

# 机器学习赋能的自动驾驶技术研究综述

杨潜源, 文家燕\*

广西科技大学自动化学院, 广西 柳州

收稿日期: 2026年3月13日; 录用日期: 2026年4月5日; 发布日期: 2026年4月13日

## 摘要

机器学习赋予智能体从数据中自主学习并归纳总结的能力, 从而实现对未知场景的理解。作为实现自动驾驶的关键, 该技术正引领系统设计从依赖人工规则向数据驱动模式转变, 是提升车辆智能化水平、实现高级别自动驾驶的重要方向。为了厘清机器学习在该领域的发展脉络与应用现状, 本研究以机器学习促进自动驾驶系统优化发展为主线, 重点对“从人工设计到数据驱动”与“从模块化架构到端到端模式”这两大核心技术路线进行分析, 详细介绍了机器学习在各个部分中的研究与应用现状, 总结了目前自动驾驶系统在决策可解释性、极端案例处理等方面存在的局限性, 以及介绍了以世界模型、大模型为代表的前沿技术在复杂交通环境中的优势表现。最后, 指出了未来促进自动驾驶技术进步的关键途径, 为进一步实现高阶自动驾驶提供了思路。

## 关键词

自动驾驶, 机器学习, 数据闭环, 模块化, 端到端, 车端大模型, 世界模型

# A Survey on Machine Learning for Autonomous Driving Technologies

Qianyuan Yang, Jiayan Wen\*

School of Automation, Guangxi University of Science and Technology, Liuzhou Guangxi

Received: March 13, 2026; accepted: April 5, 2026; published: April 13, 2026

## Abstract

Machine learning empowers intelligent agents to autonomously learn from data and generalize, enabling them to understand and adapt to unfamiliar scenarios. As a cornerstone of autonomous driving, this technology is catalyzing a paradigm shift in system design from reliance on human-defined

\*通讯作者。

rules to data-driven methodologies which represent a pivotal pathway toward enhancing vehicle intelligence and achieving higher levels of automation. To elucidate the evolution and current applications of machine learning in this domain, this study examines its role in optimizing autonomous driving systems. It focuses on two key technological trajectories: the transition from human-designed rules to data-driven approaches, and from modular architectures to end-to-end frameworks. The research provides a comprehensive overview of the current progress and practical applications of machine learning across core system components, summarizes existing limitations such as limited interpretability in decision-making and insufficient robustness in handling edge cases and highlights the advantages of emerging paradigms such as world models and large-scale foundation models in complex traffic environments. Finally, the study identifies critical directions for the future advancement of autonomous driving technologies and offers insights into achieving higher levels of intelligent automation.

## Keywords

Autonomous Driving, Machine Learning, Data Closed Loop, Modularization, End-to-End, Vehicle End Large Model, World Models

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

据世界卫生组织报告, 道路交通事故已成为全球 5 至 29 岁人群的主要杀手, 每年导致约 119 万人丧生[1], 是各国面临的严峻公共安全挑战。自动驾驶技术作为汽车行业未来发展的关键, 它在缓解交通拥堵、提升交通安全方面展现出极大的潜力。截至 2024 年 9 月, 全国累计开放智能网联汽车测试道路 3.2 万公里, 累计发放自动驾驶汽车测试号牌 1.6 万张, 累计测试里程超过 1.2 亿公里。在高校、车企、政策与基础设施的协同推动下, 车辆部署规模爆发式增长, 更为关键的是核心技术能力的持续突破[2]。自动驾驶系统本质上是多种技术融合的复杂系统, 其早期实现主要依赖人工预设的规则驱动模式。规则驱动的自动驾驶方法虽具备逻辑清晰、可解释性强的优点, 但在面对真实道路中高度不确定性和长尾场景时, 其泛化能力与自适应性能的局限日益凸显。近年来, 随着车载算力的大幅提升与芯片异构集成能力的增强, 以数据驱动的机器学习方法在自动驾驶系统中发挥着重要作用, 成为自动驾驶技术从实验室走向实际道路的关键推动力[3]。

为了系统地介绍机器学习对自动驾驶技术发展的影响, 本文从自动驾驶技术的发展脉络切入, 全面总结了机器学习在场景理解、决策规划与运动控制等核心环节的典型应用与关键进展, 系统梳理了模块化与端到端架构的演进过程。围绕数据驱动范式的兴起, 文章进一步探讨了算力不足、高质量数据管理及复杂场景适应等目前面临的主要挑战, 重点强调了车端大模型和世界模型在未来发展中的重要意义, 对自动驾驶系统未来智能性、可靠性与工程落地的持续发展进行了展望。

## 2. 自动驾驶的发展

1925 年, 一辆在纽约街头行驶的无线遥控汽车引起了广泛关注。这款汽车利用无线电遥控技术实现远程控制, 能够在无人驾驶的情况下正常行驶, 标志着自动驾驶技术的首次实现。1939 年, 纽约世博会上展出了全球首辆自动驾驶概念车——Futurama。这是一款通过无线电控制和电磁场引导的电动汽车, 广泛传播了自动驾驶的理念。1977 年, 日本筑波机械工程实验室在通用汽车的脉冲信号控制方案上进行

改进, 设计出可处理道路图像的摄像系统, 推出了现代意义上的首款自动驾驶乘用车。1992年, 国防科技大学成功研制出中国第一辆真正意义上的无人驾驶汽车。这是我国第一辆能够自主行驶的测试样车, 标志着中国无人驾驶行业正式起步并进入探索期, 无人驾驶的技术研发正式启动[4]。2004至2007年, 美国国防高级研究计划署举办了 DARPA 无人驾驶挑战赛, 涌现出许多创新的自动驾驶解决方案和大量相关人才[5]。2009年, 谷歌自动驾驶路测正式启动, 谷歌的自动驾驶汽车延续了不依赖摄像头视觉的传统。2015年, 特斯拉推出第一个投入商用的自动辅助驾驶系统 Autopilot, 为进一步实现完全自动驾驶技术突破进行了充分的软硬件准备[6]。2016年, 自动驾驶研发从科研主导转向企业市场主导, 众多企业加入了这一领域, 包括东风、吉利、北汽、上汽等传统汽车制造商, 以及百度、腾讯、阿里巴巴等互联网巨头和滴滴出行等出行服务公司。2019年, 上汽、宝马、滴滴成为国内首批获得智能网联汽车示范应用牌照的三家企业[7]。2024年, 一汽、上汽、广汽、长安、北汽蓝谷、比亚迪、蔚来、上汽红岩以及宇通客车成为全国首批进入 L3 自动驾驶上路通行试点的九家车企。

随着科技的不断进步和机器学习的应用, 自动驾驶系统也逐渐由人工设计向数据驱动发展。当前技术前沿正走向数据驱动为主, 规则约束为辅的混合范式。

## 2.1. 规则驱动

自动驾驶系统发展的初期, 主要依靠专家经验来处理具体的驾驶任务, 如遵守交通法规、避让障碍物、控制车辆的速度和转向等, 系统根据预设的规则来感知环境、理解道路状况, 并进行相应的动作[8]。因为规则明确且执行规范, 基于规则驱动的系统能够胜任一些结构化且预见性强的场景任务。例如, 系统能够根据红绿灯的状态进行停车或行驶, 能够根据路标来识别限速区域和禁止停车的区域, 甚至能够根据特定道路的设计来控制车辆行驶路线。

如图 1 所示, 规则驱动的自动驾驶系统通过预定义的驾驶场景与语义空间之间的映射关系, 实现由场景语义空间生成具体驾驶场景的过程。该方式依赖人工规则对环境进行语义划分与决策映射, 能够在结构化场景中稳定运行。然而, 随着自动驾驶技术的不断发展, 路况和应用环境变得愈加复杂, 规则驱动的系统逐渐暴露出其局限性。基于规则驱动的系统依赖于大量的人工标注, 更新成本较高, 缺乏自适应能力, 难以应对日益复杂的交通环境。学术界和产业界的共识认为, 突破瓶颈的关键在于设计以数据驱动为中心的自动驾驶系统。

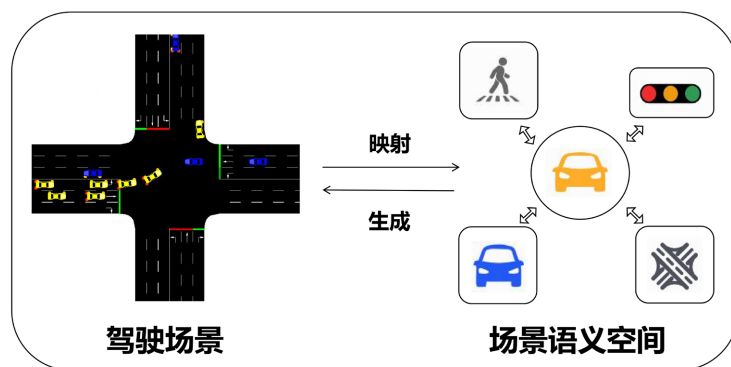


Figure 1. Rule-driven  
图 1. 规则驱动

## 2.2. 数据驱动

当前自动驾驶系统的设计不仅涉及复杂的车辆动力学原理, 还涉及到交通规则、道路状况、天气变

化、突发事件和其他交通参与者等多方面因素。规则驱动的系统无法全面覆盖这些复杂的情境，而数据驱动方法则能通过使用海量的数据，成功捕捉到这些因素之间的复杂关系，从而执行更精确的动作。数据驱动的自动驾驶系统能够基于历史驾驶数据，学习如何在复杂路况下避障、如何在突发状况中做出应急反应，甚至能够通过不断积累的行车数据优化路径规划和控制策略。如图 2 所示，数据驱动的自动驾驶系统通过机器学习模型替代部分人工规则，实现了从大规模数据中自动提取驾驶策略的能力，具备更强的泛化与自学习特性。

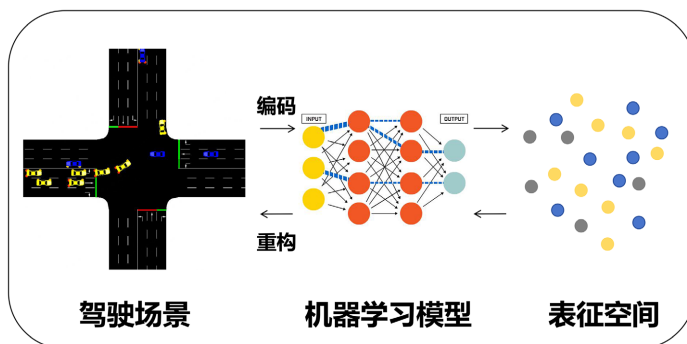


Figure 2. Data-driven  
图 2. 数据驱动

数据驱动的核心优势在于其能够通过持续的数据闭环实现系统的迭代优化。如图 3 所示，数据采集、回流、处理、标注、模型训练与仿真验证等关键环节，为自动驾驶系统提供了不断自我优化的技术基础 [9]。在数据驱动的自动驾驶框架下，系统不仅能够从人类驾驶行为中学习基础策略，更能通过与环境交互不断进化。早期的端到端强化自动驾驶系统(如 DAVE-2)已展现出从原始数据中直接学习车辆控制策略，并适应新场景的能力，其自适应性显著优于规则驱动的系统。

数据驱动的另一个重要优势在于，通过多样化、大规模的数据采集与标注，系统能够有效提升在未知场景中的泛化能力。传统方法受限于人工设计的规则，难以应对现实世界中复杂多变的长尾情况。而通过多城市联合采集的大规模驾驶数据集(如 Waymo Open Dataset、nuScenes)所训练的模型，以及通过在仿真环境中自动生成极端场景以增强模型鲁棒性的技术(如域随机化方法)，都显著提升了自动驾驶系统在面对未见过场景时的泛化性能，为其从限定测试环境走向广泛落地应用提供了关键支持。




Figure 3. Data loop closure  
图 3. 数据闭环

### 3. 自动驾驶系统的技术路线

自动驾驶系统的技术路线经历了从模块化向端到端的持续转变。传统自动驾驶系统采用模块化设计, 通过各种功能模块的有序协同, 实现了自动驾驶系统的稳定运行。随着数据规模的指数级增长和机器学习技术的持续进步, 端到端自动驾驶系统逐渐成为学术研究与产业应用的核心方向[10]。近年来, 大模型、异构计算和多任务学习等关键技术的快速发展, 进一步增强了端到端架构的泛化能力和适应性, 为自动驾驶技术的智能化发展和产业落地奠定了坚实基础。

#### 3.1. 模块化自动驾驶系统

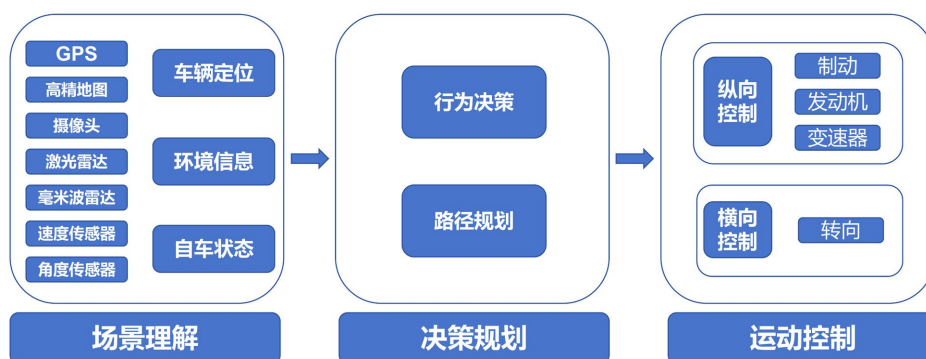


Figure 4. Modular autonomous driving system  
图 4. 模块化自动驾驶系统

如图 4 所示, 典型的自动驾驶系统通常包含场景理解、决策规划和运动控制三大功能模块。

##### 3.1.1. 场景理解

场景理解是实现自动驾驶的关键模块之一, 其任务是采集并分析自动驾驶车辆的周围环境, 实现对复杂动态场景的解读和处理。这一过程涉及对多种场景元素包括但不限于交通参与者、道路信息, 以及天气状况[11]。为了实现这一任务, 场景理解技术通常依赖于先进的传感器来捕捉周围环境的高精度数据, 并结合图像处理、机器学习算法以及高精度地图信息, 对数据进行融合、解析与理解。

早期的研究主要集中在静态环境的感知与语义分割。2015 年, Kato 等人提出了一种用于可驾驶区域检测的神经网络架构, 通过逐像素分割的方法, 旨在图像中精确识别车辆行驶的可用区域[12]。2017 年, Badrinarayanan 等人提出的 SegNet 架构, 对城市和高速公路场景中的图像进行高精度的像素级语义分割, 使车辆能够更精确地理解复杂环境[13]。随着场景的逐渐复杂, 研究重心逐渐由静态向动态场景进行转变, 场景理解逐步向生成式与交互式方向发展。2020 年, Ruben Izquierdo 等人提出了基于鸟瞰图(Bird's Eye View, BEV)渲染和 LSTM 网络的轨迹预测方法, 通过结合车辆状态信息(如速度、加速度)和卷积神经网络提取的空间信息, 预测自动驾驶车辆的未来路线, 进一步提升了场景理解的动态能力[14]。该过程可形式化表示为:

$$F_{\text{BEV}} = \Phi_{\text{BEV}} \left( \left\{ \mathcal{P}_m \left( \mathbf{E}_m \left( \mathbf{I}_m \right) \right) \right\}_{m=1}^M, \mathcal{T}_{\text{tr}} \right) \quad (1)$$

其中,  $\mathbf{I}_m$  表示来自不同传感器模态的原始观测输入,  $\mathbf{E}_m$  为对应模态的特征编码网络, 用于将高维原始感知数据映射至共享的潜在特征空间; 算子  $\mathcal{P}_m$  表示从传感器坐标系到鸟瞰坐标系的几何投影或注意力映射过程, 从而实现空间对齐。函数  $\Phi_{\text{BEV}}$  则对多模态、多视角及多时序特征进行融合与建模, 并结合历史时序信息  $\mathcal{T}_{\text{tr}}$ , 生成统一的 BEV 特征表示。

2024年, Wei等人提出了一种基于深度碰撞数据的交互式关键场景生成方法, 利用深度学习技术生成和优化极端情况下的驾驶环境, 提高了自动驾驶车辆在关键场景中的反应能力[15]。同年, Wu等人提出了HoloDrive框架, 消除从图像空间到BEV空间的投影歧义, 填补2D-3D多模态联合生成在自动驾驶中的空白[16]。

### 3.1.2. 决策规划

决策规划是自动驾驶系统的核心, 其主要功能是根据当前交通驾驶环境信息和驾驶目标, 在约束条件下自主选择驾驶行为并制定安全的驾驶策略。在执行决策规划过程中, 系统需同时考虑多种因素, 包括但不限于交通规则、道路结构、周围动态交通参与者状态等。决策规划模块的稳定性与灵活性直接决定了自动驾驶系统在多样交通环境下的安全性、可靠性以及用户体验[17]。

早期的研究主要通过强化学习或者集成学习方法实现车辆在单一场景下的行为决策与路径规划。强化学习的目标是学习到能够最大化期望累积回报的策略:

$$\begin{aligned}\pi^* &= \arg \max_{\pi} J(\pi) \\ &= \arg \max_{\pi} \mathbb{E}_{\substack{s_0 \sim d_0(s) \\ a_t \sim \pi(s_t)}} \left[ \sum_{i=0}^{+\infty} \gamma^i r(s_i, a_i) \right] \\ \text{s.t. } & s_{t+1} = f(s_t, a_t)\end{aligned}\quad (2)$$

其中, 包含四个基本元素: 状态动作对 $(s_t, a_t)$ 、策略 $\pi$ 、奖励信号 $r_t$ 和环境模型 $f$ 。 $d_0(s)$ 为 $t=0$ 时的状态分布,  $\gamma \in [0, 1]$ 为折扣系数。通过学习一个策略 $\pi$ , 使车辆在环境动态 $s_{t+1} = f(s_t, a_t)$ 约束下, 根据当前交通状态选择最优驾驶动作, 以最大化长期累计奖励, 从而实现安全、高效与舒适的决策与控制。

Ngai等于2011年利用Q-learning算法在弯曲多车道仿真环境下实现了换道超车决策[18]。2015年, Hou等采用随机森林和AdaBoost两种集成学习方法对人类驾驶专家进行模拟, 进而对变道事件进行交通状况评估和决策[19]。2016年Lillicrap等提出了DDPG算法, 在仿真平台实现了封闭道路的车道保持功能[20]。

2021年, Li等提出了一种驾驶行为预测模型, 该模型结合了梯度提升决策树、卷积神经网络和长短期记忆网络算法, 以充分挖掘驾驶行为特征, 进一步提高了驾驶行为预测模型的准确性[21]。

近年来, 研究的重心逐渐从单一场景决策转向多场景、多智能体交互的高维策略学习。2022年Duan等将DSAC算法应用于高速多车道场景, 通过引入值分布有效抑制了值函数的过估计难题, 超越了SAC的性能表现, 并进行了实车试验验证[22]。引入的值分布策略更新公式可表示为:

$$\begin{aligned}\pi_{\text{new}} &= \arg \max_{\pi} \mathbb{E}_{s, a \sim \pi} \left[ Q_{\text{new}}(s, a) - \alpha \log \pi(a|s) \right]\end{aligned}\quad (3)$$

$\mathbb{E}_{s, a \sim \pi} [\cdot]$ 是期望算子, 表示对按照策略 $\pi$ 采样得到的状态-动作对 $(s, a)$ 的平均值;  $\alpha$ 是温度参数, 用于调节奖励最大化与策略随机性之间的权衡;  $\log \pi(a|s)$ 表示策略在状态 $s$ 下选择动作 $a$ 的对数概率, 对应策略的熵正则项, 用于鼓励策略保持一定探索性。该方法通过引入值分布学习与熵正则项, 在复杂多车交互环境中抑制价值函数过估计并提升策略探索能力, 从而提高自动驾驶在多场景决策中的稳定性与鲁棒性。

2024年Wang等提出扩散在线强化学习算法DACER, 将扩散模型与在线强化学习结合, 利用其具有拟合多模态分布的能力, 从而增强策略的表达能力[23]。

### 3.1.3. 运动控制

在自动驾驶过程中需要开发多种控制策略来满足不同场景下的驾驶需求, 选择合适的运动控制策略

对于实现预期任务和确保安全运行起着关键作用。运动控制主要将生成的转向角和加速度转化为具体的执行动作[24]。通过纵向控制和横向控制确保车辆平稳行驶。常用控制方法包括 PID 控制、滑模控制、模型预测控制等[25]。为了进一步提升运动控制的适应性与安全性,现代自动驾驶系统往往还会引入自适应控制与冗余控制策略,实现对特殊工况的有效应对,从而为车辆的安全、舒适和正常行驶提供坚实保障。

随着环境多样性与训练任务复杂化程度的提升,通过将机器学习与传统控制方法相结合,以增强系统的自适应性与安全性。2022年, Li 等提出了一种基于学习的模型预测轨迹规划控制器,使用高斯过程(Gaussian Processes, GP)回归来学习残差模型不确定性,以提高模型的准确性实现了非结构化、动态环境中的避障自动驾驶[26]。其残差动力学可表示为:

$$\begin{aligned} g(z) &\sim GP(m(z), k(z, z')) \\ z &= [x, u], y = C^+(x^+ - f(x, u)) \end{aligned} \quad (4)$$

其中,  $g(z)$  为未建模动态与环境扰动引起的残差项,输入  $z = [x, u]$  由系统状态与控制量构成。通过对真实系统状态转移与名义模型预测结果之间的误差进行回归,构造监督信号  $y$ , 从而利用 GP 对残差函数进行概率建模。

同年, Yao 等人提出了一种基于深度强化学习的控制器(DCN-DDPG)生成控制命令,使车辆按照确定的路线行驶[27]。2023年, Chen 等人将量化的对象级二维场景表示集成到带有适配器的预训练 LLM 中,实现了对各种驾驶场景的直接解释和综合推理[28]。2024年, Jin 等提出了一种人工系统、计算实验和并行执行的预测控制方案。集成了模型预测控制(Model Predictive Control, MPC)控制器和物理神经网络(Physics-Informed Neural Network, PINN)模型,有效处理噪声的情况下复杂的跟踪控制任务[29]。将 MPC 的优化求解过程转化为受物理约束的连续时间神经动力系统,其一般形式可表示为:

$$E\dot{h} = -Fh - p - \zeta\Phi(Mh + \xi) + \delta \quad (5)$$

其中,矩阵  $E$ ,  $F$  以及向量  $p$  由车辆运动学模型、控制约束与软约束等物理先验信息直接构造,从而将系统动力学与优化结构显式嵌入神经网络参数中。 $Mh + \xi$  对应 MPC 二次规划问题的条件残差,  $\phi(\cdot)$  为单调奇函数形式的激活函数,用于驱动系统状态沿负梯度方向演化并保证全局收敛性; $\xi$  为收敛增益参数。向量  $\delta$  则统一表征计算误差、模型失配及外部扰动等噪声因素。该方法通过将 MPC 的优化过程转化为受车辆动力学与约束条件约束的连续时间神经动力系统,使自动驾驶车辆能够在复杂环境下快速求解满足动力学与安全约束的最优控制动作,从而实现稳定、实时的轨迹规划与控制。

## 3.2. 端到端自动驾驶系统

传统模块化的系统划分虽然使得每个模块的独立开发更加容易,但是模块间的传输容易导致信息丢失,在实际应用过程中容易出现误差累积的现象,而端到端自动驾驶则有望解决这个问题。目前端到端自动驾驶的架构可以分为四个阶段[30]。如图 5 所示:四个阶段的研究焦点依次从提高感知准确性与时序稳定性,过渡到数据驱动的决策与可行驶性,进而实现端到端的全局协同优化,最终迈向单一模型的一体化方案。

### 3.2.1. 感知端到端

感知端到端主要包括感知和决策规划两个模块。通过多传感器融合技术和 BEV 表示方法,系统能够更好地获取环境信息。近年来,考虑到 Transformer 模型的全局上下文捕获与并行计算能力,Prakash 等人通过引入 Transformer 模型及其跨注意力机制,提高了感知的准确性和鲁棒性,减少了单一传感器的误差[31]。Transformer 模型的引入奠定了感知大模型预训练算法架构的基础,通过统一特征空间和跨任务

感知训练, 增强系统对复杂交通环境的理解能力, 使感知结果更加连续、稳定, 从而使感知大模型成为自动驾驶感知的主流范式[32]。由德国慕尼黑应用科学大学智能车辆实验室提出的 BEVDriver 是基于大语言模型(LLM)的端到端自动驾驶方法。其核心思想在于让语言模型直接解读由多视角摄像头与 LiDAR 点云融合生成的 BEV 潜特征, 从而摆脱对预定义路径点或规则化中间模块的依赖。该模型通过 BEV 编码器高效提取多模态空间表示, 并在此基础上利用大语言模型执行轨迹预测与决策推理, 实现了在 CARLA 环境下的闭环自动驾驶[33]。感知端到端阶段为后续端到端自动驾驶架构的发展奠定了重要基础, 特斯拉 FSD、百度 Apollo 以及 Waymo 等早期系统均采用此类架构范式。虽然感知端到端在感知精度与系统稳定性方面取得了阶段性突破, 但这一阶段的决策规划模块仍以规则驱动为主, 限制了系统在复杂环境中的适应性和灵活性。

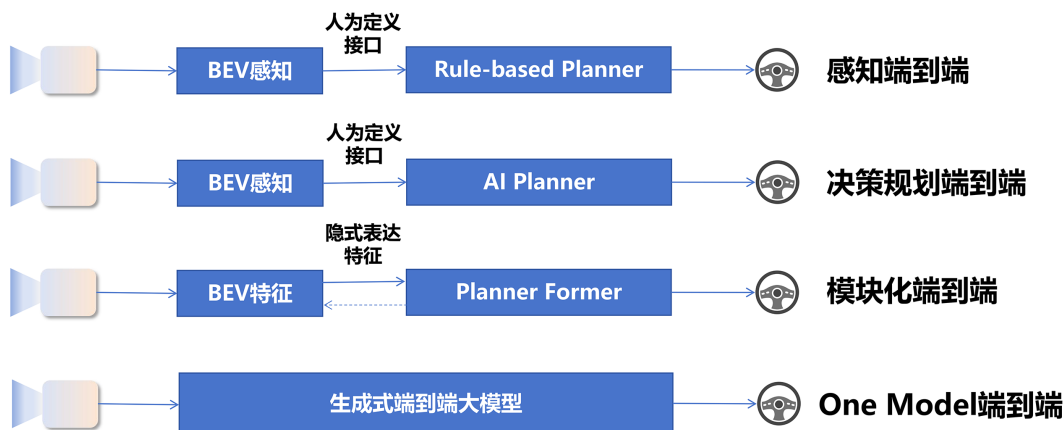


Figure 5. Evolution of end-to-end autonomous driving architecture  
图 5. 端到端自动驾驶架构演进

### 3.2.2. 决策规划端到端

决策规划端到端仍然分为感知和决策规划两个主要模块。本阶段的感知端与决策端通过人为定义的接口进行连接, 而决策规划模块通过将预测、决策和规划集成到同一个神经网络中, 实现了模块间的协同优化。虽然各模块在训练中仍有一定独立性, 但已经开始探索联合训练的机制。与感知端到端相比, 规划模块不再依赖人类设计的规则库, 而是由神经网络直接从场景中学习决策行为, 系统在处理多车交互、动态障碍物避让等复杂场景时的能力显著增强。受自然语言的启发, 将基于 Transformer 的模型应用于决策任务上, 提出面向决策任务的大模型。决策大模型的出现实现了对多源行为数据的建模优化, 能够捕捉交通参与者间复杂交互关系, 提升预测与决策在动态交通场景中的鲁棒性。2025 年, 威斯康星大学与普渡大学提出了 VLM-RL 框架, 是结合预训练视觉、语言模型与强化学习的统一框架, 该框架引入对比语言目标(Contrastive Language Goal, CLG), 通过语言描述自动生成语义奖励, 并采用分层奖励合成与批量并行训练提升复杂语义任务的学习效率。观测输入为鸟瞰图语义分割图像, 输出为一个连续的二维动作空间, 通过在 CARLA 模拟器中的大量实验表明, VLM-RL 框架在无需人工设计奖励函数的情况下, 能够学习到安全、高效的自动驾驶策略[34]。

随着模型化决策规划研究的深入, 产业界也开始将其成果应用于实际系统开发, 形成了一系列具有代表性的工程化方案。2023 年 4 月, 华为发布 HUAWEI ADS 2.0。该系统在基于 Transformer 的 BEV 感知架构上, 进一步优化了道路拓扑推理网络, 增强了道路要素建模与场景理解能力。同时, 引入拟人化决策规划大模型取代传统规则集, 在复杂城市道路中展现出更高的智能性与适应性。2024 年 5 月, 百度

Apollo 正式推出 ADFM 自动驾驶大模型, 成为全球首款支持 L4 级别自动驾驶能力的大模型架构。该模型致力于全面提升自动驾驶系统的安全水平与场景泛化能力, 集成了多模态感知大模型与多源规划大模型, 能够应对城市全域复杂驾驶场景, 实现高阶辅助驾驶功能。

### 3.2.3. 模块化端到端

与决策规划端到端相比, 模块化端到端在训练方法和模块输出上进行了优化。感知、预测与规划等功能模块在结构上仍然存在, 但不再输出可解释的中间结果, 各模块之间通过端到端梯度反向传播实现联合训练, 减少了训练过程中可能产生的误差积累, 使得整个系统更加协调一致。模块的输出由人类定义的可解释结果转变为特征向量, 避免了人工规则的局限性, 使系统能够更好地适应多变和复杂的交通场景[35]。

在学术研究方面, 2022 年, 清华大学研究团队提出了三段式端到端自动驾驶系统 iDrive, 该系统由感知模型、预测模型与决策控制模型三部分组成, 三者均基于数据驱动的神经网络进行联合训练。该架构实现了从原始感知输入到控制指令输出的全链路信息传递, 显著提升了系统在复杂交通环境中的端到端学习能力与泛化性能。2024 年, 由腾讯 T 实验室与普渡大学提出了面向真实世界地图与场景理解的大规模视觉-语言模型 MAPLM。模型的整体框架以多模态融合为核心, 整合全景 2D 图像、3D LiDAR 点云与高精地图文本, 采用“特征提取-跨模态对齐-问答生成”三级架构支撑交通场景理解与分析。通过轻量化 Adapter 高效连接大语言模型, 可以实现各类交通场景的视觉、语言问答[36]。2025 年, 由哈尔滨工业大学与百度提出了 X-Driver 大模型, 旨在实现端到端自动驾驶的可解释性; 该模型以 LLaVA-1.5-7B 为核心, 接收当前或历史图像、导航指令、场景描述与规则提示等多模态输入, 通过多模态对齐融合与思维链(Chain of Thought, CoT)分阶段推理, 将驾驶任务拆解为目标、信号、车道等子任务, 逐步形成中间语义并以自回归方式输出航点序列或控制命令; 同时引入安全与交通规则约束以提升可靠性。训练以 Bench2Drive 构建的结构化监督数据为主, 最终实现可解释的闭环控制并在复杂城市场景中表现出色[37]。

在产业实践方面, 2024 年 3 月, 商汤科技以 UniAD 为核心发布了绝影系列自动驾驶解决方案。该系统采用全栈式 Transformer 架构, 通过构建多模态自动驾驶大模型, 对来自多源传感器的数据进行深度特征提取与融合, 并依托多解码器结构实现环境语义理解与驾驶意图推理, 从而生成最优的规划路径同年 4 月, 华为发布了 ADS3.0。ADS3.0 在 ADS2.0 基础上实现了决策规划的模型化, 为端到端架构的持续演进奠定了基础。

### 3.2.4. 单一模型端到端

单一模型端到端取消了传统的感知、决策规划等模块划分, 采用单一的深度学习模型, 从原始传感器输入到最终规划轨迹的输出, 全部由同一个模型进行处理。这一架构减少了模块间信息传递的误差, 提高了系统的整体性与一致性。然而, 单一模型端到端系统对数据量、算力的需求显著增加, 并且在复杂和长尾场景中的泛化能力也面临巨大挑战。而大模型则拥有大量的参数, 能够处理包括自动驾驶在内的多种复杂任务, 使得端到端大模型成为此阶段的技术核心, 其直接进行数据输入, 加速了数据的处理, 实现了复杂场景的快速处理, 标志着端到端自动驾驶系统进入了以大模型为基础的新阶段。

在学术研究方面, 2019 年, Peng 等人提出了 D3Q (Duelling Double Deep Q-network)算法, 并基于该算法构建了端到端自动驾驶系统 D3Q-AD。该系统以相机图像与车辆运动状态为输入, 通过竞争式神经网络结构推理生成离散的前轮转角指令, 在开放赛车模拟平台 TORCS 中展现出超越人类驾驶水平的性能[38]。2025 年, 由慕尼黑工业大学与慕尼黑大学提出了“感知-对齐-交互-规划”一体化的 VLA 架构 OpenDriveVLA, 旨在将开源的 VLM 扩展为 VLA 架构, 该框架的输入为多视角图像、车辆状态与驾

驶指令, 输出为未来 T 秒的自车轨迹; 信息以 Token 的形式传递, 避免传统模块拼接带来的误差累积。在 nuScenes 基准测试中, OpenDriveVLA 达到了最先进的性能水平, 基于 Qwen2.5-VL-7B 版本的 OpenDriveVLA 实现了 0.33 米的 L2 距离和 0.10 的碰撞率[39]。同年, 由复旦大学、萨里大学与伦敦帝国理工学院提出了端到端视觉 - 语言模型 LMAD。该模型将六路环视图像输入、PI 编码器、并行 LoRA 语言解码器、感知 - 预测 - 规划三任务适配器、端到端 Token 融合与问答输出六大模块横向贯通并形成闭环; 模型融合场景理解与任务专家结构, 支持多视角图像输入, 通过 PI 机制强化跨视角信息交互, 能够无缝整合来自现有端到端驾驶系统的先验知识, 从而提升 VLMs 在自动驾驶场景中的表现[40]。

在产业实践方面, 2024 年初, 特斯拉发布了 FSD V12 系统。该系统采用端到端的生成式神经网络架构, 能够直接从原始传感器数据生成车辆控制指令, 从而显著降低系统延迟与累积误差, 全面提升了自动驾驶的响应速度与控制精度。

自动驾驶系统正经历由规则驱动向机器学习主导的转型过程, 系统智能水平不断提升。表 1 总结了各阶段自动驾驶系统的架构形式、核心技术、代表模型和优缺点, 展示了技术演进的总体趋势。

**Table 1.** Comparison of technical pathways for autonomous driving decision systems  
**表 1.** 自动驾驶决策系统技术路径对比

方法类别	架构范式	核心技术	代表模型/应用	优点	缺点
规则驱动		有限状态机 模型优化	早期 DARPA 挑战赛车辆 责任敏感安全模型	可解释性强, 确定性高	依赖于人工标注, 无法处理未知场景
模块化	场景理解	语义分割 鸟瞰图(BEV)	SegNet HoloDrive		
	决策规划	决策树 强化学习	梯度提升决策树(GBDT) 扩散在线强化学习 DACER	模块开发容易, 可解释性较好	易导致信息丢失, 容易出现误差累积
	运动控制	预测控制器	高斯过程(GP)回归 MPC + PINN 模型		
	感知端到端	感知大模型	早期 Apollo、Waymo; BEVDriver		
端到端	决策规划端到端	决策规划大模型	Apollo ADFM、VLM-RL	架构简单易训练, 部署实时性强	决策不透明, 因果混淆
	模块化端到端	模块协同优化	iDrive、MAPLM、X-Driver		
	单一模型端到端	端到端大模型/大规模预训练技术	D3Q-AD、LMAD、Open-DriveVLA		

## 4. 训练平台

自动驾驶系统早期通过真实世界评估进行验证, 但由于真实世界评估的测试周期长, 成本高, 效率低, 且覆盖的场景工况有限, 其局限性和高成本促使业界转向更具效率和低成本的数据集训练与仿真平台测试。

### 4.1. 真实世界评估

真实世界评估在自动驾驶系统验证中起着关键作用, 通过在实际道路环境中测试系统性能, 以确保

系统的可靠性与安全性。早期以 DARPA 无人驾驶挑战赛为代表, 推动了自动驾驶领域的初步技术突破。根据测试形式不同, 真实世界评估主要分为封闭场地测试与公开道路测试两种类型。

封闭场地测试通常在标准化试验场中进行, 用于验证自动驾驶系统在特定可控场景下的安全性能, 例如 AEB 紧急制动、车道保持、避障与变道等。2015 年, 美国密歇根大学 MCity 测试场投入使用, 这是全球首个专为智能网联汽车建设的城市仿真测试环境, 涵盖街区、红绿灯、隧道和虚拟行人系统, 为感知、决策与控制算法提供标准化测试条件[41]。2020 年, 北京高级别自动驾驶示范区正式启动, 示范区整合车路协同、云控平台与 5G 通信技术, 构建了“单车智能 - 车路协同”的综合测试体系。2024 年 7 月, 长三角智能网联汽车试验场即将正式运行。该试验场覆盖智能网联汽车及自动驾驶能力测试的全场景需求, 包含全球首个智能网联隧道, 可支持在无 GPS 信号及弱通信环境下的感知、决策与执行功能测试, 填补了我国在隧道工况验证领域的技术空白。

公开道路测试则在真实城市交通环境下开展, 旨在评估自动驾驶系统在复杂、多变场景中的鲁棒性与安全性。自 2015 年起, Waymo 在美国加州、亚利桑那州和德克萨斯州开展大规模无人驾驶安全测试, 并于 2020 年在菲尼克斯实现无安全员 Robotaxi 商业化运营, 累计行驶里程超过 2000 万英里, 建立了全球领先的自动驾驶安全评估体系[42]。2019 年, 百度 Apollo 推出萝卜快跑(Apollo Go)项目, 在北京、武汉、重庆、深圳等城市陆续开展道路载人测试, 并于 2021 年起在部分区域实现全无人化示范运营。截至 2025 年, Apollo Go 累计服务乘客超过 600 万人次, 成为全球规模最大、运行最稳定的城市级自动驾驶出行平台。

真实世界评估通过封闭场地与开放道路的双重验证, 为自动驾驶系统的安全性验证提供了坚实的实践基础。然而, 真实世界评估依然面临测试周期长、成本高、效率低、可覆盖场景有限等问题, 这些局限性促使业界逐步转向数据集训练与仿真平台验证的高效低成本方案。

## 4.2. 数据集

数据集是从真实驾驶场景中捕获并标记的数据集合, 这些数据集涵盖了城市道路、高速公路等不同的应用场景, 将数据集作为机器学习算法的训练素材, 使得算法能够学习如何识别和解析交通参与者和环境信息, 从而训练出能够应对复杂驾驶条件的自动驾驶模型。

从早期的视觉感知任务到近年来的多模态融合与风险预测, 自动驾驶数据集在规模、场景复杂度和任务多样性方面不断演进。早期的 KITTI 数据集由德国卡尔斯鲁厄理工学院与丰田技术研究院联合创建, 涵盖城市、乡村及高速公路等典型道路场景, 支持三维目标检测、立体视觉与光流估计任务, 是自动驾驶感知研究的奠基性数据集[43]。进入多传感器融合阶段后 nuScenes 数据集由 Motional 发布, 采集于波士顿和新加坡, 融合激光雷达、雷达与多摄像头信息, 提供全景三维标注及多任务同步数据, 为多模态感知与轨迹预测研究奠定基础[44]。BDD100K 数据集由加州大学伯克利分校发布, 包含十万段多场景视频与关键帧, 是目前规模最大、任务最丰富的开放驾驶数据集[45]。在安全导向数据集方面, DeepAccident 数据集由国内外多家研究机构联合推出, 是首个针对自动驾驶事故场景的大规模开放数据集。该数据集模拟并标注了大量真实事故与风险驾驶片段, 支持三维检测、目标跟踪、鸟瞰图(BEV)分割及运动预测任务, 为智能驾驶系统的安全评估和风险建模提供了关键支撑[46]。具体自动驾驶数据集的规模与适用任务如表 2 所示。

Table 2. Autonomous driving dataset

表 2. 自动驾驶数据集

名称	创建年份	涵盖场景	数据规模	适用任务
KITTI [43]	2013	城市、乡村道路	430 张语义分割标注	目标检测、语义分割、光流估计

续表

Cityscapes [47]	2015	50 个城市街道	5000 张精细标注图像、 2 万张粗略标注图像	像素级语义分割、 场景理解
Mapillary Vistas [48]	2017	全球城市、乡村和越野 场景	2.5 万张高分辨率图像, 66 个类别精细标注	语义分割、实例分 割、场景理解
Honda Driving [49]	2018	旧金山湾区真实驾驶场 景	104 小时真实驾驶数据	驾驶行为理解、 驾驶员行为检测
nuScenes [44]	2019	城市道路 (波士顿、新加坡)	850 个场景用于训练, 150 个场景用于测试	3D 目标检测、目 标跟踪、语义分割
Waymo Open [50]	2019	真实驾驶 场景	1200 万个激光雷达标注、 990 万个 2D 图像标注	2D/3D 目标检测、 目标跟踪、域适应
BDD100K [45]	2020	城市街道、停车场、 隧道等多种场景	10 万段高清视频	目标检测、实例分 割、车道检测
SODA10M [51]	2021	32 个城市中 多种不同的道路场景	1000 万未标记图像, 2 万张标记图像	2D 半监督/自监督 目标检测、语义/ 实例分割
ROAD [52]	2023	城市道路场景	122k 标注视频帧, 560K 个边界框	行为预测、目标检 测
DeepAccident [46]	2024	模拟真实事故场景	57K 标注帧、 285K 标注样本	运动预测、事故预 测、3D 目标检测

### 4.3. 仿真平台

仿真平台为自动驾驶系统测试提供了一个可控、安全且高效的解决方案。通过仿真平台, 使用者能够快速生成涵盖各种复杂场景的数据, 灵活配置道路类型、交通规则和车辆动态, 大幅降低运营成本和安全风险。此外, 仿真测试能够覆盖低概率但高风险的长尾事件, 提升系统对极端场景的鲁棒性和可靠性。

近年来, 仿真平台已成为自动驾驶系统验证与算法训练的重要支撑手段。主流开源仿真平台各具特点, 服务于不同层次的研究与应用。到目前为止, 常见的自动驾驶仿真平台主要有: SUMO (Simulation of Urban Mobility) 是由德国航空航天中心(DLR)自 2000 年起开发的交通流仿真平台, 支持微观与多模态交通建模, 能够精确模拟城市、乡村及高速公路等多种交通场景, 广泛用于交通规划与自动驾驶交通流交互研究。Apollo 是百度于 2017 年推出的开源自动驾驶平台, 具备完整的虚拟仿真与真实数据回放能力, 可在城市交通与自动泊车等复杂场景下进行算法验证与系统联调。Autoware 则是面向研究者与开发者的开源自动驾驶软件框架, 其仿真模块可生成多源传感器数据, 支持路径规划、车辆控制及环境建模等核心功能, 常用于算法验证与软硬件在环测试。CARLA 是学术界应用最广的自动驾驶仿真平台, 以高保真环境建模与传感器模拟著称, 支持多种天气与时间条件变化, 并允许用户自定义场景与交通要素, 成为感知、规划与控制算法验证的重要实验环境。TORCS 虽最初为赛车 AI 设计, 但凭借较高的动态仿真效率与车辆动力学真实性, 也被用于自动驾驶策略优化与控制算法研究。MetaDrive 是近年来兴起的强化学习驱动仿真平台, 通过模块化场景构建与多样化交通交互, 为策略学习与行为决策研究提供了高效的虚拟训练环境。总体而言, 仿真平台正从交通层面的宏观建模向高保真、可交互的多智能体仿真方向发展, 为自动驾驶算法的安全验证与性能评估提供了不可或缺的技术支撑。

总体而言, 仿真平台正从宏观建模向高保真、可交互的方向发展, 为自动驾驶算法的安全验证与性能评估提供了不可或缺的技术支撑, 其平台特性与对比总结如表 3 所示。

**Table 3.** Autonomous driving simulation platform

**表 3.** 自动驾驶仿真平台

名称	功能	涵盖场景	适用任务
SUMO	微观、多模态交通仿真, 精确模拟交通流动情况	城市道路、乡村、高速公路	交通流建模与模拟、交通管理优化
Apollo	支持虚拟场景构建、真实数据回放	城市交通、自动泊车、复杂驾驶场景	感知算法验证、自动驾驶系统测试与开发
Autoware	传感器模拟、路径规划与车辆控制	城市交通、实际驾驶场景	路径规划、数据生成、车辆控制
CARLA	高保真环境建模与传感器模拟, 支持多种天气、时间与复杂场景	城市交通、各种复杂交通场景	算法验证、自定义场景
TORCS	赛车仿真平台, 赛车 AI 开发与测试	赛车比赛	算法开发与驾驶策略优化

## 5. 总结与展望

机器学习在自动驾驶系统的发展和应用中发挥着重要作用。然而, 随着实际部署规模的不断扩大, 自动驾驶技术在日益复杂的场景下仍面临算力不足、数据复杂等多重挑战, 只有切实解决这些问题, 自动驾驶技术才能在复杂环境中持续演进, 向更高阶发展迈进。

### 5.1. 挑战

#### 5.1.1. 算力挑战

随着模型规模的不断扩大和训练场景的日益复杂, 模型训练对算力的需求也呈指数化增长。训练出一个可以完成决策任务的神经网络可能需要数万次甚至几十万次的迭代更新, 在这个过程中, 由于算力资源不足, 致使训练时间显著延长, 模型调优效率低下, 不利于模型的快速试验[53]。

AI 计算卡作为训练任务不可或缺的硬件部分, 一方面受到国际禁运和技术管控的影响, 导致国内各大高校及车企算力储备明显不足, 严重影响模型训练及产品化进程; 另一方面, 国产芯片开发和应用生态系统发展缓慢, 虽然国产芯片近年来取得了长足进步, 但整体与国际先进水平还存在一定差距, 尤其是在大规模训练中, 国产芯片在算力密度、能耗比及稳定性方面的不足, 使其难以胜任复杂模型的高效训练, 限制了其在工业级部署中的广泛应用。

#### 5.1.2. 数据挑战

自动驾驶系统逐步由规则驱动转变为数据驱动, 这一转变不仅代表了自动驾驶技术的提升, 更对驾驶数据提出了更高的要求。相较于规则驱动系统依赖于专家知识, 数据驱动系统则依赖神经网络从大量真实或仿真的数据中进行学习, 因此对数据量、数据质量和数据分布有更高的依赖。

模型训练往往依赖海量的数据。根据特斯拉发布的信息, 当输入超过 100 万个视频后, 基于神经网络的自动驾驶系统才开始展现出良好的性能。假设每个视频片段的时长为 30~60 秒, 粗略计算, 训练出一个端到端模型通常需要几万小时的视频数据, 而目前规模最大的公开数据集包含大约 1200 小时数据。但是要训练出一个高性能的端到端模型, 除了对数据量有极大的需求外, 对数据的质量、精度等提出了严苛标准。

自动驾驶系统的理想目标是达到与经验丰富的人类驾驶员相当的驾驶能力,能够在多变复杂的交通环境中做出安全、最优的决策。但是在现实生活中,驾驶员的驾驶水平参差不齐,导致收集到的数据无法直接用于模型训练,尤其是在端到端自动驾驶系统的训练中,模型对数据具有高度的依赖性,如果数据来自于驾驶经验不足、操作不当或反应迟缓的驾驶员,不仅会影响模型的训练效果,还可能让模型学习到具有风险性的行为[54]。这就需要一套有效的数据管理和处理流程,对原始驾驶数据进行筛选、评估和选择性提取,仅将特定场景下的高质量数据用于训练。这一过程不仅增加了数据处理的复杂度,也提升了数据获取的难度和成本。

影响数据多样性的因素难以用简单的量化指标来评估,如何科学定义并有效采集“多样化”数据,是当前面临的一大挑战。数据分布除了需要充分考虑天气状态、光照条件、道路条件和其他交通参与者行为等多维度的影响因素外,更具挑战性是如何处理那些发生频率低、但对系统性能具有重大影响的特殊情况,即“长尾问题”。这类长尾场景往往包含突发风险、边缘驾驶决策或复杂交通干扰因素,在自然驾驶数据中难以主动获得,进而影响模型对极端情况的泛化与应对能力。这一问题的有效解决,将是推动自动驾驶系统迈向高安全性与高可靠性的关键一步。

## 5.2. 未来趋势

### 5.2.1. 车端大模型

随着 ChatGPT、DeepSeek 等通用大模型在多个领域展现出强大的语言理解与推理能力,大模型范式也逐渐应用到自动驾驶系统中,成为推动智能化发展的重要方向之一。在自动驾驶领域,车端大模型指的是部署在车辆、具备多模态感知与多任务处理能力的模型系统。随着模型参数量的增加,大模型具备更强的表示能力和任务协同能力,能够在复杂交通场景中执行更精准的感知、理解与决策。自动驾驶中的大模型通常是将多个功能模块融合构建的统一模型架构。尤其在车端部署中,多个轻量模型的整合可以减少模块间通信开销、提升推理效率,并增强系统响应的实时性与稳定性。视觉-语言模型(VLM)是当前大模型体系中的关键组成,它通过融合图像与语言信息,赋予系统更强的语义理解能力。例如,车辆可以通过 VLM 识别交通标志、理解语音指令,甚至以自然语言解释当前驾驶行为和环境变化,从而提升驾驶决策的可解释性[55]。进一步发展的视觉-语言-动作模型(VLA)则在此基础上实现从多模态输入到驾驶行为控制的端到端闭环,能够直接输出转向、加速、制动等控制指令。这不仅提升了系统整体的一致性和实时性,也显著增强了其复杂环境的适应能力。

### 5.2.2. 世界模型

世界模型(World Model)的概念最早由 Ha 等人在 2018 年提出,借鉴人类通过内部模型推理外部世界的认知机制,在人工智能中构建具备预测和生成能力的模拟环境。它通过学习外部环境的动态变化规律,构建虚拟状态空间,从而使系统能够脱离真实交互,在“想象空间”中进行大规模策略优化与演化。在自动驾驶应用中,世界模型以感知数据为输入,生成可用于策略训练的未来状态,显著提高了训练速度和样本利用效率,特别是在强化学习任务中,可以减少训练对数据的依赖,实现极端场景的有效覆盖[56]。除此之外,世界模型在解决数据获取和标注问题上也表现出明显优势。通过对有限样本的建模与虚拟轨迹生成,能够在不依赖大量实车数据的前提下,完成策略预训练。特别是在极端场景上,世界模型通过环境构建,实现极端环境下的策略稳健性评估与优化,从根本上缓解了由于数据稀缺对训练带来的影响。

世界模型之所以能够做到这些,是因为它将环境建模任务转化为预测问题和轨迹生成问题,使用网络结构完成环境搭建,并通过反复模拟训练,从而形成一个无需高成本真实数据交互即可支撑训练的闭环系统。

### 5.3. 总结

机器学习对自动驾驶的发展起着重要推动作用, 其作为核心技术使自动驾驶技术的快速发展。通过对海量数据的处理和学习, 机器学习算法能够从复杂多变的交通环境中提取关键信息, 优化自动化系统的功能模块, 从而实现更高效、更安全的自动驾驶。从早期的规则驱动到当前的数据驱动, 机器学习的应用使得自动驾驶系统具备了更强的自适应能力和泛化能力, 能够更好地应对长尾问题和极端场景。在场景理解方面, 基于深度学习的图像处理、语义分割和轨迹预测等技术极大地提升了自动驾驶系统对环境的感知精度, 特别是在复杂动态场景中的表现尤为突出。在决策规划方面, 强化学习算法的引入使得车辆能够在多车交互、动态避障等复杂情境下做出更加智能和安全的决策。此外, 端到端自动驾驶系统的兴起标志着机器学习在自动驾驶中的应用进入了一个新的阶段, 通过单一模型实现从感知到控制的完整闭环, 减少了模块间的信息传递误差, 提升了系统的整体性能[35]。

总体而言, 机器学习已广泛应用于自动驾驶领域, 并持续推动该领域的技术革新与应用拓展。随着算法的持续优化、算力提升以及数据闭环系统的完善, 自动驾驶技术有望在安全性、可靠性和智能化方面实现新的突破, 最终实现高级别自动驾驶。

### 参考文献

- [1] World Health Organization (2023) Global Status Report on Road Safety 2023: Summary. World Health Organization.
- [2] 李国强, 戴一凡, 李升波, 等. 智能网联汽车(ICV)技术的发展现状及趋势[J]. 汽车安全与节能学报, 2017, 8(1): 1-14.
- [3] 李升波, 关阳, 侯廉, 等. 深度神经网络的关键技术及其在自动驾驶领域的应用[J]. 汽车安全与节能学报, 2019, 10(2): 119-145.
- [4] 陈虹, 郭露露, 边宁. 对汽车智能化进程及其关键技术的思考[J]. 科技导报, 2017, 35(11): 52-59.
- [5] Urmson, C., Baker, C., Dolan, J., Rybski, P., Salesky, B., Whittaker, W., *et al.* (2009) Autonomous Driving in Traffic: Boss and the Urban Challenge. *AI Magazine*, **30**, 17-28. <https://doi.org/10.1609/aimag.v30i2.2238>
- [6] Divakarla, K.P., Emadi, A. and Razavi, S. (2019) A Cognitive Advanced Driver Assistance Systems Architecture for Autonomous-Capable Electrified Vehicles. *IEEE Transactions on Transportation Electrification*, **5**, 48-58. <https://doi.org/10.1109/tte.2018.2870819>
- [7] 钱志鸿, 田春生, 郭银景, 等. 智能网联交通系统的关键技术与发展[J]. 电子与信息学报, 2020, 42(1): 2-19.
- [8] 李升波, 占国建, 蒋宇轩, 等. 类脑学习型自动驾驶决策系统的关键技术[J]. 汽车工程, 2023, 45(9): 1499-1515.
- [9] Li, X., Wang, Z., Huang, Y. and Chen, H. (2023) A Survey on Self-Evolving Autonomous Driving: A Perspective on Data Closed-Loop Technology. *IEEE Transactions on Intelligent Vehicles*, **8**, 4613-4631. <https://doi.org/10.1109/tiv.2023.3319689>
- [10] Chen, C., Seff, A., Kornhauser, A. and Xiao, J. (2015) DeepDriving: Learning Affordance for Direct Perception in Autonomous Driving. 2015 *IEEE International Conference on Computer Vision (ICCV)*, Santiago, 7-13 December 2015, 2722-2730. <https://doi.org/10.1109/iccv.2015.312>
- [11] Karle, P., Geisslinger, M., Betz, J. and Lienkamp, M. (2022) Scenario Understanding and Motion Prediction for Autonomous Vehicles—Review and Comparison. *IEEE Transactions on Intelligent Transportation Systems*, **23**, 16962-16982. <https://doi.org/10.1109/tits.2022.3156011>
- [12] Xue, P., Pi, D., Wang, H., Cheng, Y., Yan, Y., Sun, X., *et al.* (2025) Drivable Area Detection Method in Dark Unstructured-Roads Based on CNN Data Fusion with Surface Normal Estimation. *IEEE Transactions on Intelligent Transportation Systems*, **26**, 8694-8706. <https://doi.org/10.1109/tits.2025.3557013>
- [13] Badrinarayanan, V., Kendall, A. and Cipolla, R. (2017) SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **39**, 2481-2495. <https://doi.org/10.1109/tpami.2016.2644615>
- [14] Izquierdo, R., Quintanar, Á., Llorca, D.F., Daza, I.G., Hernández, N., Parra, I., *et al.* (2023) Vehicle Trajectory Prediction on Highways Using Bird Eye View Representations and Deep Learning. *Applied Intelligence*, **53**, 8370-8388. <https://doi.org/10.1007/s10489-022-03961-y>
- [15] Wei, Z., Huang, H., Zhang, G., Zhou, R., Luo, X., Li, S., *et al.* (2025) Interactive Critical Scenario Generation for

- Autonomous Vehicles Testing Based on In-Depth Crash Data Using Reinforcement Learning. *IEEE Transactions on Intelligent Vehicles*, **10**, 1471-1482. <https://doi.org/10.1109/tiv.2024.3415961>
- [16] Wu, Z., Ni, J., Wang, X., *et al.* (2024) HoloDrive: Holistic 2D-3D Multi-Modal Street Scene Generation for Autonomous Driving. arxiv: 2412.01407.
- [17] Schwarting, W., Alonso-Mora, J. and Rus, D. (2018) Planning and Decision-Making for Autonomous Vehicles. *Annual Review of Control, Robotics, and Autonomous Systems*, **1**, 187-210. <https://doi.org/10.1146/annurev-control-060117-105157>
- [18] Ngai, D.C.K. and Yung, N.H.C. (2011) A Multiple-Goal Reinforcement Learning Method for Complex Vehicle Overtaking Maneuvers. *IEEE Transactions on Intelligent Transportation Systems*, **12**, 509-522. <https://doi.org/10.1109/tits.2011.2106158>
- [19] Hou, Y., Edara, P. and Sun, C. (2015) Situation Assessment and Decision Making for Lane Change Assistance Using Ensemble Learning Methods. *Expert Systems with Applications*, **42**, 3875-3882. <https://doi.org/10.1016/j.eswa.2015.01.029>
- [20] Lillicrap, T.P., Hunt, J.J., Pritzel, A., *et al.* (2016) Continuous Control with Deep Reinforcement Learning. *International Conference on Learning Representations (ICLR) 2016*, San Juan, 2-4 May 2016.
- [21] 李晨. 基于组合神经网络的车辆驾驶行为预测[D]: [硕士学位论文]. 北京: 北京交通大学, 2021.
- [22] Duan, J., Zhang, F., Li, S.E., Ren, Y., Cheng, B. and Xin, Z. (2022) Applications of Distributional Soft Actor-Critic in Real-World Autonomous Driving. 2022 *2nd International Conference on Computer, Control and Robotics (ICCCR)*, Shanghai, 18-20 March 2022, 109-114. <https://doi.org/10.1109/icccr54399.2022.9790288>
- [23] Wang, Y., Tan, M., Zou, W., *et al.* (2025) Enhanced DACER Algorithm with High Diffusion Efficiency. arxiv: 2505.23426.
- [24] Klomp, M., Jonasson, M., Laine, L., Henderson, L., Regolin, E. and Schumi, S. (2019) Trends in Vehicle Motion Control for Automated Driving on Public Roads. *Vehicle System Dynamics*, **57**, 1028-1061. <https://doi.org/10.1080/00423114.2019.1610182>
- [25] Li, F., Zhang, Y., Chen, H., Stano, P., Sorniotti, A., Tian, H., *et al.* (2025) Decoupling Control Based on Neural Network Inverse System for Path Tracking in Multi-Actuated Unmanned Ground Vehicles. *Vehicle System Dynamics*. <https://doi.org/10.1080/00423114.2025.2456035>
- [26] Li, Z., Zhao, P., Jiang, C., Huang, W. and Liang, H. (2022) A Learning-Based Model Predictive Trajectory Planning Controller for Automated Driving in Unstructured Dynamic Environments. *IEEE Transactions on Vehicular Technology*, **71**, 5944-5959. <https://doi.org/10.1109/tvt.2022.3159994>
- [27] Yao, J. and Ge, Z. (2022) Path-Tracking Control Strategy of Unmanned Vehicle Based on DDPG Algorithm. *Sensors*, **22**, Article 7881. <https://doi.org/10.3390/s22207881>
- [28] Chen, L., Sinavski, O., Hünermann, J., Karnsund, A., Willmott, A.J., Birch, D., *et al.* (2024) Driving with LLMs: Fusing Object-Level Vector Modality for Explainable Autonomous Driving. 2024 *IEEE International Conference on Robotics and Automation (ICRA)*, Yokohama, 13-17 May 2024, 14093-14100. <https://doi.org/10.1109/icra57147.2024.10611018>
- [29] Jin, L., Liu, L., Wang, X., Shang, M. and Wang, F. (2024) Physical-Informed Neural Network for Mpc-Based Trajectory Tracking of Vehicles with Noise Considered. *IEEE Transactions on Intelligent Vehicles*, **9**, 4493-4503. <https://doi.org/10.1109/tiv.2024.3358229>
- [30] 辰韬资本, 南京大学上海校友会自动驾驶分会, 九章智驾, 宝通科技. 端到端自动驾驶行业研究报告[R]. 上海, 2024.
- [31] Prakash, A., Chitta, K. and Geiger, A. (2021) Multi-Modal Fusion Transformer for End-To-End Autonomous Driving. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 20-25 June 2021, 7073-7083. <https://doi.org/10.1109/cvpr46437.2021.00700>
- [32] Wang, X., Li, K. and Chehri, A. (2024) Multi-sensor Fusion Technology for 3D Object Detection in Autonomous Driving: A Review. *IEEE Transactions on Intelligent Transportation Systems*, **25**, 1148-1165. <https://doi.org/10.1109/tits.2023.3317372>
- [33] Winter, K., Azer, M. and Flohr, F.B. (2025) BEVDriver: Leveraging BEV Maps in LLMs for Robust Closed-Loop Driving. 2025 *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Hangzhou, 19-25 October 2025, 20379-20385. <https://doi.org/10.1109/iros60139.2025.11247237>
- [34] Huang, Z., Sheng, Z., Qu, Y., You, J. and Chen, S. (2025) VLM-RL: A Unified Vision Language Models and Reinforcement Learning Framework for Safe Autonomous Driving. *Transportation Research Part C: Emerging Technologies*, **180**, Article ID: 105321. <https://doi.org/10.1016/j.trc.2025.105321>
- [35] Yu, Z., Li, J., Chen, Z., Wei, Y., Zhang, X. and Tan, X. (2025) Multimodal End-To-End Autonomous Driving via Bilateral Modality Interaction. *Expert Systems with Applications*, **293**, Article ID: 128458.

- <https://doi.org/10.1016/j.eswa.2025.128458>
- [36] Cao, X., Zhou, T., Ma, Y., Ye, W., Cui, C., Tang, K., *et al.* (2024) MAPLM: A Real-World Large-Scale Vision-Language Benchmark for Map and Traffic Scene Understanding. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 16-22 June 2024, 21819-21830. <https://doi.org/10.1109/cvpr52733.2024.02061>
- [37] Liu, W., Zhang, J., Zheng, B., *et al.* (2025) X-Driver: Explainable Autonomous Driving with Vision-Language Models. arxiv: 2505.05098.
- [38] Peng, B., Sun, Q., Li, S.E., Kum, D., Yin, Y., Wei, J., *et al.* (2021) End-To-End Autonomous Driving through Dueling Double Deep Q-network. *Automotive Innovation*, **4**, 328-337. <https://doi.org/10.1007/s42154-021-00151-3>
- [39] Zhou, X., Han, X., Yang, F., *et al.* (2025) Opendrivelva: Towards End-To-End Autonomous Driving with Large Vision Language Action Model. arxiv: 2503.23463.
- [40] Song, N., Zhang, B., Zhu, X., *et al.* (2025) LMAD: Integrated End-to-End Vision-Language Model for Explainable Autonomous Driving. arxiv: 2508.12404.
- [41] Dong, Y., Zhong, Y., Yu, W., *et al.* (2019) Mcity Data Collection for Automated Vehicles Study. arxiv: 1912.06258.
- [42] Di Lillo, L., Gode, T., Zhou, X., Atzei, M., Chen, R. and Victor, T. (2024) Comparative Safety Performance of Autonomous- and Human Drivers: A Real-World Case Study of the Waymo Driver. *Heliyon*, **10**, e34379. <https://doi.org/10.1016/j.heliyon.2024.e34379>
- [43] Geiger, A., Lenz, P., Stiller, C., *et al.* (2013) Vision meets robotics: The KITTI Dataset. *The International Journal of Robotics Research*, **32**, 1231-1237.
- [44] Caesar, H., Bankiti, V., Lang, A.H., Vora, S., Liong, V.E., Xu, Q., *et al.* (2020) nuScenes: A Multimodal Dataset for Autonomous Driving. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 13-19 June 2020, 11618-11628. <https://doi.org/10.1109/cvpr42600.2020.01164>
- [45] Yu, F., Chen, H., Wang, X., Xian, W., Chen, Y., Liu, F., *et al.* (2020) BDD100K: A Diverse Driving Dataset for Heterogeneous Multitask Learning. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 3-19 June 2020, 2633-2642. <https://doi.org/10.1109/cvpr42600.2020.00271>
- [46] Wang, T., Kim, S., Wenxuan, J., Xie, E., Ge, C., Chen, J., *et al.* (2024) DeepAccident: A Motion and Accident Prediction Benchmark for V2X Autonomous Driving. *Proceedings of the AAAI Conference on Artificial Intelligence*, **38**, 5599-5606. <https://doi.org/10.1609/aaai.v38i6.28370>
- [47] Cordts, M., Omran, M., Ramos, S., Rehfeld, T., Enzweiler, M., Benenson, R., *et al.* (2016) The Cityscapes Dataset for Semantic Urban Scene Understanding. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 3213-3223. <https://doi.org/10.1109/cvpr.2016.350>
- [48] Neuhold, G., Ollmann, T., Bulo, S.R. and Kotschieder, P. (2017) The Mapillary Vistas Dataset for Semantic Understanding of Street Scenes. 2017 *IEEE International Conference on Computer Vision (ICCV)*, Venice, 22-29 October 2017, 5000-5009. <https://doi.org/10.1109/iccv.2017.534>
- [49] Ramanishka, V., Chen, Y., Misu, T. and Saenko, K. (2018) Toward Driving Scene Understanding: A Dataset for Learning Driver Behavior and Causal Reasoning. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 7699-7707. <https://doi.org/10.1109/cvpr.2018.00803>
- [50] Sun, P., Kretschmar, H., Dotiwalla, X., Chouard, A., Patnaik, V., Tsui, P., *et al.* (2020) Scalability in Perception for Autonomous Driving: Waymo Open Dataset. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 13-19 June 2020, 2443-2451. <https://doi.org/10.1109/cvpr42600.2020.00252>
- [51] Han, J., Liang, X., Xu, H., *et al.* (2021) Soda10m: A Large-Scale 2D Self/Semi-Supervised Object Detection Dataset for Autonomous Driving. arxiv: 2106.11118.
- [52] Singh, G., Akrigg, S., Maio, M.D., Fontana, V., Alitappeh, R.J., Khan, S., *et al.* (2023) ROAD: The Road Event Awareness Dataset for Autonomous Driving. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **45**, 1036-1054. <https://doi.org/10.1109/tpami.2022.3150906>
- [53] Yang, H., Pan, L. and Liu, S. (2025) An RL-Based Cost-Effective Two-Layer Scaling Strategy for Multiregional Heterogeneous and Time-Varying Cloud Instances. *IEEE Internet of Things Journal*, **12**, 10709-10721. <https://doi.org/10.1109/jiot.2024.3513958>
- [54] Xie, S., Chen, S., Zheng, J., Tomizuka, M., Zheng, N. and Wang, J. (2022) From Human Driving to Automated Driving: What Do We Know about Drivers? *IEEE Transactions on Intelligent Transportation Systems*, **23**, 6189-6205. <https://doi.org/10.1109/tits.2021.3084149>
- [55] Zeng, Y., Zhang, X., Li, H., Wang, J., Zhang, J. and Zhou, W. (2024) X2-VLM: All-In-One Pre-Trained Model for Vision-Language Tasks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **46**, 3156-3168. <https://doi.org/10.1109/tpami.2023.3339661>
- [56] Qu, Y., Huang, Z., Sheng, Z., *et al.* (2025) VL-SAFE: Vision-Language Guided Safety-Aware Reinforcement Learning with World Models for Autonomous Driving. arxiv: 2505.16377.