAFIOS E DIREÇÕES FUTURAS

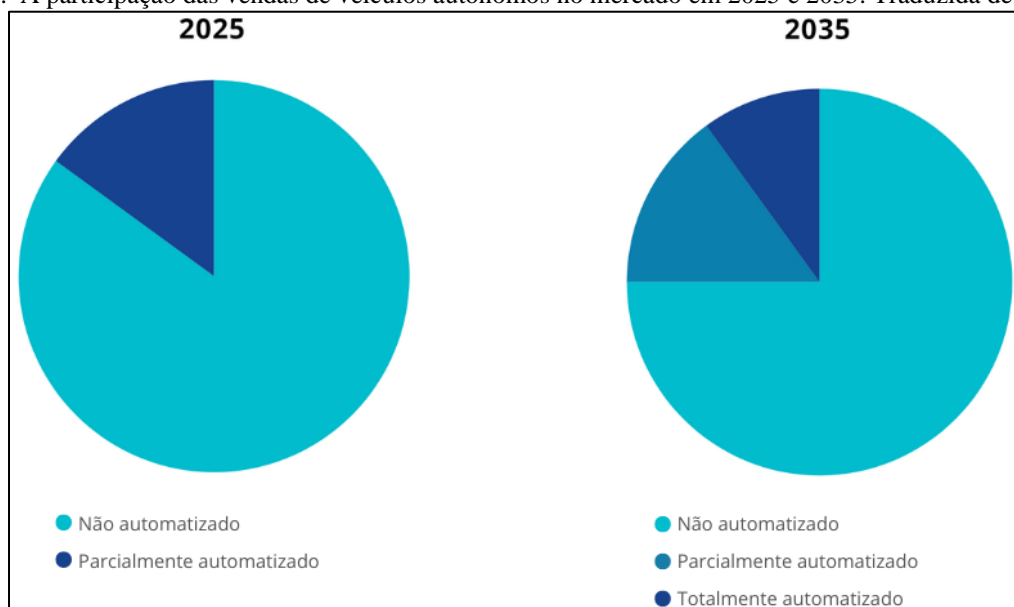
Apesar das contribuições notáveis dos principais especialistas na área, os Veículos Inteligentes permanecem confinados principalmente a programas de ensaio limitados devido a preocupações sobre a sua confiabilidade e segurança [16]. Os carros autônomos alimentados por IA enfrentam desafios como

aceitabilidade social, condições das estradas, tráfego, clima, privacidade de dados e segurança cibernética [4]. Os VAs terão impactos substanciais ao longo do tempo, mesmo que ainda estejam em desenvolvimento. Assim, há necessidade de estudar as precauções de segurança antes de aceitá-los em ambientes reais [15]. Garantir a segurança, robustez e adaptabilidade dos métodos de planejamento tornam-se cruciais para a implementação bem sucedida de sistemas de condução autônoma [16].

Até 2035, espera-se que os veículos sem condutor representem 25% do total de vendas de automóveis, sendo 15% parcialmente autônomos e 10% totalmente autônomos, em comparação com 12,4% em 2025. De acordo com a maioria dos especialistas do setor, a América do Norte se tornará o principal mercado para veículos autônomos. Os Estados Unidos serão líderes no mercado de veículos autônomos [4, 33]. A Figura 7 [4, 33] apresenta um comparativo entre a quantidade de veículos de autônomos, parcialmente automatizados e não automatizados nos anos de 2025 e 2035.

Pesquisas futuras também podem explorar maneiras de melhorar os mecanismos de feedback, permitindo que os usuários compreendam o processo de tomada de decisão e infundam confiança na confiabilidade dos sistemas de condução de ponta a ponta [2]. Os hábitos de condução humanos afetam o desempenho da tomada de decisões dos condutores e, portanto, a inclusão de hábitos de condução humanos na concepção de sistemas de condução autônoma pode melhorar a aceitação das tecnologias emergentes pelos condutores, sendo este cenário um provável alvo de pesquisas futuras [30].

Fig. 7. A participação das vendas de veículos autônomos no mercado em 2025 e 2035. Traduzida de [4, 33].



Quanto à escolha da arquitetura ideal para redes profundas, pesquisas futuras podem definir quais devem ser adotadas para situações específicas. Atualmente, o maior gargalo dos KANs reside na sua lentidão no treinamento. KANs são geralmente mais lentos do que MLPs, dado o mesmo número de parâmetros.



Portanto o treinamento lento dos KANs pode ser encarado mais como um problema de engenharia a ser melhorado no futuro, em vez de uma limitação fundamental [25], e essa informação pode nos dar alguma pista sobre futuras pesquisas sobre arquiteturas de redes profundas e suas aplicações.

Do ponto de vista legal cabe destacar que, até o momento que este artigo é construído, a legislação Brasileira ainda não possui uma Lei que regulamente os VAs. Atualmente, a principal referência legal para a circulação de veículos autônomos no Brasil é o Projeto de Lei 1.317/2023, que visa regulamentar a utilização de veículos autônomos em todo o território nacional e ainda está em tramitação na Câmara dos Deputados. Ademais, a Resolução 479/2018 do Conselho Nacional de Trânsito (Contran) define responsabilidades e regras quanto à realização de testes com VAs e requisitos mínimos de segurança, que podem nortear e facilitar os testes de protótipos de VAs Brasileiros. Como consequência, essa lacuna legal pode levar a impasses negativos em pesquisas e testes em VA. De acordo com [15], é necessário que os legisladores criem legislação que beneficie o país economicamente e socialmente, e complementa afirmando que estudos examinam o potencial dos AVs para se tornarem um “aplicativo matador” com consequências dramáticas.

5 CONSIDERAÇÕES FINAIS

Este artigo apresentou uma pesquisa bibliográfica sobre aprendizado de máquina aplicado à condução veicular autônoma, revisando os principais pontos que circundam o tema, fornecendo uma visão geral das aplicações da IA em VAs, os principais desafios, direções futuras, percepção do público, cenário atual do mercado de VAs, além de apresentar projeções de crescimento da área para a próxima década. As principais iniciativas de pesquisa e da indústria que permeiam o estudo direcionado a VAs foram apontadas, evidenciando o avanço significativo das pesquisas relacionadas ao tema nos últimos anos.

O foco em métodos guiados por IA representa uma evolução promissora na busca por um sistema de transporte mais seguro e eficiente. Em VAs, modelos de IA são integrados a tecnologias como GPS, LiDAR, Radar, câmeras, serviços em nuvem e sinais de controle, responsáveis por entender o ambiente que o agente de inteligência está inserido, a fim de tomar as melhores decisões e proporcionar respostas assertivas em tempo real. Métodos avançados de aprendizado de máquina, como aprendizado profundo (DL), aprendizado por reforço (RL), dentre outras técnicas, são fundamentais para promover o controle de VAs e formular políticas de tráfego mais seguras e otimizadas socialmente, dentro de um processo evolutivo de aprendizado.

Ao entender os principais mecanismos que circundam o tema de IA aplicada a VAs, observou-se que o uso conjunto de DL e RL se mostrou promissor no campo da condução autônoma, assim como a aplicação de modelos de redes KANs em detrimento de redes MLPs em determinados contextos de



aprendizado, apesar de geralmente KANs serem mais lentas do que MLPs no que diz respeito ao treinamento dos modelos, dado o mesmo número de parâmetros.

A condução autônoma não apenas supera os padrões tradicionais de tráfego, mas também promove mais segurança e conforto aos passageiros em ambientes de tráfego estocásticos e altamente variáveis, fato este que explica o crescente aumento por pesquisas na área de condução veicular autônoma, tendo a IA como um dos principais objetos de estudos da área. Portanto, as pesquisas e inovações contínuas nessa área são essenciais para enfrentar os desafios e maximizar os benefícios dos veículos autônomos na sociedade moderna.



REFERÊNCIAS

- N. J. Zakaria, M. I. Shapiai, R. A. Ghani, M. N. M. Yassin, M. Z. Ibrahim, e N. Wahid, "Lane Detection in Autonomous Vehicles: A Systematic Review," *IEEE Access*, vol. 11, pp. 3729-3765, Jan. 2023. doi: 10.1109/ACCESS.2023.3234442.
- P. Chib, e P. Singh, "Recent Advancements in End-to-End Autonomous Driving Using Deep Learning: A Survey," *IEEE Transactions on Intelligent Vehicles*, vol. 9, no. 1, pp. 103-118, Jan. 2024. doi: 10.1109/TIV.2023.3318070.
- Dudwadkar, B. Deshpande, e I. Zare, "Artificial Intelligence Used In An Autonomous Car: A Review," *International Journal of Emerging Technologies and Innovative Research*, vol. 6, issue 4, pp. 361-368, Abr. 2019. Disponível em: <http://www.jetir.org/papers/JETIR1904F59.pdf>.
- Karnati, D. Mehta, e M. Ks, "Artificial Intelligence in Self Driving Cars: Applications, Implications and Challenges," *Ushus - Journal of Business Management*, 2022, Vol. 21, No. 4, p. 1-28. ISSN 0975-3311. Disponível em: <https://doi:10.12725/ujbm.61.1>.
- X. Di, e R. Shi, "A survey on autonomous vehicle control in the era of mixed-autonomy: From physics-based to AI-guided driving policy learning," *Transportation Research Part C: Emerging Technologies*, v. 125, p. 103008, 2021. doi: 10.1016/j.trc.2021.103008.
- M. Bachute, e J. Subhedar, "Autonomous Driving Architectures: Insights of Machine Learning and Deep Learning Algorithms," *Machine Learning with Applications*, v. 6, p. 100164, 2021. doi: 10.1016/j.mlwa.2021.100164.
- W. Liu, M. Hua, Z. Deng, Z. Meng, Y. Huang, C. Hu, S. Song, L. Gao, C. Liu, B. Shuai, A. Khajepour, L. Xiong, e X. Xia, "A Systematic Survey of Control Techniques and Applications in Connected and Automated Vehicles," *IEEE Internet of Things Journal*, vol. 10, no. 24, pp. 21892-21916, 15 Dec. 2023. doi: 10.1109/JIOT.2023.3307002.
- K. Makantasis, M. Kontorinaki, e I. Nikolos, "Deep reinforcement-learning-based driving policy for autonomous road vehicles," *IET Intelligent Transport System*, 2023, vol. 14. Disponível em: <https://doi.org/10.1049/iet-its.2019.0249>.
- S. Abbasi, e A. Rahmani, "Artificial Intelligence and Software Modeling Approaches in Autonomous Vehicles for Safety Management: A Systematic Review," *Information*, v. 14, n. 10, p. 555, 2023. Disponível em: <https://doi.org/10.3390/info14100555>.
- World Health Organization, "Global status report on road safety 2023," Dez. 2023. [Online]. Disponível em: <https://www.who.int/publications/i/item/9789240086517>.
- Instituto de Pesquisa Econômica Aplicada, "Balanço da 1ª década de ação pela segurança no trânsito no Brasil e perspectivas para a 2ª década," 2023. [Online]. Disponível em: <https://repositorio.ipea.gov.br/handle/11058/12250>.
- Observatório Nacional de Segurança Viária, "Estimativa dos custos associados aos acidentes de trânsito – Projeção no período 2018-2027," 2023. [Online]. Disponível em: https://www.onsv.org.br/source/files/originals/RELATORIO_CUSTO_MORTALIDADE-809088.pdf.



S. Atakishiyev, M. Salameh, H. Yao, e R. Goebel, “Explainable Artificial Intelligence for Autonomous Driving: A Comprehensive Overview and Field Guide for Future Research Directions,” 2024.

Sociedade dos Engenheiros Automotivos (SAE International), “Norma SAE J3016: Taxonomia e Definições para Sistemas de Condução Automatizada.” [Online]. Disponível em: <https://www.sae.org/blog/sae-j3016-update>.

G. Bathla, k. Bhadane, R. Singh, R. Kumar, R. Aluvalu, R. Krishnamurthi, A. Kumar, R. N. Thakur, e S. Basheer, “Autonomous Vehicles and Intelligent Automation: Applications, Challenges, and Opportunities,” *Mobile Information Systems*, v. 2022, p. 7632892, 2022. Disponível em: <https://doi.org/10.1155/2022/7632892>.

S. Teng, X. Hu, P. Deng, B. Li, L. Ivan, Y. Ai, D. Yang, L. li, Z. Xuanyuan, F. Zhu, e L. Chen, “Motion Planning for Autonomous Driving: The State of the Art and Future Perspectives,” *IEEE Transactions on Intelligent Vehicles*, vol. 8, no. 6, pp. 3692-3711, Jun. 2023. doi: 10.1109/TIV.2023.3274536.

L. Chen, P. Wu, K. Chitta, B. Jaeger, A. Geiger, e H. Li, “End-to-end Autonomous Driving: Challenges and Frontiers,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023.

Zhang, Z. C. Lipton, M. Li, e A. J. Smola, *Dive into Deep Learning*. [Online]. Disponível em: <https://d2l.ai>.

Y. Ma, Z. Wang, H. Yang, and L. Yang, “Artificial intelligence applications in the development of autonomous vehicles: A survey,” *IEEE/CAA Journal of Automatica Sinica*, vol. 7, pp. 315-329, 2020, doi: 10.1109/JAS.2020.1003021.

R. S. Sutton, e A. G. Barto, *Reinforcement Learning: An Introduction*, 2a ed. Cambridge, MA: The MIT Press, 2018.

F. Ye, S. Zhang, P. Wang, e C. -Y. Chan, “A Survey of Deep Reinforcement Learning Algorithms for Motion Planning and Control of Autonomous Vehicles,” *2021 IEEE Intelligent Vehicles Symposium (IV)*, Nagoya, Japan, 2021, pp. 1073-1080, doi: 10.1109/IV48863.2021.9575880.

Y. Zhang, P. Sun, Y. Yin, L. Lin, e X. Wang, “Human-like Autonomous Vehicle Speed Control by Deep Reinforcement Learning with Double Q-Learning,” *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1251-1256, doi: 10.1109/IVS.2018.8500630.

H. Liu, B. Kiumarsi, Y. Kartal, A. Koru, H. Modares, e F. Lewis “Reinforcement Learning Applications in Unmanned Vehicle Control: A Comprehensive Overview,” *Unmanned Systems*, 2022. doi: 10.1142/S2301385023310027.

M.-C. Popescu, V. Balas, L. Perescu-Popescu, e N. Mastorakis, "Multilayer perceptron and neural networks," *WSEAS Transactions on Circuits and Systems*, vol. 8, 2009.

Z. Liu, Y. Wang, S. Vaidya, F. Ruele, J. Halverson, M. Soljačić, T. Y. Hou, e M. Tegmark, *KAN: Kolmogorov-Arnold Networks*, 2024. doi: 10.48550/arXiv.2404.19756.

J. Vaca-Rubio, L. Blanco, R. Pereira, e M. Caus, “Kolmogorov-Arnold Networks (KANs) for Time Series Analysis,” 2024. doi: arXiv:2405.08790.



Ó. Pérez-Gil, R. Barea, E. López-Guillén, L. M. Bergasa, C. Gómez-Huélamo, R. Gutiérrez, e A. Díaz-Díaz, “Deep reinforcement learning based control for Autonomous Vehicles in CARLA,” *Multimed Tools Applications*, vol. 81, pp. 3553–3576, 2022, doi: <https://doi.org/10.1007/s11042-021-11437-3>.

S. Aradi, “Survey of Deep Reinforcement Learning for Motion Planning of Autonomous Vehicles,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 2, pp. 740-759, Fev. 2022, doi: [10.1109/TITS.2020.3024655](https://doi.org/10.1109/TITS.2020.3024655).

J. Wu, W. Huang, N. de Boer, Y. Mo, X. He, e C. Lv, “Safe Decision-making for Lane-change of Autonomous Vehicles via Human Demonstration-aided Reinforcement Learning,” *2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*, Macau, China, 2022, pp. 1228-1233, doi: [10.1109/ITSC55140.2022.9921872](https://doi.org/10.1109/ITSC55140.2022.9921872).

G. Li, Y. Qiu, Y. Yang, Z. Li, S. Li, W. Chu, P. Green, e S. E. Li, “Lane Change Strategies for Autonomous Vehicles: A Deep Reinforcement Learning Approach Based on Transformer,” *IEEE Transactions on Intelligent Vehicles*, 2022, pp. 1-15. doi: [10.1109/TIV.2022.3227921](https://doi.org/10.1109/TIV.2022.3227921).

J. Liao, T. Liu, X. Tang, X. Mu, B. Huang, e D. Cao, “Decision-Making Strategy on Highway for Autonomous Vehicles Using Deep Reinforcement Learning,” *IEEE Access*, vol. 8, pp. 177804-177814, 2020, doi: [10.1109/ACCESS.2020.3022755](https://doi.org/10.1109/ACCESS.2020.3022755).

R. Kiran, I. Sobh, V. Talpaert, P. Mannion, A. A. Al Sallab, S. Yogamani, e P. Pérez, “Deep Reinforcement Learning for Autonomous Driving: A Survey,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 6, pp. 4909-4926, Junho 2022, doi: [10.1109/TITS.2021.3054625](https://doi.org/10.1109/TITS.2021.3054625).

GreyB, “Top 30 Self Driving Technology and Car Companies,” GreyB, 2022. [Online]. Disponível em: <https://www.greyb.com/autonomous-vehicle-companies/>.