

中国学术期刊网络出版总库 (CNKI) 收录

万方数据—数字化期刊群收录

超星数字期刊数据库收录

维普网数据库收录

ISSN 2096-5915

CN 10-1565/TJ



无人系统技术

UNMANNED SYSTEMS TECHNOLOGY

主管：中国航天科工集团有限公司 主办：北京海鹰科技情报研究所

ISSN 2096-5915



2021.6
第4卷 NO.



无人系统技术

WUREN XITONG JISHU

第 4 卷第 6 期
2021 年 11 月

目 次 CONTENTS

· 系统综述 · Systematic Review

- 深度学习在自动驾驶领域应用综述 段续庭, 周宇康, 田大新, 等 (01)
A Review of Deep Learning Applications for Autonomous Driving DUAN Xuting, et al (01)
无人作战系统仿真发展综述 常晓飞, 蒋邓怀, 姬晓闯, 等 (28)
Summary of Simulation Development of Unmanned Combat System CHANG Xiaofei, et al (28)

· 路径规划 · Path Planning

- 基于遗传算法与 Dubins 理论的高速无人系统在多障碍环境中的路径规划 李 艳, 郭继峰, 罗汝斌 (37)
Path Planning of High-speed Unmanned System in Multi-obstacle Environment Based on Genetic Algorithm and Dubins Theory LI Yan, et al (37)
基于模型预测控制的无人车辆轨迹跟踪控制 李 畅, 张 佳, 孙中奇, 等 (46)
Trajectory Tracking Control of Unmanned Vehicle based on Model Predictive Control LI Chang, et al (46)
基于全局 SLAM 的四足机器人路径规划研究 刘宇飞, 江 磊, 邢伯阳, 等 (57)
Research on Path Planning of Quadruped Robot Based on Globally SLAM LIU Yufei, et al (57)

· 其他 · Others

- 超声速导弹群协同博弈突防制导研究 陈洁卿, 孙瑞胜, 陈 伟 (65)
Research on Cooperative Penetration Game Guidance of Supersonic Missile Group CHEN Jieqing, et al (65)
一种火星多任务探测器系统概念设计 刘华伟, 田百义, 呼延奇, 等 (75)
Conceptual Design of A Probe System for the Mars Multitask Exploration LIU Huawei, et al (75)
中国航天科工集团有限公司科技期刊联合征订启事 (82)

[引用格式] 段续庭, 周宇康, 田大新, 等. 深度学习在自动驾驶领域应用综述[J]. 无人系统技术, 2021, 4(6): 1-27.

深度学习在自动驾驶领域应用综述

段续庭^{1,2}, 周宇康^{1,2}, 田大新^{1,2}, 郑坤贤^{1,2}, 周建山^{1,2}, 孙亚夫³

(1. 北京航空航天大学交通科学与工程学院车路协同与安全控制北京市重点实验室, 北京 102206;
2. 综合交通大数据应用技术国家工程实验室, 北京 100191; 3. 北京千方科技股份有限公司, 北京 100085)

摘要:成熟的自动驾驶技术能够极大降低交通事故率, 保障驾驶人员与行人的安全, 优化交通流运行, 但早期的自动驾驶系统可靠性与智能性都很低, 不能满足实际应用需求。近年来, 深度学习技术迅速发展, 并与自动驾驶领域结合, 其在机器视觉、自然语言处理等领域的成功应用使得自动驾驶越来越接近现实。介绍了目前自动驾驶系统的主流技术框架, 并对其各模块中深度学习技术的应用情况进行系统梳理, 将自动驾驶系统分为分解式和端到端式两种技术方案, 并将分解式方案进一步分为感知、决策、控制 3 大模块, 分别对以上两类解决方案中深度学习技术应用的历史沿革、研究现状以及典型算法性能进行综合评述。已有的研究成果表明, 分解式方案的技术路径较为成熟, 感知、决策、控制 3 个功能模块分工清晰, 可解释性强, 但系统复杂度高, 计算量大, 软件架构庞大, 硬件要求高, 应进一步简化各问题的算法, 加强各个算法模块间的功能整合, 降低系统复杂度与硬件要求; 端到端式方案计算量小, 硬件要求低, 且系统复杂度低, 但对算法要求高, 安全性低, 可解释性、可靠性差, 建议未来通过完善智能道路基础设施, 推进 5G 传输的应用, 加强车路、车云协同, 进一步完善现有算法来解决以上问题。

关键词:深度学习; 自动驾驶; 目标检测; 路径规划; 端到端学习; 感知; 决策; 控制
中图分类号: U471.15 **文献标识码:** A **文章编号:** 2096-5915(2021)06-01-27
DOI: 10.19942/j.issn.2096-5915.2021.6.051

A Review of Deep Learning Applications for Autonomous Driving

DUAN Xuting^{1,2}, ZHOU Yukang^{1,2}, TIAN Daxin^{1,2}, ZHENG Kunxian^{1,2}, ZHOU Jianshan^{1,2}, Sun Yafu³

(1. Beijing Key Laboratory for Cooperative Vehicle Infrastructure Systems and Safety Control, School of Transportation Science and Engineering, Beihang University, Beijing 102206, China; 2. National Engineering Laboratory for Comprehensive Transportation Big Data Application Technology (NEL-CTBD), Beijing 100191, China; 3. China TRANSINFO, Beijing 100085, China)

Abstract: The rate of traffic accidents can be reduced by mature autonomous driving technology. The technology can guarantee the safety of drivers and pedestrians, and also optimize the operation of traffic flow. However, the reliability and intelligence of early autonomous driving systems were inadequate, which could not meet practical requirements. In recent years, thanks to the rapid development of the deep learning technology, the autonomous driving technology is much closer to reality with its successful applications in Machine Vision, Nature Language Processing and other fields. This article introduces some dominant technical frameworks in autonomous driving systems, and conduct a systematic analysis in the application of different modules of deep learning technology. The autonomous driving system can be divided into two technical plans, decomposition plan and end-to-end plan. The decomposition plan can be divided further into three modules, perception, decision-making, and control. The article conducts a comprehensive assessment of the

收稿日期: 2021-07-02; 修回日期: 2021-08-20

基金项目: 国家自然科学基金资助项目 (62173012; U20A20155; 61822101); 北京市自然科学基金资助项目 (L191001); 国家自然科学基金中英才计划 (62061130221)

evolution histories, contemporary researches and performance of typical deep learning algorithm in autonomous driving systems. Existing research results show that the technique of decomposition plan is relatively more mature, with a clearer distinguishment of functions among three modules, as well as a better interpretability. However, the decomposition system is complex and requires high computing capability large software structure and cutting-edge hardware. The algorithm should be simplified, the integration of functions between each algorithm module should be enhanced, and the complexity and hardware requirements should be decreased. On the other hand, the end-to-end plan has a smaller computing ability requirements and does not require much on hardware, while it requires a better algorithm and the safety level, interpretability and reliability is rather low. The problems above are suggested to be solved by implementing intelligent road infrastructure, the applications of 5G transmission technology, the strengthened co-operation between vehicle-road and vehicle-cloud, as well as the improvement of contemporary algorithm.

Key words: Deep Learning; Autonomous Driving; Target Detection; Path Planning; End-to-end Learning; Perception; Decision-making; Control

1 引言

近年来,自动驾驶技术从概念设计阶段向实际应用阶段快速迈进。也有越来越多的企业和研究人员进入自动驾驶赛道,投身到自动驾驶领域的研究中来。

自动驾驶已有数十年的历史,但自动驾驶行业最初并未受到广泛关注。20世纪80年代,无人车 Naclab-1 完成了无人驾驶行驶试验,该型号无人车由美国卡耐基梅隆大学在雪佛兰厢式货车的基础上研制。这之后许多为无人车开放道路实验的法律法规相继出台。后续数年中对自动驾驶的研究逐渐流行开来,2009年,自动驾驶汽车的雏形图片被曝光,自动驾驶开始受到广泛关注。鉴于计算机工作的高稳定性与合逻辑性,可以预见自动驾驶技术一旦能够付诸应用,将极大减少目前因驾驶员因素造成的交通事故量,与之配套的车辆与基础设施互联技术也将通过车云交互极大减轻交通拥堵。为此,各个工业强国纷纷出台政策,为自动驾驶的发展提供便利。我国于2015年发布《中国制造2025》^[1],强调智能制造、高端制造对产业升级的意义。2019年,我国发布《汽车产业中长期发展规划》^[2],明确提出我国产业转型升级的一个重要方向是智能网联汽车。在人工智能方面,美国于2016年发布《国家人工智能研究与发展战略规划》,表明美国将持续对人工智能领域投资。2017年,国务院发布《新一代人工

智能发展规划》^[3],提出我国人工智能发展的战略目标与总体部署。2018年,科技部启动“新一代人工智能”重大项目申报^[4],进一步推动了人工智能产学研结合、与传统行业融合的趋势。

自动驾驶技术包括环境感知、行为决策与控制执行3个主要模块。感知系统对多种类型传感器所感知的数据进行处理,通过多种定位设备与高精度地图实现精准定位,并利用高精度地图获取路径与交通信号灯等固定信息,最终综合种种信息实现对当下行驶场景的场景理解。决策系统负责路线规划和行车动作决策,根据感知模块所传输的场景信息做出规则允许下实现乘客收益最大化的决策,除了车辆自身的软硬件系统外,以上功能的实现往往还需要车联网技术的支持。控制系统多与汽车底盘相关,负责执行决策模块做出的运动指令,控制车辆加减速、转向或刹车等。

自动驾驶技术的推广面临着许多问题,如感知系统中,为数众多的传感器会产生大量不同类型的数据交由主控电脑识别整理,去芜存菁;决策系统中,汽车在行进过程中的每个多样化情境都需要做出合理决策,既要高效快速,又要保证安全,对于决策问题,现行的解决方案包括基于规则的方法(如有限状态机法)和基于学习的方法(深度学习方法及决策树等机器学习方法)。有限状态机法的优点是逻辑清晰、实用性强,但在驾驶场景较复杂时,有限状态机的状态划分将变得繁琐,状态转移条件也将变得更加复杂。近年

来, 随着深度学习方法在决策支持、图像处理等领域大放异彩, 自动驾驶各模块中也越来越多地应用了深度学习算法。目前, 已有一些工作对无人驾驶场景深度学习的应用进行总结与阐述, 张新钰等^[5]对基于深度学习的自动驾驶领域目标检测与识别、任务辅助等技术的研究现状进行了介绍, 王玉龙等^[6]对自动驾驶决策系统的拟人化决策算法进行了综述, 这也是深度学习在决策系统应用的一个重要分支。Grigorescu 等^[7]综述了深度学习在自动驾驶中的应用现状, 并重点论述了自动驾驶系统面临的信息安全问题。此外, Fayyad 等^[8]针对自动驾驶感知与定位中的传感器融合问题, 介绍了当前自动驾驶领域使用深度学习融合算法进行感知和定位的研究现状。Ni 等^[9]介绍了自动驾驶汽车的发展历程, 并综述了深度学习方法在自动驾驶所面临的几项主要问题中的应用, 如障碍物检测、场景理解、车道检测与路径规划等。Gwak 等^[10]对自动驾驶软件模块中包含的车道跟踪、图像识别、激光雷达检测等算法进行了综述, 并重点介绍了其中的深度学习方法。然而现有的文献综述或只针对自动驾驶的单个功能模块进行介绍, 而不涉及其他模块或全局性能的讨论, 或仅基于问题进行综述, 论述深度学习算法在自动驾驶所面临的几项典型问题中的应用, 既不够全面也不够系统(并且往往不包含决策问题)。本文从自动驾驶的技术路径出发, 以自动驾驶的感知、决策、控制3大模块及端到端式解决方案作为章节划分的依据, 在每一模块下介绍自动驾驶汽车所需要解决的问题及深度学习算法在其中的应用, 并进一步探讨了两类自动驾驶全局解决方案——端到端式和分解式解决方案的优劣。

2 深度学习算法

深度学习是机器学习领域中的一项子内容。依靠深层结构和强大的特征学习机制, 深度学习系列算法不仅在计算机科学方面表现出色, 还极大地促进了其他科学领域的研究^[11]。在自动驾驶领域, 深度学习广泛用于解决感知、决策、控制

算法中面临的难题, 以提高自动驾驶系统的智能化水平。

机器学习作为实现人工智能的一种方式, 其对人类神经网络的深入研究和模拟催生了人工神经网络。人工神经网络能够进行简单的特征学习, 学到给定任务数据集上的特征, 寻找到任务数据的内在结构, 输出解决方案。然而, 传统浅层神经网络由于参数和超参数较少, 对复杂任务的学习能力有限, 难以满足任务需求。后来研究人员发现, 增加网络深度可以提升神经网络对复杂数据的表征能力, 提高准确性, 但是因为易过拟合, 训练速度慢, 且层次较少(<4)时并不比其他方法更优等原因而不受重视。2006年, Hinton 等^[12]在实践中采用逐层调整和微调的方法成功训练了深度学习网络, 证明深度学习模型是可以训练的。此外, 其他研究人员也提出 ReLU 和 dropout 等方案来解决其过拟合的问题, 提升了模型的泛化能力, 深度学习的学习机制得以进一步完善。

深度学习通过多层的前馈或者循环网络结构, 实现多层网络中大量的参数学习, 最终实现对所需要的输入-输出间复杂映射的逼近^[13]。此外, 深度学习能够有效地从低级原始数据中学得低级特征, 存储在网络前部的结构中, 并通过不同的后部结构完成特征提取、分类、结果输出等任务。深度学习与传统神经网络之间的区别在于其深层性与层间连接的多样性。传统神经网络层数一般在3层左右, 层间一般采用全连接方式, 而深层神经网络可达上千层。连接方式包括全连接、延时连接与随机连接等。含1个隐藏层的深度学习模型如图1所示。

深度学习常用的方法包括卷积神经网络(Convolutional Neural Networks, CNN)、循环神经网络(Recurrent Neural Networks, RNN)和深度置信网络(Deep Belief Nets, DBN)等。其中, 卷积神经网络的应用最为广泛。

2.1 卷积神经网络

卷积神经网络是人工神经网络的一个分支, 也是应用最广泛的一类人工神经网络。它通常由一层输入层, 多于一层的隐藏层(包含卷积层与

池化层) 以及一层全连接层和一层输出层组成, 基本结构如图 2 所示^[9]。




图 1 含 1 个隐藏层的深度学习模型

Fig. 1 A deep learning model with one hidden layer

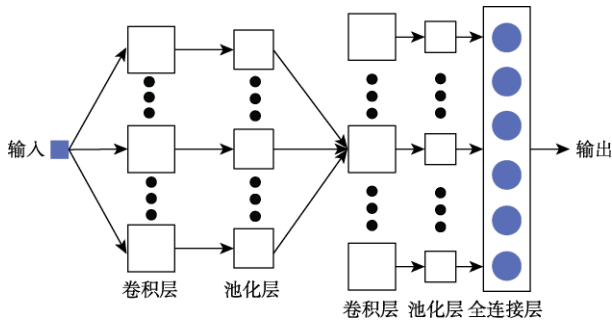


图 2 CNN 的基本结构^[9]

Fig. 2 Basic structure of CNN^[9]

卷积层是 CNN 的核心组成部分。卷积核与输入图像的局部区域卷积。即^[9]

$$y_j = \sum w_{ij} * x + b_j \quad (1)$$

式中, 运算符*为二维离散卷积运算; w 为滤波器矩阵, b 为偏置参数; x 为输入要素图, y 为要素图的输出。卷积核通常被初始化为 3×3 或 5×5 的小矩阵。在网络的训练过程中, 卷积核将通过学习不断更新, 并最终获得合理的权重。激活函数运行时激活神经网络中某一部分神经元, 激活函数在神经网络中加入了非线性因素, 使得神经网络能够在解决非线性问题时获得满意的输出。

主要的激活函数有以下几种^[9]:

$$\text{Sigmoid: } R = \frac{1}{1 + e^{-y}}$$

$$\text{Tanh: } R = \frac{e^y - e^{-y}}{e^y + e^{-y}} \quad (2)$$

$$\text{ReLU: } R = \max(0, y)$$

卷积神经网络采用权值共享机制, 大大降低了网络参数数量和计算量, 同时采取网络局部连接机制限制隐藏层节点数。这在输入与要求输出间为复杂映射关系时尤其有效, 极大地提高了计算效率。卷积神经网络广泛应用于图像处理等领域。

2.2 循环神经网络

有关神经网络的研究起源于 20 世纪 80 年代, 并在 21 世纪初发展为深度学习的典型算法之一。典型的循环神经网络包括双向循环神经网络 (Bidirectional RNN, Bi-RNN) 和长短期记忆网络 (Long Short-Term Memory Networks, LSTM)。RNN 的基本结构如图 3 所示。图中 X 、 S 、 O 都是向量, 分别表示输入层、隐藏层和输出层的值; U 是输入层到隐藏层的权重矩阵, V 是隐藏层到输出层的权重矩阵。循环神经网络的隐藏层的值 S_t 不仅仅取决于当前输入 X , 还取决于上一次输入时隐藏层的值 S_{t-1} 。权重矩阵 W 就是上一次隐藏层的值作为此次输入时的权重。




图 3 RNN 的基本结构^[14]

Fig. 3 Basic structure of RNN

RNN 的一般公式表示如下:

$$\begin{aligned} S_t &= f(U \cdot X + W \cdot S_{t-1} + b) \\ O_t &= g(V \cdot S_t + c) \end{aligned} \quad (3)$$

CNN 的状态仅依赖于当前输入, 与前后输入无关, 而 RNN 的状态还与网络上一时刻的状态有关, 因而可以处理前后输入相关的问题, RNN

被广泛应用于自然语言处理领域,例如语音识别、语言建模、机器翻译等问题中。

2.3 生成对抗网络

Goodfellow 等^[15]在 2014 年提出了生成对抗网络 (Generative Adversarial Networks, GAN) 的概念, GAN 使用无监督学习方式, 同时训练生成

模型和判别模型。生成模型的目的是产生尽可能消除生成样本与真实样本的差别, 判别模型的目的是将生成样本与真实样本区分开, 生成网络一般包含逆卷积层, 而判别网络一般是 CNN。GAN 就是通过两个模块的不断博弈产生需要的结果。GAN 的基本结构如图 4 所示。




图 4 GAN 的基本结构^[15]
Fig. 4 Basic structure of GAN

生成模型是用于产生指定分布数据的模型, 生成模型将对网络输入数据的特征通过极大似然估计转化为指定的生成样本。

目前, GAN 主要应用于图像生成领域, 如创建超分辨率图像、语义分割、文本到图像转换和人脸合成、图像修复等。

2.4 深度强化学习

强化学习的特点是在“试错”中学习, 即在与外部环境的互动中根据当前行动获得的奖励不断调整行动策略。强化学习不需要对训练集进行标注, 侧重在线学习, 因此多用于解决无法严格标注“对错”的问题, 如自动驾驶汽车的决策问题。机器学习、深度学习、强化学习、监督学习与深度学习之间的关系如图 5 所示。

强化学习框架如图 6 所示, 标准的强化学习智能体框架由 3 个模块组成: 输入模块 I 、强化模块 R 和策略模块 P , 输入模块读取外部输入, 强化模块确定智能体所要达到的目标, 一般是使其获得的最终奖励最大, 策略模块根据当前状态与强化目标选择智能体所要采取的动作。

强化学习的策略 (Policy, P) 是智能体在给定的状态 S 下, 对所要做出的动作的选择, 定义为




图 5 各种机器学习方式与深度学习的关系^[16]
Fig. 5 Relationships among deep learning and several machine learning methods

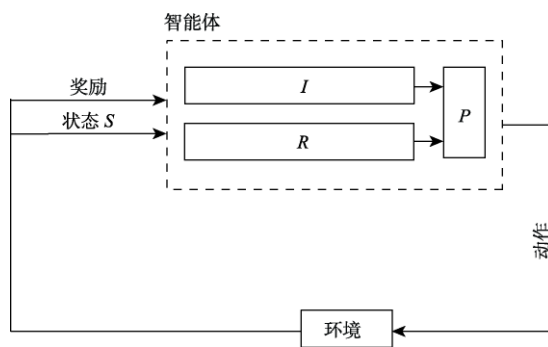


图 6 强化学习框架
Fig. 6 Framework of reinforcement learning

π 。奖励是每次智能体与环境进行交互后环境给予的反馈，智能体的目标是使整个行动过程中的累计奖励最大。价值函数指一个状态在给定的策略 π 下长期期望奖励的高低。环境是对真实世界的模拟。

强化学习具有解决决策问题的能力，但学习复杂特征的能力较弱；而深度学习模型广泛应用于感知领域，能够学习复杂的抽象特征，但缺乏解决决策问题的能力。因此，结合两者优势的深度强化学习为复杂系统的决策问题提供了解决办法^[17]。深度强化学习引入神经网络来解决强化学习的容量限制的问题，如将卷积神经网络与强化学习结合，典型例子是深度 Q 网络（Deep Q Network, DQN）利用深度神经网络来映射动作和状态的关系；或将循环神经网络与强化学习相结合，典型例子是深度递归 Q 网络（Deep Recurrent Q Network, DRQN）。DQN 使用 CNN 作为函数近似器，权重 θ 作为 Q 网络，如下所示：

$$Q^*(s_t, a_t, \theta_t) = E[r(s_t, a_t) + \gamma \max_{a_{t+1}} Q(s_{t+1}, a_{t+1}; \theta_{t+1}) | s_t, a_t]_{a_{t+1}} \quad (4)$$

2.5 深度学习与自动驾驶技术

深度学习具有传统算法所不具有的种种优势，近年来被广泛应用于自动驾驶技术中。深度学习应用的核心目标就是让智能车辆能够像人一样从已有的道路交通资料及规章中学习驾驶技术，最终达到能够独立安全处理车辆行驶过程中所面临的各类问题的层次。自动驾驶按技术流程

可被分为分解式和端到端式两种解决方案，分解式解决方案包括感知、决策、控制 3 个主要模块，是一个 3 个功能模块互相联系、分工协作的综合系统。感知模块接收车载传感器和 V2X 通信获得的环境信息并对其进行处理，包括图像、点云识别与高精度定位等，最终实现对车辆行驶环境的场景理解。决策模块接收感知模块传来的环境信息，结合乘客乘车需求（如时间最短等），规划车辆行驶路径，并进行行驶过程中的行为决策。控制模块则接收决策模块传来的控制指令，实现对车辆的运动控制。而端到端式方案则多使用深度学习技术由所输入的传感器数据直接输出控制指令。两种解决方案的一般技术路径如图 7 所示。自动驾驶分解式方案的架构及特点如图 8 所示。

在控制执行方面，深度学习技术用于学习控制系统，以控制对象和环境交互的特性，改善控制性能；在规划决策方面，深度学习技术被用于解读感知模块信息，并进一步利用感知信息解决无人汽车的路径规划与行为决策问题，主要解决汽车如何走的问题；在环境感知方面，深度学习算法广泛应用于车载传感器目标检测与识别，旨在从多种车载传感器数据中（一般为视觉传感器与激光雷达）准确检测识别出各类环境信息，如车道线、分隔栅栏、交通信号等。为系统决策和控制提供依据，是整个自动驾驶系统的基础，主要解决环境（外部条件）是如何的问题。

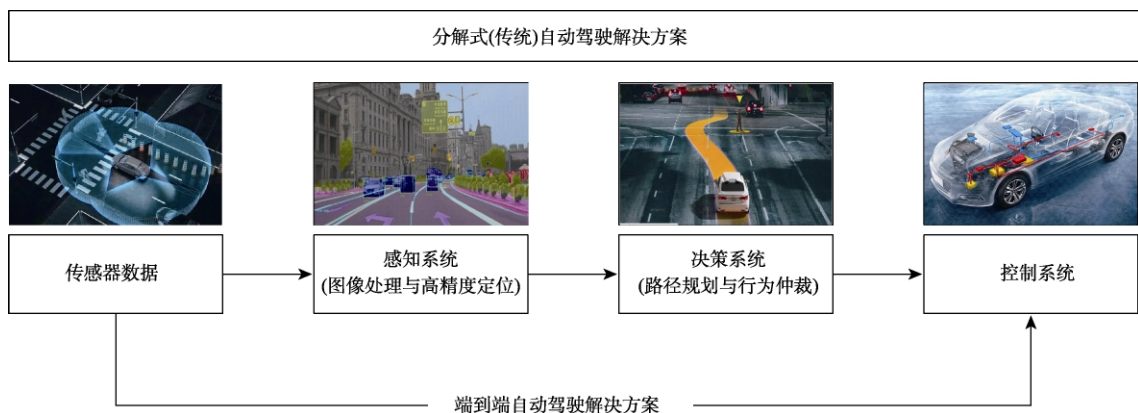


图 7 两种自动驾驶解决方案

Fig. 7 Two plans of autonomous driving

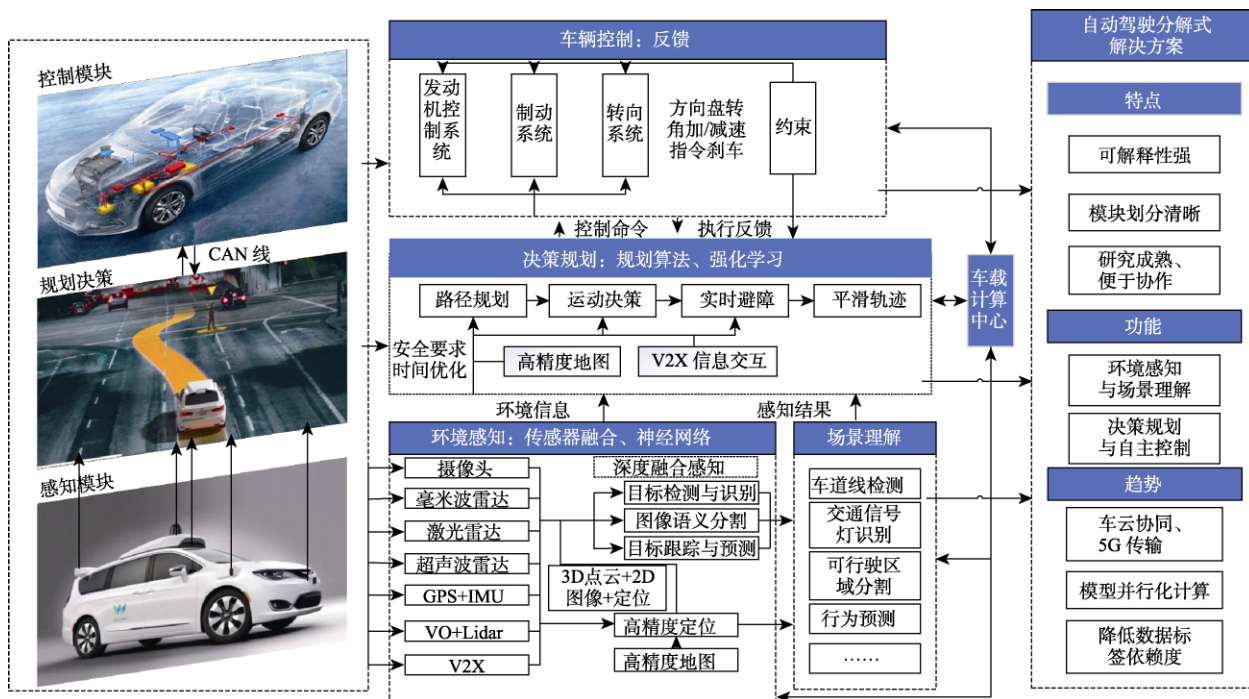


图 8 自动驾驶分解式架构

Fig. 8 Decomposed architecture for autonomous driving

自动驾驶分解式方案感知、决策、控制的分工架构使其可解释性更强、驾驶规则更严谨，但同时也极大地增加了系统的复杂度和计算量，从而大大提高了系统的开发难度与对车载硬件的要求（包括算力、体积、功耗等）。对于其决策模块而言，由于自动驾驶车辆需要能够适应和处理各类复杂极端环境，因此其行驶规则库构建难度很大，目前仍存在许多难以用规则描述的环境，使得系统不能实现对驾驶场景的覆盖与处理。端到端自动驾驶方案通过直接进行传感器数据到控制指令的映射来实现车辆的自动驾驶，不需要感知、决策等中间模块，避开了感知算法融合、驾驶规则库构建等难题，极大地降低了系统复杂度，具有开发难度小、硬件要求低的优点。但中间模块的去除使得这种方案的可靠性、灵活性很差，几乎不具有解释分析性，安全性难以保证。

3 深度学习在自动驾驶中的应用

3.1 自动驾驶环境感知中的深度学习

环境感知位于自动驾驶系统和复杂的外界环境之间，是自动驾驶系统进行决策的核心和前提，

其主要功能是为自动驾驶系统提供可靠的外部环境判断，判断自身所处位置和周边驾驶态势。自动驾驶环境感知包括障碍物检测、交通信号灯识别与车道线检测等，其基础技术主要是目标检测和语义分割等。目前，自动驾驶系统所使用的传感器主要包括摄像头、毫米波雷达、超声波雷达、激光雷达等^[18]。

3.1.1 主要的传感硬件

常见的摄像头分为单目^[19]和双目^[20]两类。单目摄像机结构简单，相机标定也简单，但单张照片难于确定物体的真实大小，只有在移动的情况下，才能推测深度信息。双目摄像机利用两架摄像机定位。对于物体上某个点，只需知道两个相机的准确位置，就可以知道该特征点在统一的同一个坐标系中的坐标值，即特征点的位置。视觉传感器安装简单，获取信息量巨大，算法多样，但易受光照和气象条件的影响。

激光雷达多用于三维目标检测，相比摄像机所获得的二维图像，它还能获得所处环境的深度信息。同时，它具有极高的分辨率和距离探测精度，最高可达厘米级^[21]，因此几乎所有自动驾驶

传感器系统都包括激光雷达。激光雷达使用激光束进行探测,是激光技术与现代光电技术结合的高精度探测设备。毫米波雷达是指波长在毫米级别的雷达,主要工作频段在 24 GHz、77 GHz、60 GHz^[22]。24 GHz 用于短距防撞预警和盲点检测,77 GHz 具有更好的距离分辨力,能够提高道路上的测距精度。毫米波雷达不受天气影响,它的探测距离较远,性能稳定,距离分辨率较高且成本低^[23],其缺点在于行人感知能力较弱,对建筑物无法建模,角度分辨率比较差。深度学习方法较多用于从 2D 图像(由摄像头获得)和 3D 点云(由激光雷达等获得)中检测和识别对象。

在自动驾驶中,三维感知主要基于激光雷达传感器,激光雷达数据以三维点云的形式供自动驾驶感知系统处理。三维目标探测精度由传感器的分辨率决定,目前先进的激光雷达已经能够提

供 2~3 cm 的精度^[24]。激光雷达和视觉传感器各有优缺点,雷达即使在黑暗中也具有高分辨率和精确感知能力,但易受恶劣天气条件(如大雨)的影响,并且涉及移动部件。相比之下,相机成本更低,但感知效果受光照影响较大。此外,照相机对恶劣天气也很敏感。

除了以上传感器外,自动驾驶汽车还使用了其他雷达和超声波传感器以进一步增强感知能力。例如,除了 5 个激光雷达传感器外,Waymo 还使用了 4 个毫米波雷达和 8 个摄像头,而 Tesla 汽车配备了 8 个摄像头、12 个超声波传感器和 1 个毫米波雷达^[7]。Mobileye 公司的自动驾驶汽车上一共有 12 个摄像头(前方 3 个,角落 2 个,朝前 2 个,朝后 2 个,朝侧 3 个,用作停车),目前各类自动驾驶汽车的传感器使用情况如表 1 所示^[10]。

表 1 各类自动驾驶车辆的传感器使用情况
Table 1 Sensors of various autonomous vehicles

自动驾驶车辆	Tesla	Waymo	Uber	Apollo	成本	优势	劣势
超声波雷达	√	×	√	√	低	成本低,结构简单,抗干扰能力强,精度较高	探测距离近,灵敏度与制造晶片相关
摄像头	√	√	√	√	中	成本较低,可识别目标多,如车道线及交通信号、行人等	受天气及光照影响较大
毫米波雷达	√	√	√	√	较高	不受天气影响,探测距离远,精度较高	成本较高,无法识别行人等目标
激光雷达	×	√	√	√	高	精度极高,能够通过 SLAM 建立周边环境三维模型	成本高,应用效果受天气影响

3.1.2 传感器目标检测

自动驾驶汽车能够检测的物体包括各类交通参与者、车道线、交通信号灯,障碍物等。传统的目标检测算法包括 HOG、SVM 等,其流程为:(1)感兴趣区域提取;(2)区域内目标特征提取;(3)分类器设计(AdaBoost/SVM 等)^[25]。传统方法的区域提取复杂度高,窗口冗余,且其目标特征需要手动构造,不能覆盖自动驾驶可能面临的全部场景。相比之下,深度学习算法不需要手动构造特征,简化了识别过程,在识别精度和速度上都有很大提升。

二维图像检测包含单级式和双级式两大类方法。单级式:直接输入图片,回归出含有特定目标的概率和目标的具体位置(4 个坐标),主要算

法包括 YOLO 算法和 SSD 算法,直接用一端到端的网络得出结果;双级式:双级式是基于区域的算法,先提取出可能包含物体的区域,再进行 BoundBox 的回归,回归出物体在图像中的具体位置,包括 R-CNN、Fast R-CNN、Faster R-CNN、Mask-RCNN、RFCN 等目标检测算法,图 9 为使用 YOLOv3 进行目标检测的示例。单级检测方法的准确率不如双级算法,但速度更快。

Redmon 等^[26]提出的 YOLO 算法,速度快,但精度较低,直接进行端到端回归,回归出来的结果是 4 个坐标以及各种物体和背景的概率。YOLO 系列算法包括 YOLOv1^[27]、YOLOv2^[26]、YOLOv3^[28]、YOLOv4^[29]、YOLOv5 等。Liu 等^[30]提出的 SSD 算法,使用多尺度的特征图检测结果可以检测大

物体与小物体, 同时对于每个中心点设置不同尺度和长宽比的 Prior boxes, 得到概率值和锚点 (Anchor Offset)。SSD 系列算法包括 R-SSD^[31]、DSSD^[32]、ASSD^[33]、FSSD^[34]、RetinaNet^[35]等。张婷婷等^[36]与黄健^[37]、罗元^[38]等比较了几种主要单级目标检测算法的性能, 结果如表 2 所示, VOC2007、2010、2012 与 MS COCO 是用于目标检测的 4 种不同数据集, 目标检测精确度的度量标准为平均准确度 (Mean Average Precision, MAP)。




图 9 YOLO 目标检测示例

Fig. 9 An example of YOLO target detection

表 2 单级式算法性能对比

Table 2 Performance comparison of single-stage algorithms

检测模型	基础网络	VOC2007	VOC2010	VOC2012	MS COCO (mAP/%)	
		(mAP/%@IoU=0.5)	(mAP/%@IoU=0.5)	(mAP/%@IoU=0.5)	AP@0.5	AP@[0.5,0.95]
YOLOv1 ^[27]	GoogLeNet	63.4	60.3	57.9	-	-
YOLOv2 ^[27]	DarkNet-19	76.8	76.5	73.4	44.0	21.6
YOLOv3 ^[28]	DarkNet-53	-	79.8	-	57.9	33.0
YOLOv4 ^[29]	CSPDarknet-53	-	-	-	64.9	43.0
SSD ^[30]	VGG-16	77.2	75.1	75.8	48.5	28.8
DSSD ^[32]	ResNet-101	78.6	-	76.3	53.3	33.2
RSSD ^[31]	VGG-16	78.5	-	76.4	-	-
ASSD ^[33]	ResNet-101	83	-	81.3	55.5	34.5
FSSD ^[34]	VGG-16	78.8	-	82	52.8	31.8
MDSSD ^[39]	VGG-16	78.6	-	-	-	26.8
RetinaNet ^[35]	ResNet-101-FPN	-	-	-	59.1	39.1

Grishick 等^[40]提出了 R-CNN 算法。算法分为三步: 第一步为确定候选区域, 之后运用选择性搜索算法, 不断合并最相似的区域, 最后选出符合条件的感兴趣区域; 第二步将每个候选区域的尺寸改变为固定大小, 送入 CNN 模型中提取特征向量; 第三步利用多类别 SVM 分类器进行目标分类。Grishick^[41]提出 Fast R-CNN, 对 R-CNN 进行改进, 提出了空间金字塔池化网络, 通过共享计算加速 R-CNN, 消除了许多重复计算。Ren 等^[42]提出了 Faster R-CNN, 对以上算法进行了进一步改进, 用 RPN 进行区域候选, 用滑动窗口生成参考框的坐标值和存在检测客体的概率, 并将这个值传给后续回归部分。Faster R-CNN 实现了端到端, 能够将所有运算都用 CNN 实现。He 等^[43]提出了 Mask-RCNN, 改进了感兴趣区域池化过程, 将池化过程中的取整操作取消, 改为通过双

线性插值填补非整数位置, 解决了池化过程中可能出现小数导致误差的问题, 因为插值改进了检测过程的像素精度, Mask-RCNN 也可用于图像分割。Dai 等^[44]提出了 R-FCN, 目标检测面临着平移不变性与敏感性间的矛盾, 因此需要将位置信息加入感兴趣区域池化, 并引入位置敏感得分图的概念, 得到类别与位置信息。不同双级式算法在 VOC2007、2012 及 COCO 测试集上的性能对比如表 3 所示。

3.1.3 图像语义分割

图像语义分割是对图像中的每个像素点进行分类, 为它确定一个标签, 从而对整幅图像中不同类别的对象进行分类。图像语义分割技术已经广泛应用于自动驾驶可行区域检测、车辆及障碍物检测等任务中。深度学习在语义分割中取得了巨大成功, 图 10 为应用深度学习技术进行车辆

表3 双级式算法性能对比
Table 3 Performance comparison of two-stage algorithms

模型	基础网络	VOC2007 (mAP/%@IoU=0.5)	VOC2010 (mAP/%@IoU=0.5)	VOC2012 (mAP/%@IoU=0.5)	COCO (mAP/%@IoU=0.5:0.95)
RCNN ^[40]	AlexNet	58.5	53.7	-	-
Fast RCNN ^[41]	VGG-16	70.0	68.8	68.4	19.7
Faster RCNN ^[42]	VGG-16	73.2	-	70.4	21.9
Mask-RCNN ^[43]	ResNet-101	-	-	-	36.7
R-FCN ^[44]	ResNet-101	80.5	-	77.6	29.9
HyperNet ^[45]	VGG-16	76.3	-	71.4	-
MR-CNN ^[46]	VGG-16	78.2	-	73.9	-
OHEM ^[47]	VGG-16	74.6	-	71.9	22.6



图10 街道可行驶区域图像语义分割结果
Fig. 10 Semantic segmentation results of street drivable area

可行驶区域语义分割的结果示例。目前,应用于图像语义分割领域的深度学习方法主要是全监督学习与弱监督学习^[48],常用的语义分割模型包括以下几种:语义分割 FCN、反卷积网络(Deconvolution Network, DeconvNet)、DeepLab、RefineNet、ResNet 和 PSPNet 等。

FCN 将 CNN 最后的全连接层换成了卷积层,这是两者的主要区别。输入 FCN 的图像可以是任意尺寸的,它将生成与之具有相同尺寸的分割图像,目前使用的深度学习语义分割模型基本都由 FCN 发展而来。2015 年,Long 等^[49]首次提出了端到端训练的 FCN,并将其用于图像分割。FCN 是使用深度学习进行语义分割的先驱,但它有种种缺陷,包括不考虑上下文信息、实时性差以及不完全适用于非结构化数据等。

2015 年,在 FCN 的基础上,Vijay 等^[50]发表 Segnet 模型,它采用编码器-解码器对称结构,所完成的语义分割任务能够达到像素级别。相比于 FCN,Segnet 的体量更小,采样过程中特征图及空间信息的损失也更小。DeepLab-v1 是 Google 团队研发的一种图像分割网络,是目前语义分割性能最好的模型之一。DeepLab 仍然采用了 FCN 的全卷积化结构,但它通过“Hole”算法引入空洞卷积^[51],能够扩大感受野,保持分辨率,同时不增加模型的参数。DeepLab 还在后处理中引入全连接条件随机场,对 FCN 图像细节较差的缺陷进行了改进。但引入空洞卷积的后果是计算量极大增加,需要大量内存。之后,Google 团队对 DeepLab 进行了更新,在 DeepLab-v2 中提出空洞空间卷积池化金字塔^[52],以此提取多尺度特征。DeepLab-v3 对所提出的空洞金字塔进行了进一步改进^[53]。针对 DeepLab 空洞卷积计算代价大,并且需要大量的内存的问题,DeepLab 的做法是只预测原始输入的 1/8。2016 年,Lin^[54]提出了一种高精度语义分割网络 RefineNet,该网络将以往丢弃的低层细节特征融入到分隔任务中,辅助高层粗糙特征实现高精度的分类。RefineNet 在 PASCAL VOC 2012 数据集上获得了截至其发表时各语义分割模型的最好成绩。表 4 显示了几种图像语义分割方法准确率对比。

3.1.4 高精度定位

定位算法的目的是获得车辆的实时位置及姿态。目前,主流的定位方式是 GPS/IMU 融合,这类算法精度可以达到米级。自动驾驶要求厘米

表 4 几种图像语义分割方法准确率对比

Table 4 Comparison of the accuracy of several image semantic segmentation methods

分割方法	基础网络	PASCAL VOC 2012 mIoU (%)	Cityscapes mIoU (%)	其他数据集 mIoU (%)
FCN ^[49]	VGG-16	67.2	65.3	PASCAL-CONTEXT35.1
DeepLab-v1 ^[51]	ResNet	71.6	63.1	-
DeepLab-v2 ^[52]	ResNet	79.7	70.4	PASCAL-CONTEXT45.7
DeepLab-v3 ^[53]	ResNet	86.9	81.3	-
DeepLab-v3+ ^[55]	ResNet	89.0	82.1	-
RefineNet ^[54]	ResNet	83.4	-	SUN-RGBD 45.9
ERFNet ^[56]	-	-	87.3	-
DeconvNet ^[57]	FCN	69.6	-	-
ENet ^[58]	FCN	-	58.3	CamVid 51.3

级定位精度,目前使用 GPS/IMU/LiDAR/HD Map 融合的定位方案已经能够在无遮挡区域达到此要求。汽车在自动驾驶过程中大多通过实时与高精度地图比对来获得高精度定位^[59]。但在存在高楼或隧道遮挡的情况下,以上系统的定位精度远远不能满足自动驾驶要求。深度学习在定位系统中主要应用于视觉定位 (Visual Odometry, VO) 与激光雷达定位,两者的原理都是通过相邻两帧的图像或者雷达数据估计本车的运动轨迹,从而估算当下状态相对于初始状态的位置。

(1) 视觉里程计

根据所用相机的类型,视觉里程计可分为基于单目、立体或 RGB-D 图像的 VO 系统,按照所用方法,可分为特征点法及直接法 VO 系统^[60]。特征法从图像中提取一些特征进行跟踪和匹配计算,计算量小、计算速度快、鲁棒性与稳定性强,其一般流程如图 11 所示。直接法不使用特征点,直接利用像素梯度计算相机位姿,直接法的计算量很大,目前主流的 VO 系统大多使用特征点法。

视觉定位通过匹配相邻两帧图像间的特征点来估计相机的运动,同时重建当前环境。研究人




图 11 特征点法视觉里程计的一般流程

Fig. 11 Process of visual odometer using feature point method

员已经证明,相比传统的车轮里程与航位推算技术,VO 的定位精度更高,成本也更低^[61]。基于深度学习的视觉里程计无须传统方法的特征提取和复杂计算,有效降低了定位运算量^[62]。Konda 等^[63]最先将深度学习与 VO 系统结合起来,使用 CNN 学习从视频到运动情况的映射。Liu 等^[64]提出了一种基于深度学习的单目视觉里程计,以无监督的端到端方式训练,仅采用单眼图像作为输入,并直接以绝对比例生成姿态,RCNN-VO 与 SMFLearning 的输入分辨率为 416×128, VISO2-MONO 与 VISO2-Stereo 输入的图像分辨率为 1242×376。在 KITTI 数据集上的实验表示,该系统在平移和旋转精度方面优于其他单眼 VO 系统,由于 SMFLearning 依赖于地面真实姿态进行比例恢复,测试中对其结果进行了后处理,以进行比较,表 5 中显示了该算法与传统算法的性能对比情况。Wang 等^[65]使用深度学习技术读取原始 RGB 图像(视频)序列并输出相应姿态,该系统所使用的网络是递归神经网络 (Recursive Neural Network, RNN),这种网络的架构是端到端的,它不依赖于传统 VO 算法中的任何模块(甚至是相机校准)。

深度学习视觉定位能够有效降低定位计算量,并且可以通过端到端的方式极大简化视觉定位的中间过程,如参数标定、频率匹配等。但它也有一些明显的缺点,如模型可解释性差,解的精度较低,不具备泛化性等。Wang 等^[65]提出的利用 RCNN 的端到端 VO 系统在精度上已经可以

表 5 基于 RCNN 的 VO 算法与传统 VO 算法定位精度比较^[64]

Table 5 Comparison of positioning accuracy between VO algorithm based on RCNN and traditional VO algorithm

Seq	RCNN-VO		SfMLearner		VISO2-Mono		VISO2-Stereo	
	trmse	rrmse×100	trmse	rrmse×100	trmse	rrmse×100	trmse	rrmse×100
00	5.14	2.13	45.89	6.23	18.24	2.69	1.86	0.58
02	4.88	2.26	57.59	4.09	4.34	1.18	2.01	0.40
03	6.03	1.83	13.08	3.79	8.47	1.96	3.21	0.73
04	2.15	0.89	10.86	5.13	4.69	1.80	2.12	0.24
05	3.84	1.29	16.76	4.06	19.22	3.54	1.53	0.53
06	4.64	1.21	23.53	4.80	7.30	1.78	1.48	0.30
07	3.80	1.71	17.52	5.38	23.61	4.11	1.85	0.78
08	2.95	1.58	24.02	3.06	24.18	2.47	1.92	0.55
09	5.59	2.57	22.27	3.62	7.08	1.15	1.99	0.53
10	4.76	2.95	14.36	3.98	41.60	3.03	1.17	0.43
mean	4.38	1.84	24.59	4.41	15.83	2.37	1.91	0.51

- trmse(%):average translational RMSE drift(%) on length of 100~800 m.
- rrmse(%):average rotational RMSE drift(°/m) on length of 100~800 m.
- RCNN-VO :Monocular Absolute Scale Unsupervised
- SfMLearner:Monocular Scale Post-processing Unsupervised
- VISO2-Mono:Monocular Absolute Scale Feature based
- VISO2-Stereo:Stereo Absolute Scale Feature based

和传统 VO 方法相比,但文章也指出,基于深度学习的 VO 目前只能作为传统 VO 的补充。

(2) 激光里程计

激光里程计采集激光雷达扫描周围环境产生的三维点云作为数据输入进行车辆的位置识别。Jo 等^[66]提出了使用 Lidar 和相机结合的定位方法,并将其成功应用于移动机器人定位。

目前,深度学习 LIDAR 定位已经具有能够满足应用要求的定位精度及计算速度,但也具有可解释性差、依赖样本质量、数量等缺点。此外,激光雷达在雨雪等极端天气下扫描效果很差,且 LIDAR 定位具有漂移误差,因此大多都用于配合先验性地图及其他传感器共同定位。

3.2 自动驾驶决策规划中的深度学习

3.2.1 路径/轨迹规划

路径规划是自动驾驶汽车根据地图及传感数据,在起点和终点之间生成行驶路线的能力。简单地说,就是给定环境、汽车模型指定规划目标(如无碰撞等),自动搜索出车辆运动路径。路径规划分全局规划和局部规划,全局路径规划基于先验地图与环境信息,属于静态规划(离线规划),局部路径规划基于实时传感器信息,属于动态规

划(在线规划)^[67]。目前,深度学习技术主要用于局部路径规划。常用的路径搜索算法包含 Dijkstra、Floyd-Warshall、人工势场法、蚁群算法等。常用的路径规划算法流程如图 12 所示。


图 12 路径规划算法流程^[68]

Fig. 12 Process of path planning algorithm

深度学习路径规划的一个方向是基于传感器、目标和地图的端到端路径规划。这部分算法大多采用深度强化学习方式,因为强化学习可以从与环境的交互“试错”中学习,这种学习方式最接近人类思考过程,能够较好地解决无法简单标注对错的问题。该类算法的特点是只需制定规划目标,之后通过实际环境试验或仿真训练更新模型即可^[67]。Grigorescu 等^[69]基于神经网络提出了 NeuroTrajectory,该方法能够从占用栅格和相应的驾驶命令中学习车辆局部状态轨迹。针对车辆所处的实际城市路网环境,肖浩等^[70]基于深度 Q 学习和深度预测网络技术进行自动驾驶车辆的最短时间全局路径规划,与 Dijkstra 算法、

A*等静态算法相比, 该算法行车时间最高减少 17.97%。

深度学习路径规划的另一个方向是将深度学习技术与传统路径规划方法相结合, 以提升传统算法性能。CL-RRT 算法可以考虑到复杂交通情况下车辆运动的多种约束, 因此搜索出的最佳路径具有较高的安全性, 但它的计算量大、计算时

间过长。Chaulwar 等^[71]使用 3D-CNN 预测关键交通场景中的适合加速曲线, 从而减少了 CL-RRT 的计算时间。实验结果表明, 与传统 CL-RRT 方法相比, 该方法将路径规划平均时间由 5.05 s 降为 0.62 s, 而基本没有损害安全性 (无碰撞路径率由 100%降为 99.63%)。深度学习于路径规划应用研究案例如表 6 所示。

表 6 深度学习路径规划应用研究案例

Table 6 Examples of deep learning methods in path-planning problems

行车环境	所用算法	算法效果
GridSim 模拟器 (市中心区域)+实际道路 (50 km 高速公路+50 km 城市道路) ^[69]	DNN	该算法在模拟和实际测试中均实现了最低误差, 除在实际高速公路驾驶中的最大纵向误差 $\max(e_y)$ 低于 DWA 外
城市路网 ^[70]	深度 Q 学习	与 Dijkstra 算法、A*等静态算法相比, 行车时间最高减少 17.97%, 最低减少 6.89%
高速公路 ^[72]	3D-CNN+LSTM	相比对比方法 (comma.ai 轨迹规划方法), 轨迹规划结果更稳定、更可靠
关键交通场景 ^[71]	3D-CNN+CL-RRT	与传统 CL-RRT 算法相比, 该方法将路径规划平均时间由 5.05s 降为 0.62s, 无碰撞路径率由 100%降为 99.63%

自动驾驶车辆存在路径与轨迹的区分, 可以认为轨迹是同时考虑空间和时间因素的路径。当路径规划过程要满足车辆运动的纵向和横向动力学约束时, 就成为轨迹规划。自动驾驶车辆纵向速度规划与时间密切相关, 而车辆横向动力学对纵向速度的影响较大。轨迹规划的输入包括拓扑地图、障碍物及障碍物的预测轨迹、交通信号灯的状态, 以及车辆定位、导航、车辆状态等信息。输出则是一个轨迹, 即一个时间到位置的函数。传统车辆轨迹规划的方法主要有: 基于状态空间的轨迹规划方法、基于参数化曲线的轨迹规划方法、针对系统特征的规划方法和基于滚动窗口的轨迹规划等^[73]。

深度学习技术的快速发展为轨迹规划提供了更多可能, 基于深度学习的轨迹规划算法大多属于端到端类方法, 根据所输入的信息直接产生车辆运动轨迹。上述算法的一个分支是利用深度神经网络。Pfeiffer 等^[74]使用一个端到端的卷积神经网络来学习从 2D 激光测距结果与目标位置到转向命令的映射。仿真结果显示, 该运动计划器的内容略优于完全了解地图的专家计划器。Lin 等^[75]使用深度学习模型从人类驾驶员泊车轨迹中学习车辆动力学指标与所处地图环境同车辆控制动作

间的关系, 意在使该模型用于人类驾驶员驾车的高级驾驶辅助系统。

利用深度学习进行轨迹规划的另一分支是深度强化学习。Yu 等^[76]提出了一种基于深度强化学习的轨迹规划方法, 该方法训练的路径规划模型可以根据传感器数据及旧动作直接输出控制动作和轨迹序列。Du 等^[77]使用深度强化学习进行智能车辆自动泊车轨迹规划, 仿真结果显示泊车成功率超越 90%, 泊车时长根据所用计算平台不同在 11~97 s 间波动。

目前, 深度学习在路径规划与轨迹规划领域应用较少, 因为使用神经网络规划路径/轨迹的整体效果并不理想, 原因在于规划环境复杂多变, 而神经网络的泛化能力差, 可解释性不足。但相比传统算法, 神经网络算法的学习能力与鲁棒性更强。深度学习算法通过学习大量驾驶数据集, 在测评中显示出较低的误差率, 但由于数据集中极端情况数据缺乏 (如越野驾驶、车辆碰撞等), 使得模型在面对未知数据时的响应不确定。

3.2.2 行为决策

这里的自动驾驶的决策模块是指狭义的决策系统, 其根据车辆感知系统所获得的环境与车辆状态信息, 发出合理的行驶指令 (加/减速和转向

等),并将指令传递给控制执行模块。目前,自动驾驶决策系统主要分为两类,分别是基于规则的决策系统和基于机器学习的决策系统。基于规则的决策系统需要建立庞大的驾驶规则库,对本车可能面临的驾驶场景选择对策。该方法的缺点在于不能应对陌生场景,只适用于几种简单情况。研究人员提出了许多基于深度学习的决策模块。Loiacono 等^[78]提出了一种使用深度 Q 网络(Deep Q Network, DQN)的自动驾驶汽车超车策略,DQN 的算法流程如图 13 所示。作者考虑直线/大转弯或急转弯两种情况下车辆的超车决策问题,并在 TORCS 中进行了仿真实验,表明该算法能够进行合理超车决策。Sun 等^[79]针对自适应巡航状况下的重型商用车辆,提出了一种用于确定不同曲率道路中车辆巡航目标的深度确定性策略梯度(Deep Deterministic Policy Gradient, DDPG)算法。通过合理设计强化学习参数,大大缩短了 Agent 的训练时间,并解决了传统基于规则算法在复杂陌生环境中无法解决的问题。Zheng 等^[80]

根据仿真数据,建立了基于强化学习的自动驾驶决策系统,将车辆决策过程建模为马尔科夫决策过程(Markov Decision Process, MDP),并使用强化学习改进 MDP 的性能。高速环路环境下的仿真测试表明了该方法的有效性,表 7 中总结了近年来部分应用深度学习技术进行自动驾驶车辆决策的研究。其中,文献[81]为数值仿真方式测试,未说明具体仿真平台。

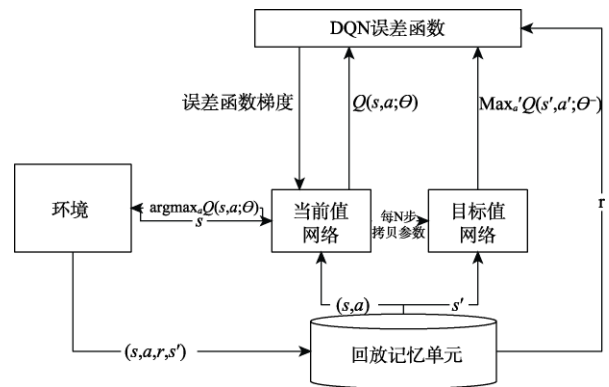
图 13 DQN 算法流程^[82]

Fig. 13 Process of DQN algorithm

表 7 部分深度学习决策研究

Table 7 Examples of deep learning methods in decision-making problems

深度学习方法	测试平台	目标场景	所解决的问题
DQN	PreScan ^[83]	行人横穿马路	设计了一种自动制动系统,用于避免车辆和行人之间的碰撞
	TORCS ^[78]	直行/急转弯超车	考虑直线/大转弯或急转弯两种情况下车辆的超车决策问题
	PreScan ^[79]	高速公路车辆巡航	解决了在不同曲率道路中重型商用车辆巡航自动控制的问题
DRL	数值仿真 ^[83]	车辆行驶紧急情况	解决紧急情况下车辆自动制动问题,使车辆能够在紧急情况下自动采取最佳制动行为,提高驾驶安全性
DDPG	Airsim ^[84]	车辆换道	将车道变更系统建模为 MDP,设计了避免碰撞的奖励函数,并将其与 DDPG 算法集成在一起
	VISSIM ^[85]	车辆跟驰与车道变换	在所建立的框架内训练模型进行车辆跟驰决策,与经典交通模型智能驾驶员模型(IDM)相比,训练后的效率提高了 7.9%

以上都是针对特定场景的决策研究,但自动驾驶的应用要求决策系统能够解决汽车行驶过程中所面临的几乎所有问题,目前有些使用深度学习技术构建的决策系统已经被应用于无人驾驶车辆。Mobileye 公司^[86]使用基于深度强化学习的驾驶决策系统,并将其置入“感知—决策—控制”的传统自动驾驶架构中,实现了 3 个主要模块的协同性。Waymo 的自动驾驶决策系统使用深度学习技术来进行场景理解,并且能够预测行人或车辆下一步的动作,并判断该动作对自身车辆行驶

的影响,最终做出合理的决策。

基于深度学习的自动驾驶决策系统目前已经能解决一些驾驶场景下的决策问题,并表现出了卓越的数据学习能力。但深度学习决策模型的性能受样本情况及算法结构影响较大,如果样本数量不足、质量较低,会导致决策模型对场景了解不足,不能做出有效决策。如果算法过于复杂,会导致决策时间过长,训练复杂,不能满足对决策时间的限制。对深度学习决策模型,一方面要保证样本质量和数量,一方面要采取合适的算法

结果, 合理确定神经网络层数。

3.3 自动驾驶控制执行中的深度学习

根据接受到的传感器数据, 实现无人车辆的自主运动控制是自动驾驶最基本的任务之一。深度学习在此模块中的应用有两种方向, 其中之一是利用深度学习进行控制器构建, 即根据已有驾驶和环境数据来训练模型, 使模型参数更精确, 鲁棒性和适应性更强; 另一个是基于深度学习的端到端控制系统, 利用深度学习进行控制器构建, 直接从传感器输入数据中学习, 输出车辆方向盘转角等控制量。在自动驾驶的业界领域, 除具备车辆底盘部件研发能力的传统车企外, 大部分研发企业都只做到规划决策水平, 而将执行控制的部分交给供应商。

传统汽车使用底盘控制器 (Central Power Control, CPC) 来根据驾驶人的动作执行相应的转向与速度指令。传统控制器通过规定控制器模型参数的方式实现汽车运动精确控制。但标准控制器往往只针对一般场景和近似汽车模型实现参数拟合, 当面对恶劣环境 (如泥泞、雨雪、多石路段等) 或汽车运动模块受损 (如轮胎损坏、刹车不灵等) 时, 传统模型无法适应以上变化, 而从已有数据中学习可以解决这类问题。

深度学习控制器的一个研究方向是从已有控制器的输入输出数据中学习, 从而构建适应性更强的控制器模型。Ostafew 等^[87]提出了一种基于学习的非线性预测控制 (Nonlinear Model Predictive Control, NMPC) 算法。该算法适用于户外越野机器人, 利用实际经验来减少路径跟踪错误, 而不是预先编程目标地形下的轮-地作用, 形成地形拓扑或机器人动力学的精确分析模型。

深度学习还与模型预测控制 (Model Predictive Control, MPC) 相结合, 模型预测控制是一种通过求解优化问题来计算控制行为的控制策略。深度学习与其结合从数据中学习不同驾驶风格, 并依据不同风格输出转向和速度命令^[88]。Chen 等^[89]提出了一种输入凸的神经网络 (Input Convex Recurrent Neural Network, ICRNN) 用于系统建模, 并将系统模型嵌入到 MPC 框架中, 求

解其最优控制值。这一类控制策略为了获得车辆运动中的最优约束, 使用深度神经网络学习 MPC 中的车辆非线性动力学以更好地预测控制指令对车辆运动的影响。

深度学习控制器的主要优势在于其能够将深度学习技术与传统控制理论结合起来。这样不仅能发挥传统控制理论的优点, 还能利用已有成果进行控制器设计和稳定性分析。但目前将深度学习用于控制领域的研究和应用都较少, 原因在于神经网络控制模型需要面临两个问题, 一是神经网络的可解释性问题, 控制模块作为汽车最底层的执行模块, 需要满足对汽车安全性和可解释性的要求; 二是模型的泛化能力问题, 所训练的模型需要能够应用于不同车辆、不同场景, 以降低开发成本。此外, 一般来说, 深度神经网络的优化求解过程中包含很多局部最优点, 所以很容易陷入局部最优解^[89]。而很多控制问题的求解对稳定性有极高的要求, 如航空航天系统控制、车辆运动控制等, 这在一定程度上限制了深度学习在实际控制问题中的应用。

3.4 端到端自动驾驶

基于传统“感知—决策—控制”流程的自动驾驶系统的优势在于技术积累深厚, 路线清晰可解释性强。但也存在着许多问题, 如硬件要求高, 并且分解式系统往往十分庞大, 系统复杂度极高。为了解决以上问题, 研究人员开始将端到端深度学习用于自动驾驶。端到端自动驾驶系统直接从传感数据映射到转向命令^[90], 能够大幅降低系统的各项成本。

1989年, 卡耐基梅隆大学的 Pomerleau 等^[91]利用单隐藏层全连接网络, 以手中的驾驶样本对其训练得到了第1个端到端驾驶系统, 这也是端到端自动驾驶系统的起源。因神经网络层数及样本数量的限制, 该系统所表现出的驾驶效果差强人意。但在之后的数十年中, 端到端驾驶系统发展迅速, 得益于深度神经网络训练的突破, 目前端到端自动驾驶系统所用的神经网络层数大大增加, Nvidia 的端到端自动驾驶系统所使用的深度学习网络层数达到了9层 (归一化层1个, 卷积

层 5 个, 全连接层 3 个)^[92]。在大数据时代, 所能用于训练的数据量也大大增加, Lecun 等^[93]使用 10 万张图像训练驾驶模型, 并使其具有了避障能力, 并通过训练使车辆获得了避障能力。LSTM 网络具有时序记忆功能, 一些研究将其和 CNN 的数据处理能力结合, 组成混合模型应用于端到端驾驶系统。Eraqi 等^[94]提出了一种复合神经网络, 用于估计方向盘的角度。该网络包括一个 CNN 和一个 LSTM 网络, 使用相机作为输入, CNN 用于逐帧处理相机图像。CNN 提取驾驶场

景的特征, 然后将其传递到 LSTM 层的堆栈中。这些功能的时间依赖性可以通过 LSTM 网络了解。最后, 转向角预测由输出层执行。

强化学习具有强大的试错学习能力, 能够从环境互动和错误中学习最优策略。Sallab 等^[95]提出了一个使用深度强化学习的自动驾驶框架。基于 TORCS 的仿真测试表明, 该系统在能够较好地完成车辆在复杂道路中的转弯决策。表 8 总结了目前业界和学术界几种端到端自动驾驶方法及其优劣势。

表 8 几种端到端自动驾驶方法及其优劣势

Table 8 Several end-to-end autonomous driving plans and their advantages and disadvantages

端到端自动驾驶方法	传感器数据输入	优势	劣势
NVIDIA-CNN ^[92]	视觉图像	数据依赖性低, 能够从少量数据中学习驾驶行为; 能够适应多种情况下的驾驶任务(晴天、雨天、多云等)	网络鲁棒性有待提升; 驾驶决策可解释性低。不控制速度, 障碍物刹车时需要人为接管
Comma.ai-GAN(RAE) ^[96]	视觉图像	使用基于 GAN 框架下的 VAE, 模型简单, 平台要求低, 计算量小	模型安全性较差; 缺乏障碍物检测、车道检测、红绿灯检测等功能
FCN-LSTM ^[94]	大规模视频数据	考虑到驾驶行为的时间性, 使用 LSTM 基于前帧和当前帧共同得到决策指令	网络体量大; 模型训练所需的迭代次数多
TORCS-DRL ^[95]	TORCS 仿真图像	降低了在嵌入式硬件上部署的计算复杂度; TORCS 仿真结果表明处理复杂道路和车辆相互作用场景结果较好	需要在环境中试错来训练模型, 大多在电子游戏引擎中完成, 训练时间长, 迁移性差
ApolloE2E	视觉图像	横向控制使用 CNN, 纵向使用 C-LSTM, 使用 LRCN 结合横纵向模型; 使用地图采集车采集了大量适合中国道路情况的数据集并开源使用	目前基于已有数据的训练只能实现 Reactive Control, Proactive Planning 功能还在探索

目前深度学习端到端自动驾驶系统多处于理论及实验阶段, Comma.ai 公司将端到端自动驾驶系统应用于其无人车辆, 该类型无人车已经行驶约 1.35×10^6 km, 累计行驶时间约 22000 h^[96], 但其最终因为安全隐患被美国交通部叫停。

英国自动驾驶企业 Wayve 的端到端无人驾驶车辆实现了社区道路自主行驶, 并发布了 Demo 视频。此外, Nvidia 的端到端自动驾驶系统架构如图 14 所示, 但其车辆并未进行路测。

相比于传统基于规则的系统, 端到端自动驾驶系统的复杂度和算力要求更低, 所需传感器成本也更低, 但其缺点也有很多, 包括: (1) 不能利用车辆动力学模型^[25], 迁移性差, 对于不同的车辆与传感器, 端到端系统需要进行重新校准; (2) 现实世界中对于同一驾驶场景, 不同驾驶员

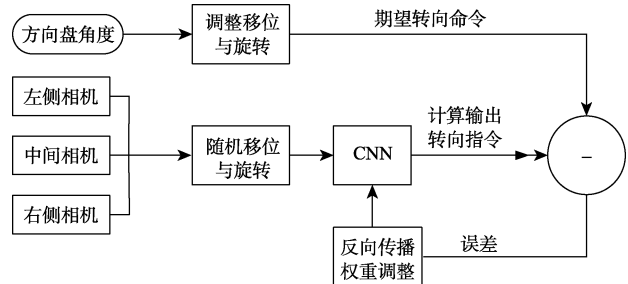


图 14 NVIDIA 端到端自动驾驶学习框架

Fig. 14 NVIDIA end-to-end learning framework of autonomous driving

可能做出不同的反应, 端到端的学习可能随之也出现不稳定现象, 从而变成一个不适宜问题; (3) 以表 8 中 TORCS-DRL^[95]为代表的强化学习式端到端自动驾驶系统面临虚拟仿真环境到实际道路环境的迁移问题, 以 FCN-LSTM^[94]为代表的监督学习式端到端自动驾驶系统面临数据需求量过

大、对低占比样本不能有效学习的问题；(4) 目前端到端自动驾驶系统大多基于图像数据进行训练，但在恶劣天气下视觉传感器的可靠性将大打折扣，影响行驶安全。

4 基于深度学习的自动驾驶平台

4.1 北京航空航天大学研发的自动驾驶平台

目前，自动驾驶高效的研发流程是，先在计算机软件上通过仿真测试技术升级算法，确保它在虚拟环境中可以运行成功，再进行硬件在环测试，接着在封闭场地测试，最后再进行道路测试。北京航空航天大学车路协同北京市重点实验室立足自动驾驶技术虚拟仿真测试及实车验证需求，

研发联合 TORCS 与 Torch7 的仿真测试平台及基于 ROS 的实车验证平台。

4.1.1 自动驾驶端到端强化学习仿真训练开发平台

如图 15(a)所示，仿真平台底层基于 TORCS 游戏引擎生成虚拟道路场景，基于 Torch7 机器学习库构建基于深度学习框架的端到端自动驾驶模型，TORCS 与 Torch7 之间通过 ubuntu 的共享内存实现数据互传，游戏引擎将生成的视觉图像信息传给 Torch7 中的端到端自动驾驶模型以生成控制指令，之后再通过共享内存回传控制指令，控制虚拟场景中的自动驾驶车辆在道路上行驶。仿真平台对所测试的端到端自动驾驶模型从 5 个方面展开定量评价，包括最初性能、收敛步数、最优性能、最终性能、总体性能。

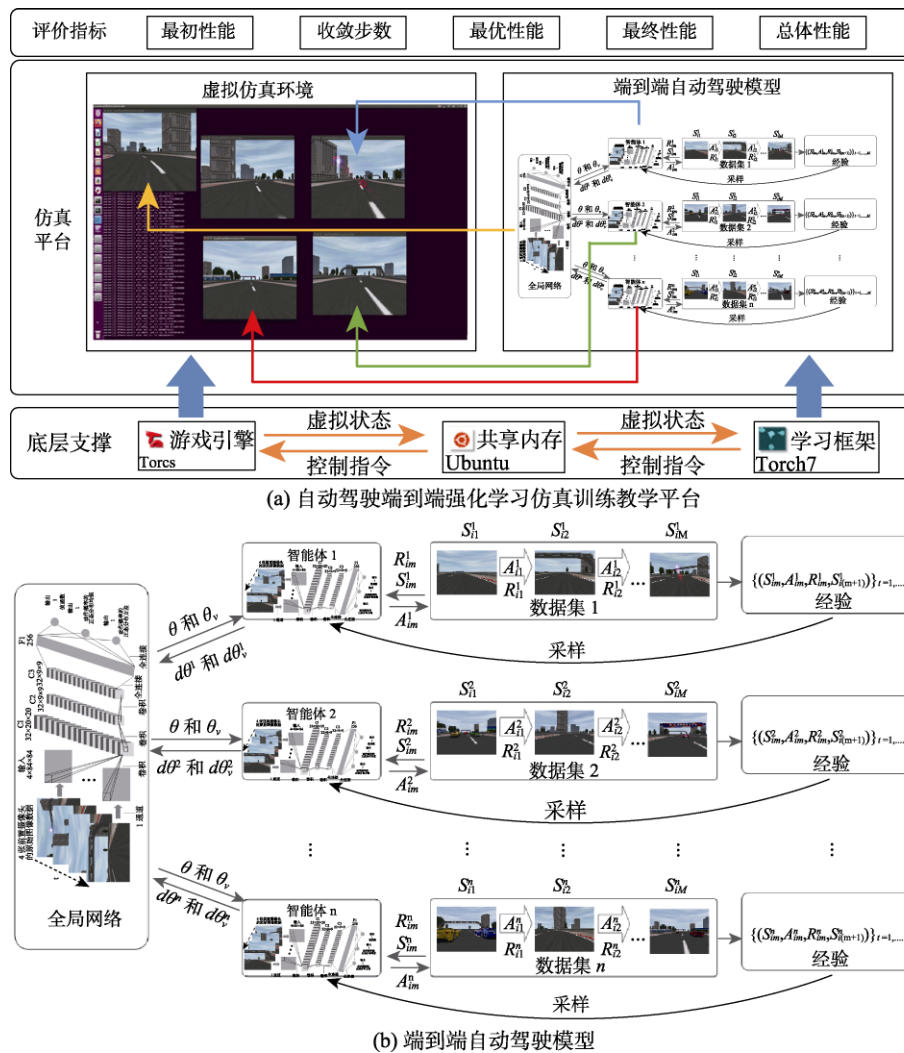


图 15 自动驾驶端到端强化学习仿真平台及模型

Fig. 15 Autonomous driving end-to-end reinforcement learning simulation platform and the model

最优性能、最终性能和总体性能,如图 15(b)所示。各指标的具体定义如下。

(1) 最初性能: 被训练模型在强化学习阶段第一次获得的平均奖励;

(2) 收敛步数: 被训练模型在强化学习阶段某一训练步数后连续 5×10^6 个训练步获得的平均奖励标准差不超过 500 时, 此训练步数为收敛步数;

(3) 最优性能: 被训练模型在强化学习阶段获得的最高平均奖励;

(4) 最终性能: 被训练模型在强化学习阶段的最终学习效果, 为训练结束时获得的平均奖励;

(5) 总体性能: 模型训练过程中累计的总奖励 (即学习曲线下的面积(AUC))。我们使用梯形法则来逼近 AUC:

$$AUC \approx \sum_{s=1}^S \frac{f(x_{s-1}) + f(x_s)}{2} \Delta x_s$$

式中, $f(x_s)$ 是第 s 训练步数时的奖励; $\Delta x_s = x_s - x_{s-1} = 1 \times 10^3$ 是估算步长。

4.1.2 自动驾驶软件开发平台

如图 16 所示, 实车验证软件平台联合 ROS、Apollo、Autoware 与 Torch7 搭建而成, 其中 ROS 作为软件平台的底层框架主要支持各个模块之间松耦合通信; 基于百度 Apollo 研发适配其他车型的 CANBus 模块, 反馈无人车当前的状态 (航向, 角度, 速度等信息), 并且发送控制命令到无人车线控底盘; 基于 Autoware 深度研发高精度地图与组合定位结合的自适应定位算法, 向上层基于 Torch7 的端到端自动驾驶模型提供必要信息; 基于 Torch7 研发学习驱动的自动驾驶模型, 在底层各个模块提供的信息基础上, 深度神经网络得到最佳车辆驾驶动作并交由 CANBus 模块传达线控底盘执行。

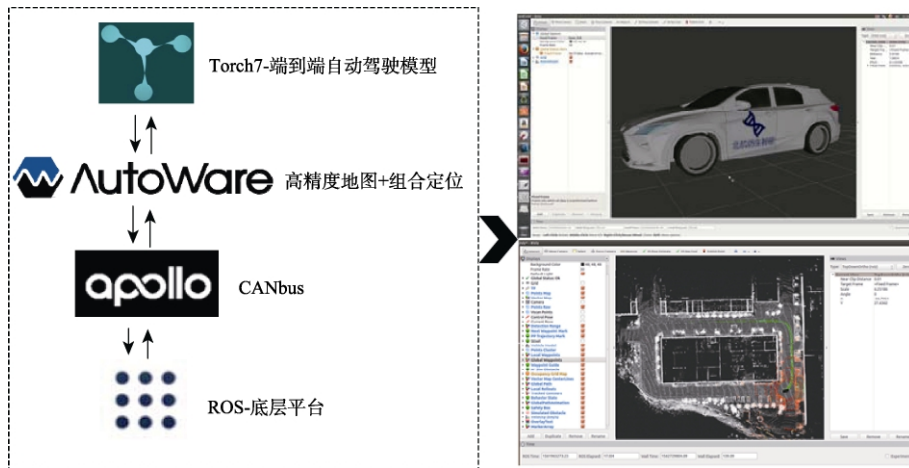


图 16 自动驾驶软件开发平台

Fig. 16 Autonomous driving software development platform

在系统的内部功能模块之外, 针对自动驾驶系统设计的人机交互问题, 本文所提软件平台还开发了如图 17 所示的图形操作界面。图形操作界面意在以良好的可视化界面提供车辆实时动态、周围环境动态、程序算法状态等信息, 从而更方便用户操作与观察当前系统开发情况。

4.1.3 百度 Apollo 自动驾驶教学开发平台

本文所提实车验证平台将其软件平台部署于如图 18 所示的百度 Apollo 开发者套件。在各类驾驶环境下 (十字路口、丁字路口、雨雪天气)

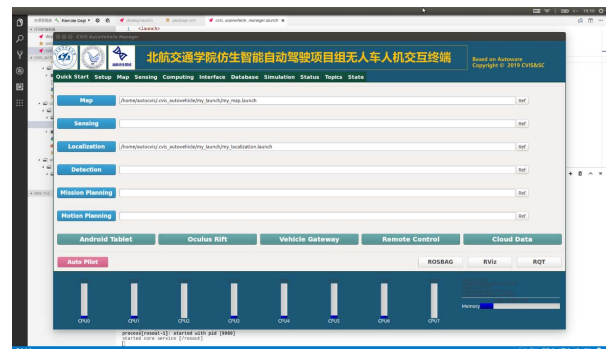


图 17 系统可视化界面

Fig. 17 Visualization interface of auto-driving software platform



图 18 百度 Apollo 开发者套件

Fig. 18 Baidu autonomous driving develop kit (Apollo D-kit)

测试算法的性能，以验证所开发软件系统的智能性与安全性。

4.1.4 实车线控底盘教学开发平台

百度 Apollo 开发者套件能够实现自动驾驶系统感知、规划等模块的效果检验与即时调试，但是开发者套件的底盘同实车的线控底盘有较大差别，要想让自动驾驶系统真正落地，还需要在实车拆卸下的线控底盘(如图 19)中对 CANBus 模块进行测试,使其能够适配乘用车的线控系统。



图 19 实车线控底盘

Fig. 19 Vehicle wire control chassis

4.2 Nvidia 自动驾驶平台

2017 年 9 月，Nvidia 发布其端到端自动驾驶平台 Nvidia DRIVE，产品涵盖车载计算平台、开源软件堆栈。

4.2.1 车载计算平台

2019 年 12 月，Nvidia 发布了其全新自动驾驶芯片 Drive AGX Orin，该类型芯片每秒可运行 200 万亿次计算，相较于上一代 Xavier 的性能，

提升了 7 倍。Orin 可处理在自动驾驶汽车和机器人中同时运行的大量应用和深度神经网络，并且达到了 ISO 26262 ASIL-D 等级系统安全标准。自此，Nvidia 形成了其包含 NVIDIA DRIVE AGX XAVIER、NVIDIA DRIVE AGX PEGASUS 与 NVIDIA DRIVE AGX ORIN 的 NVIDIA DRIVE AGX 自动驾驶计算平台系列。NVIDIA DRIVE AGX 系列嵌入式计算平台能够处理来自摄像头、普通雷达和激光雷达传感器的数据，以感知周围环境、在地图上确定汽车的位置，以及规划和执行安全的行车路线。这款 AI 平台支持自动驾驶、驾驶室功能和驾驶员监控，以及其他安全功能^[97]。Nvidia 各型号计算平台的性能对比如表 9 所示。

表 9 Nvidia DRIVE AGX 各型号计算平台性能对比
Table 9 Performance comparison of Nvidia DRIVE AGX computing platforms

	XAVIER	PEGASUS	ORIN	HYPERION
应用	L2+/L3 级自动驾驶	L4/L5 级自动驾驶	自动驾驶汽车与机器人	自动驾驶数据收集与感知评估
芯片	1×XAVIER	2×XAVIER	1×ORIN	2×XAVIER
GPU	N/A	2×Post-Volta	N/A	2×Nvidia Turing
CPU	8×Nvidia Custom ARM	16×Nvidia Custom ARM	基于 Nvidia Custom ARM	16×Nvidia Custom ARM
算力	30TOPS	320TOPS	200TOPS	--
功耗	30 W	500 W	--	--

4.2.2 开源软件

Nvidia 自动驾驶开源软件堆栈包括自动驾驶安全操作系统 DRIVE OS、自动驾驶软件开发套件 DriveWorks SDK、自动驾驶感知、控制、规划应用层 DRIVE AV 与舱内感知应用平台 DRIVE IX。

DRIVE OS 操作系统包括处理传感器数据的 NvMedia、Nvidia CUDA 库、NVIDIA TensorRT 等,可满足汽车最高安全等级 ASIL-D。DRIVE OS 为应用程序提供了安全的执行环境，例如安全启动、安全服务、防火墙和无线更新。另外，它提供了带有实时操作系统 (Real Time Operating System, RTOS)和服务质量管理程序的实时环境。

NVIDIA DRIVE 开源软件堆栈的架构如图 20 所示。

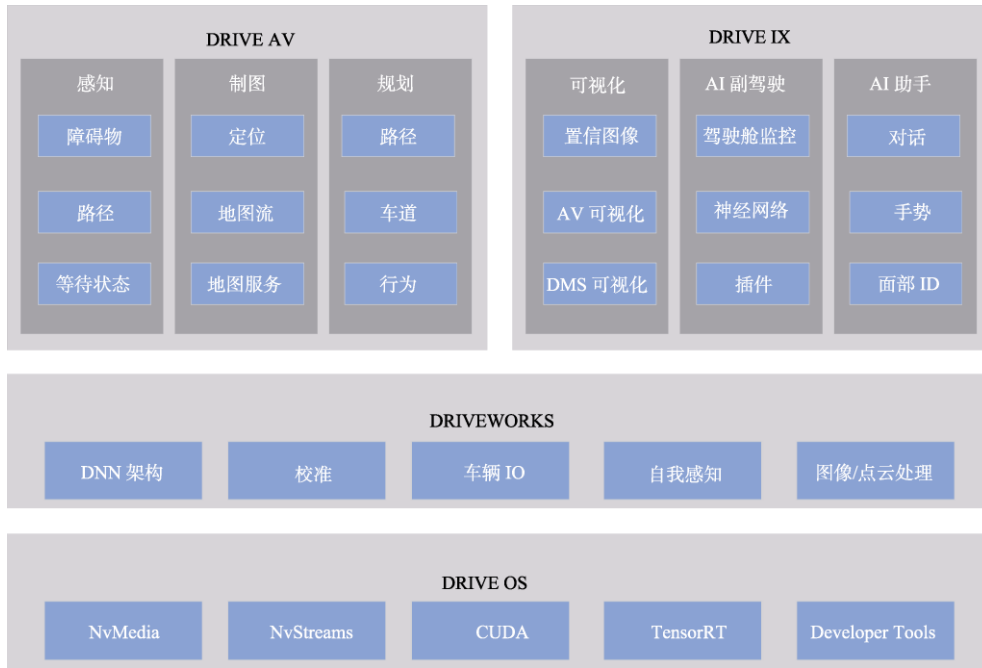


图 20 Nvidia DRIVE 软件堆栈的架构^[98]
 Fig. 20 Architecture of Nvidia DRIVE software stack

4.3 百度 Apollo 平台

2017 年 4 月，百度发布“Apollo”，为自动驾驶领域的研究人员和业界需求提供一个开放式软

件平台^[99]。同年 7 月，百度开放 Apollo1.0。截至目前，Apollo 平台已经更新至 5.5 版本，平台架构涵盖云端、软件与硬件，具体架构如图 21 所示。



图 21 百度 Apollo 平台架构^[100]
 Fig. 21 Structure of Baidu Apollo platform

4.3.1 开源软件平台

如图 21 所示，Apollo 的开源软件平台包括自动驾驶的感知、规划与控制部分。感知模块提供基于毫米波雷达/激光雷达点云数据对障碍物的检测，基于相机的红绿灯检测识别，对车辆进行多种传感器融合的高精度定位和基于运动的跟

踪。Apollo Cyber RT 是为 Apollo 自动驾驶一系列功能模块定制的开源运行框架，Apollo Cyber RT 采用高度集成的并行计算模型，能够实现任务执行的高并发、低延迟以及高吞吐量。针对自动驾驶业务场景的定制开发，使其能够满足自动驾驶解决方案的高性能要求^[100]。Apollo 规划模块能够

根据车辆通过传感器及 V2X 通信获得环境信息, 结合乘客乘车需求规划路径, 进行行为决策。其控制模块能够适配不同路况、不同车速、不同车型和不同的底盘交互协议^[100]。RTOS 由 Ubuntu 14.04+ApolloAuto/apollo-kernel 组成。

4.3.2 开源硬件平台

Apollo 开源硬件平台涵盖各类自动驾驶传感器 (GPS/IMU、毫米波雷达、激光雷达等)、汽车人机接口设备、传感器单元、扩展单元与车载计算单元等。其中, 传感器单元负责收集车载传感器信息, 并可通过与工控机通信实现对车辆的控制; 扩展单元允许使用者插入其他插件来增强 Apollo 的性能; 车载计算单元是整车实现功能的核心, 具有 CAN 总线接口和千兆以太网接口, 负责完成对自动驾驶各任务的计算。

5 深度学习应用挑战及发展方向

5.1 自动驾驶领域深度学习应用挑战

近年来, 深度学习迅速发展, 在图像处理、大数据分析、复杂博弈问题决策等问题中取得了一系列成果。然而, 由于车辆行驶环境变化多样, 面临的问题复杂且难以量化, 自动驾驶领域中深度学习的应用还面临着以下挑战。

5.1.1 系统计算速度与可靠性挑战

汽车在道路上的行驶速度限制了自动驾驶系统从感知到决策的时间, 要求自动驾驶系统的感知、决策和执行各个模块能够对所采集的各类信息进行实时处理。但随着自动驾驶软件系统的升级, 其计算量已经达到了 10~1000TOPS (每秒万亿次操作) 级别, 这对车载硬件的计算性能提出了很高的要求。而当前的车载硬件不能在性能、体积、噪声与散热问题上同时达到要求。媒体人在体验百度无人车时, 曾提到其位于车后部的计算设备的噪音与散热问题。因此, 要让自动驾驶汽车的安全性与舒适性都满足要求, 还需进一步提升车载硬件的性能。

5.1.2 信息安全挑战

信息安全是指保证计算机信息的完整性、保

密性以及可用性等。深度学习系统中的信息安全风险包括: (1) 数据传递阶段的入侵, 在深度学习系统不同模块间数据的传输过程中添加干扰, 造成传递信息的失真; (2) 利用“对抗样本”现象, 对原始数据添加微小扰动, 造成深度学习模型输出的明显转变; (3) 侵犯深度学习系统的模型与数据隐私等。在使用中, 深度学习系统需要满足保证用于驾驶的模型安全及数据隐私, 确保系统运行正常可靠。值得一提的是, 将区块链技术应用与车联网系统中以保证信息安全是当前的一个热门研究方向^[101]。

5.1.3 传统自动驾驶系统的复杂性挑战

传统的自动驾驶框架包括感知、决策、控制 3 个子系统, 每个系统内又包括许多不同的功能模块, 如目标检测、语义分割、融合定位等, 这使得其算法架构庞大臃肿。此外, 传统自动驾驶系统的层级架构使其在场景遍历广度上存在瓶颈, 难以处理复杂情况。

5.1.4 深度学习技术的可解释性挑战

可解释性是指解决某个问题的过程中获得足够可理解信息的能力^[99]。具体到人工智能领域, 可解释性指深度模型能够给出每一个预测结果的决策依据^[102]。深度学习技术在图像识别、语义分割及自然语言处理等领域获得了广泛应用, 并表现出了卓越的性能。然而深度学习技术的卓越表现更多依赖于模型高度的非线性和调参技术, 而其模型内部的学习进展及决策历程不可探知^[103]。也就是说, 模型的输出几乎是不可解释的。为了提高深度学习模型的可解释性, 需要探明黑盒结构的运行原理。目前, 提出的可解释性算法主要有以下几类^[103-104]。

(1) 内部可视化方法。

内部可视化方法是对模型内部学习的权重参数、神经网络的神经元或者特征检测器等进行可视化的方法。这类方法能够将模型的运算过程直观地展示出来, 但对可解释性的提高较小。Castanon 等^[105]采取将网络特征图在输入图像中可视化的方法, 观察图像的哪些部分会影响识别结果。

(2) 数据扰动测试方法。

基于鲁棒性扰动的方法尝试通过对输入数据添加扰动元素,观察模型输出结果的变化情况,分析扰动部分在模型处理过程中的重要程度。Koh 等^[106]提出了影响函数的概念,以影响函数定量地表示样本添加扰动后对结果的影响,从而理解深度学习模型行为。

(3) 建立可解释学习模型的方法。

近年来,一些研究人员尝试通过改进深度学习模型的构建方法或通过在其运行过程中迁入辅助解释模型的方式,来提高模型本身的可解释性。Sabour 等^[107]在 2017 年提出一种名为“胶囊”的张量神经元,并使用一组该神经元代替神经网络的一层,“胶囊”所输出向量的长度表征了某个实例(物体,视觉概念或者它们的一部分)出现的概率,其方向表征了物体的某些图形属性。该网络采取协议路由机制,每个胶囊能够编码一个特定语义的概念,从而可以清晰地知道每一个“胶囊”所做的工作,一定意义上增强了模型的可解释性^[104]。

5.1.5 深度学习模型的鲁棒性挑战

研究表明,尽管具有卓越的初始性能,深度学习模型却很容易对添加很小的扰动的样本(即对抗样本)产生误判。这大大限制了深度学习模型的应用范围与场景,同时也影响了其安全性。目前的模型鲁棒性分析方法主要分为两大类:精确方法可以获得精确的鲁棒性边界,但其计算复杂度很高,只能用于小规模的神经网络。一个典型算法是基于混合整数非线性规划(Mixed Integer Nonlinear Programming, MINLP)的方法,Cheng 等^[108]将鲁棒性边界定为可容忍的最大输入或传感器扰动,通过启发式算法与并行化技术大大减少了 MINLP 问题的计算量,并使用此算法计算了多个神经网络的鲁棒性边界;近似方法无法获得精确的鲁棒性边界,大多采取计算其下界的方式,近似方法的计算量较小,典型算法有基于区间传播的方法、基于概率的方法和基于控制论的方法等。

目前,提升模型鲁棒性的方法主要有以下几种:改变神经网络结构,如改变网络的深度、构

成或损失函数等;添加外部模块,借助具有所需功能的外部模块来提升网络的鲁棒性。但是,在现阶段,实现深度学习模型的完全鲁棒性是很困难的,以上几种方法都不能完全满足要求。

5.1.6 法律适用挑战

目前,在无人驾驶汽车法律规制方面我国的相关法规刚刚起步,无人汽车行驶的法规依据始终不明,存在国内对无人驾驶汽车上路合法化的法规依据问题,在我国法律“人-物”二分原则下无人驾驶汽车的归属认定问题^[109],同时这也是对现行汽车保险制度的挑战^[110]。事实上,自动驾驶汽车定责的法律问题相当复杂,不仅涉及到设计、制造、用户等之间的多重法律关系,还需要理清包括合同责任、侵权责任、产品责任等在内的一系列问题^[111]。

5.2 深度学习应用未来发展方向

深度学习的自动驾驶领域应用面临着许多挑战,但它也给车辆的智能化、网联化进程带来了巨大的机遇。Google 研发的无人汽车在汽车的感知、决策、控制系统中都广泛应用了深度学习算法。自动驾驶的快速发展不仅能实现巨大的经济效益,释放人力,避免人为事故,大大缓解交通拥堵,还将深刻改变汽车行业的布局,并推动其他领域人工智能的应用,如智慧城市、广泛物联网等。在未来,深度学习技术在自动驾驶领域的应用方面将具有如下发展趋势。

5.2.1 无监督/半监督学习

目前应用的深度学习模型大多采用监督学习方式训练,监督学习的方法需要对数据做出标签,为算法规定出一组“标准答案”,这不仅会大大增加人工成本,也严重依赖人为因素。而自动驾驶车辆所处的行车环境复杂多样,此外,受限于“长尾效应”,训练符合要求的自动驾驶系统所需的带标签数据量是巨大的。与此同时,在现代社会,大数据时代的到来使寻找大量数据变得越来越容易,因此标签依赖性低的无监督/半监督学习将是深度学习技术未来的发展趋势之一。

5.2.2 深度学习模型的并行化计算

深度学习可以提取材料中的抽象特征,完成

之前只能人工完成的任务,如语音识别、图像识别和检测等。传统避免过拟合的方法不能充分发挥硬件性能,这导致随着模型复杂度的提高训练时间会迅速增长。因此通过并行化计算加快深度神经网络模型的训练将是未来的发展方向,包括数据并行与模型并行。数据并行是指对训练数据做切割,使用多个模型同时使用所切分开的各个数据分块进行训练,数据并行需要参数交换器进行参数交换;而模型并行是指对训练模型进行切分,同时进行训练,当模型分块间出现数据交换时,产生通信开销。由于通信开销的存在,多数情况下,模型并行带来的速度收益低于数据并行。目前,多数选择是同时通过数据并行和模型并行加快训练。Google的Distbelief系统、百度的Paddle平台、腾讯的Mariana平台等都是这一探索的典型代表。不过,数据并行和模型并行都有并行数量的限制,如果并行数量太多,同步消耗和通信开销将急剧增加,使并行收益下降。

5.2.3 全自动神经网络

深度学习依靠深层神经网络自主拟合输入与输出间的映射关系,神经网络中各层的参数通过对训练集的学习获得。但神经网络的超参数依然需要人工调试,如神经网络的层数、每层神经元个数、学习率高低等。这些参数的选择对最终学习效果影响很大,然而这部分工作没有放之四海而皆准的规则,大多数时候依赖研究者的经验来完成。未来的深度神经网络应当也能够学习网络本身的超参数,如DeepMind提出的Learning to Learn算法^[112],神经网络能够同时学习,从而能更快收敛到理想精度。

5.2.4 量子计算与深度学习

量子计算是一种遵循量子力学规律调控量子信息单元进行计算的新型计算模式。量子计算机与传统计算机在所解决问题上并无不同,但量子力学叠加性的存在使其得计算效率大大提升,2020年12月,中国科学技术大学的研究人员使用量子计算机在200s内求解出了传统超级计算机需要耗费数十亿年才能完成的“高斯玻色取样”问题的计算。量子计算与深度学习的结合方式包括:

(1)利用量子计算强大的计算能力将深度学习中受限于计算能力的问题变为可能;(2)将量子理论的并行性于深度学习算法结合,建立一类量子深度学习模型,提高学习效率与准确度。不过,对量子计算的研究目前距离通用化实用化还有很大距离,在通用量子计算机研究成功之前,量子计算与深度学习的结合都将处于早期探索阶段。

5.2.5 5G车云协同与车路协同

2018年10月23日,湖南湘江新区智能系统测试区进行了基于5G的车路协同及车车协同的V2X应用测试,测试内容包括前向碰撞预警、逆向超车预警、紧急制动预警、变更车道盲区预警和紧急车辆提醒等多项场景。在自动驾驶等高级应用场景下,车联网要求网络时延在10ms以下且可靠性达到99.999%,4G网络因其技术限制,无法满足以上要求。而5G网络快速且稳定的数据通信能力能够极大增强智能车辆与交通系统的数据交流能力,5G网络能够为车辆提供毫秒级时延,最高10GB/s的传输速率,99.999%的可靠性,以及 $10^6/\text{km}^2$ 的超多连接数^[113]和容忍500km/h的移动,从而有效实现车路协同,扩大车辆的探测感知范围,有效弥补车辆传感器的不足,同时降低因传感器故障导致事故的概率,保障行驶的安全性。

自动驾驶与深度学习技术都处于快速发展成熟阶段,汽车驾驶是一个涉及人工智能、图像识别、机器视觉与模糊决策的综合应用场景,其发展方向必将受到以上多领域技术发展的深刻影响。但总的方向是解决深度学习算法在不同车型、不同驾驶风格、多样行驶问题下的多场景适配问题、硬件要求问题与算法稳定性、可解释性问题,实现汽车自动驾驶系统的安全性、稳定性、即时性与智能化。

6 结束语

得益于深度学习的助力,过去几年中自动驾驶技术快速发展,进一步向实用化迈进。深度学习方法的应用不仅体现在传统自动驾驶感知一规

划—执行方案的完善,还催生了能够直接从传感器数据映射到驾驶操作的端到端自动驾驶系统。但汽车自动驾驶系统是一个需要兼顾效率、成本与安全的复杂系统,深度神经网络的应用还面临着许多挑战,包括可解释性、信息安全问题、训练数据集构建等。深度学习在自动驾驶中的应用具有广阔的发展空间,但其技术走向成熟,实现大规模应用尚需时日。目前,不论是深度学习算法,还是自动驾驶技术都处于快速发展阶段,需要持续不断深入研究与应用验证。但毋庸置疑的是,在当今社会智能化网联化的趋势以及5G网络普及化的背景下,自动驾驶汽车具有巨大的发展潜力与光明的前景。本文对深度学习技术在自动驾驶感知、规划、控制模块与端到端驾驶系统中的应用进行了介绍,为基于深度学习的自动驾驶系统的进一步研究提供了参考。

参 考 文 献

- [1] 国家制造强国建设战略咨询委员会. 《中国制造 2025》重点领域技术创新绿皮书[M]. 北京: 电子工业出版社, 2016.
- [2] 工业和信息化部, 国家发展和改革委员会, 科学技术部. 汽车产业中长期发展规划[R]. 北京: 工业和信息化部, 国家发展和改革委员会, 科学技术部, 2017.
- [3] 中华人民共和国中央人民政府(2017). 国务院关于印发新一代人工智能发展规划的通知[EB/OL]. 2019[2021]. http://www.gov.cn/zhengce/content/2017-07/20/content_5211996.htm.
- [4] 中华人民共和国科学技术部(2018). 科技部关于发布科技创新 2030—“新一代人工智能”重大项目 2018 年度项目申报指南的通知[EB/OL]. 2018[2021]. http://www.most.gov.cn/fgwj/zfwj/zfwj2018/201810/t20181012_142132.htm.
- [5] 张新钰, 高洪波, 赵建辉, 等. 基于深度学习的自动驾驶技术综述[J]. 清华大学学报(自然科学版), 2018, 58(4): 438-444.
- [6] 王玉龙, 裴锋, 刘文如, 等. 基于开关式网络的拟人化自动驾驶决策算法[J/OL]. 中国机械工程:1-9. [2020-08-09][2021-02-07]. <http://kns.cnki.net/kcms/detail/42.1294.TH.20200710.1354.002.html>.
- [7] Grigorescu S, Trasnea B, Cocias T, et al. A survey of deep learning techniques for autonomous driving[J]. *Journal of Field Robotics*, 2020, 37(3): 362-386.
- [8] Fayyad J, Jaradat M A, Gruyer D, et al. Deep learning sensor fusion for autonomous vehicle perception and localization: A review[J]. *Sensors*, 2020, 20(15): 4220.
- [9] Ni J, Chen Y, Chen Y, et al. A survey on theories and applications for self-driving cars based on deep learning methods[J]. *Applied Sciences*, 2020, 10(8): 10.3390/app10082749.
- [10] Gwak J, Jung J, Oh R, et al. A review of intelligent self-driving vehicle software research[J]. *KSI Transactions on Internet and Information Systems*, 2019, 13(11): 5299-5320.
- [11] Hatcher W G, Yu W. A survey of deep learning: Platforms, applications and emerging research trends[J]. *IEEE Access*, 2018, 6: 24411-24432.
- [12] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. *Neural Computation*, 2006, 18(7): 1527-1554.
- [13] Bengio Y, Courville A, Vincent P. Representation learning: A review and new perspectives[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2013, 35(8): 1798-1828.
- [14] Yann L, Yoshua C, et al. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [15] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. *Advances in Neural Information Processing Systems*, 2014, 3: 2672-2680.
- [16] Li Y. Deep reinforcement learning[EB/OL]. 2018[2021]. <https://arxiv.org/pdf/1810.06339.pdf>.
- [17] 赵冬斌, 邵坤, 朱圆恒, 等. 深度强化学习综述: 兼论计算机围棋的发展[J]. *控制理论与应用*, 2016, 33(6): 701-717.
- [18] Gruyer D, Magnier V, Hamdi K, et al. Perception, information processing and modeling: Critical stages for autonomous driving applications[J]. *Annual Reviews in Control*, 2017, 44: 323-341.
- [19] Caselitz T, Steder B, Ruhnke M, et al. Monocular camera localization in 3D LiDAR maps[C]. 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Daejeon, Korea, October 9-14, 2016.
- [20] Cao L, Wang C, Li J. Robust depth-based object tracking from a moving binocular camera[J]. *Signal Processing*, 2015, 112: 154-161.
- [21] 高德芝, 段建民, 郑榜贵, 等. 智能车辆环境感知传感器的应用现状[J]. *现代电子技术*, 2008(19): 151-156.
- [22] 郑富瑜. 基于低成本二维激光雷达的自动移动机器人[D]. 广州: 广东工业大学, 2018.
- [23] 李朋. LFMCW 汽车防撞雷达信号处理及硬件实现[D]. 成都: 电子科技大学, 2016.
- [24] Livox. Horizon: High-performance LiDAR designed for L3/L4 autonomous driving[EB/OL]. 2020[2021]. <https://www.livoxtech.com/horizon>.
- [25] 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.
- [26] Redmon J, Farhadi A. YOLOv3: An Incremental Improvement [EB/OL]. 2018[2021]. <https://arxiv.org/abs/1804.02767>.
- [27] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[J]. *arXiv e-prints*, 2015(6): 2640-2650.
- [28] Choi J, Chun D, Kim H, et al. Gaussian YOLOv3: An accurate and fast object detector using localization uncertainty for autonomous driving[C]. *International Conference on Computer Vision*, Seoul, Korea, October 20-26, 2019.
- [29] Bochkovskiy A, Wang C, Liao H. YOLOv4: Optimal speed and accuracy of object detection[C/OL]. 2020-04-22[2021-02-07]. <https://arxiv.org/abs/2004.10934.pdf>.

- [30] Liu W, Anguelov D, Erhan D, et al. SSD: Single shot multibox detector[J]. ECCV 2016: Computer Vision, 2016: 21-37.
- [31] Jeong J, Park H, Kwak N. Enhancement of SSD by concatenating feature maps for object detection[C]. Proceedings of CVPR 2017, Hawaii, USA, July 21-26, 2017.
- [32] Fu C Y, Liu W, Ranga A, et al. DSSD: Deconvolutional Single Shot Detector[C/OL]. 2017-12-10[2021-02-07]. <https://arxiv.org/pdf/1701.06659.pdf>.
- [33] Yi J, Wu P, Metaxas D N. ASSD: Attentive single shot multibox detector[J]. Computer Vision and Image Understanding, arXiv: 1909.12456, 2019.
- [34] Li Z, Zhou F. FSSD: Feature fusion single shot multibox detector[EB/OL]. 2017[2021]. <https://arxiv.org/abs/1712.00960>.
- [35] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017(99): 2999-3007.
- [36] 张婷婷, 章坚武, 郭春生, 等. 基于深度学习的图像目标检测算法综述[J]. 电信科学, 2020, 36(7): 92-106.
- [37] 黄健, 张钢. 深度卷积神经网络的目标检测算法综述[J/OL]. 2020-08-22[2021-02-07]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20200727.1157.010.html>.
- [38] 罗元, 王薄宇, 陈旭. 基于深度学习的目标检测技术的研究综述[J]. 半导体光电, 2020, 41(1): 1-10.
- [39] Cui L, Ma R, Lv Pei, et al. MDSSD: Multi-scale deconvolutional single shot detector for small objects[J]. Science China (Information Sciences), 2020, 63(2): 98-100.
- [40] Girshick R, Donahue J, Darrelland T, et al. Rich feature hierarchies for object detection and semantic segmentation[C]. 2014 IEEE Conf. on Computer Vision and Pattern Recognition, Columbus, U.S.A, June 20-23, 2014.
- [41] Girshick R. Fast R-CNN[J]. Computer Science, 2015(4): 169-178.
- [42] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [43] He K, Gkioxari G, Dollar P, et al. Mask-RCNN[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2018(42): 386-397.
- [44] Dai J, Li Y, He K, et al. R-FCN: Object detection via region-based fully convolutional networks[C]. 2016 Advances in Neural Information Processing Systems, Barcelona, Spain, December 5-10, 2016.
- [45] Kong T, Yao A, Chen Y, et al. HyperNet: Towards accurate region proposal generation and joint object detection[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, June 26-July 1, 2016.
- [46] Gidaris S, Komodakis N. Object detection via a multi-region & semantic segmentation-aware CNN model[C]. 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, December 7-13, 2015.
- [47] Shrivastava A, Gupta A, Girshick R. Training Region-based Object Detectors with Online Hard Example Mining[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, June 26-July 1, 2016.
- [48] 张新明, 祝晓斌, 蔡强, 等. 图像语义分割深度学习模型综述[J]. 高技术通讯, 2017, 27(Z1): 808-815.
- [49] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), Boston, USA, June 7-12, 2015.
- [50] Vijay, Badrinarayanan, Alex, et al. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Scene Segmentation.[J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(12): 2481-2495.
- [51] Chen L C, Papandreou G, Kokkinos I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[J]. International Conference on Learning Representations, 2014(4): 357-361.
- [52] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.
- [53] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation[EB/OL]. 2017[2021]. <https://arxiv.org/abs/1706.05587v1>.
- [54] Lin G, Milan A, Shen C, et al. RefineNet: Multi-path refinement networks for high-resolution semantic segmentation[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Hawaii, USA, July 21-26, 2017.
- [55] Chen L C, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]. Proceedings of the European conference on computer vision (ECCV), Munich, Germany, September 8-14, 2018.
- [56] Romera E, Alvarez J M, Bergasa L M, et al. ERFNet: Efficient residual factorized convnet for real-time semantic segmentation[J]. IEEE Transactions on Intelligent Transportation Systems, 2017(1): 1-10.
- [57] Noh H, Hong S, Han B. Learning deconvolution network for semantic segmentation[C]. 2015 IEEE international conference on computer vision(ICCV), Santiago, Chile, December 7-13, 2015.
- [58] Paszke A, Chaurasia A, Kim S, et al. Enet: A deep neural network architecture for real-time semantic segmentation[EB/OL]. 2016[2021]. <https://arxiv.org/pdf/1606.02147.pdf>.
- [59] 吴琦, 于海靖, 谢勇, 等. 人工智能在自动驾驶领域的应用及启示[J]. 无人系统技术, 2019, 2(1): 23-28.
- [60] 慈文彦, 黄影平, 胡兴. 视觉里程计算法研究综述[J]. 计算机应用研究, 2019, 36(9): 2561-2568.
- [61] Helmick D M, Cheng Y, Clouse D S, et al. Path following using visual odometry for a Mars rover in high-slip environments[C]. 2004 IEEE Aerospace Conference, Big Sky, USA, March 6-13, 2004.
- [62] 刘瑞军, 王向上, 张晨, 等. 基于深度学习的视觉 SLAM 综述[J]. 系统仿真学报, 2020, 32(7): 1244-1256.
- [63] Konda K, Memisevic R. Learning visual odometry with a convolutional network[C]. Proc of International Conference on

- Computer Vision Theory and Applications, Berlin, 2015.
- [64] Liu Q, Li R, Hu H, et al. Using unsupervised deep learning technique for monocular visual odometry[J]. *IEEE Access*, 2019: 18076-18088.
- [65] Wang S, Clark R, Wen H, et al. DeepVO: Towards end-to-end visual odometry with deep recurrent convolutional neural networks[C]. 2017 IEEE International Conference on Robotics and Automation (ICRA), Singapore, May 29-June 3, 2017.
- [66] Jo H G, Kim E. New monte carlo localization using deep initialization: A three-dimensional LiDAR and a camera fusion approach[J]. *IEEE Access*, 2020(99): 1.
- [67] 姚君延. 基于深度增强学习的路径规划算法研究[D]. 成都: 电子科技大学, 2018.
- [68] 张广林, 胡小梅, 柴剑飞, 等. 路径规划算法及其应用综述[J]. *现代机械*, 2011(5): 85-90.
- [69] Grigorescu S, Trasnea B, Marina L, et al. Neurotrajectory: A neuroevolutionary approach to local state trajectory learning for autonomous vehicles[J]. *IEEE Robotics and Automation Letters*, 2019, 4: 3441-3448.
- [70] 肖浩, 廖祝华, 刘毅志, 等. 实际环境中基于深度Q学习的无人车路径规划[J/OL]. [2020-12-09][2021-02-07]. <http://kns.cnki.net/kcms/detail/37.1391.T.20201015.1717.002.html>.
- [71] Chaulwar A, Botsch M, Utschick W. A hybrid machine learning approach for planning safe trajectories in complex traffic-scenarios[C]. The 15th IEEE International Conference on Machine Learning, Anaheim, CA, USA, 2016.
- [72] Bai Z, Cai B, Shanguan W, et al. Deep learning based motion planning for autonomous vehicle using spatiotemporal LSTM network[C]. 2018 Chinese Automation Congress (CAC), Xi'an, China, November 30-December 2, 2018.
- [73] 李爱娟. 智能车辆运动轨迹规划方法的研究[D]. 南京: 南京航空航天大学, 2013.
- [74] Pfeiffer M, Schaeuble M, Nieto J, et al. From perception to decision: A data-driven approach to end-to-end motion planning for autonomous ground robots[C]. 2017 IEEE International Conference on Robotics and Automation (ICRA), Singapore, May 29-June 3, 2017.
- [75] Lin W, Li Z, Li L, et al. Parking like a human: A direct trajectory planning solution[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(12): 3388-3397.
- [76] Yu L, Shao X, Wei Y, et al. Intelligent land-vehicle model transfer trajectory planning method based on deep reinforcement learning[J]. *Sensors*, 2018, 18(9): 2905.
- [77] Du Z, Miao Q, Zong C. Trajectory planning for automated parking systems using deep reinforcement learning[J]. *International Journal of Automotive Technology*, 2020, 21(4): 881-887.
- [78] Loiacono D, Prete A, Lanzi P L, et al. Learning to overtake in TORCS using simple reinforcement learning[C]. IEEE Congress on Evolutionary Computation, Barcelona, Spain, July 18-23, 2010.
- [79] Sun M, Zhao W, Song G, et al. DDPG-Based decision-making strategy of adaptive cruising for heavy vehicles considering stability[J]. *IEEE Access*, 2020, 8: 59225-59246.
- [80] Zheng R, Liu C, Guo Q. A Decision-making method for autonomous vehicles based on simulation and reinforcement learning[C]. 2013 International Conference on Machine Learning and Cybernetics (ICMLC), Tianjin, China, July 14-17, 2013.
- [81] Fu Y, Li C, Yu F R, et al. A Decision-making strategy for vehicle autonomous braking in emergency via deep reinforcement learning[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(6): 5876-5888.
- [82] Volodymyr M, Koray K, David S, et al. Human-level control through deep reinforcement learning[J]. *Nature*, 2019, 518(7540): 529-533.
- [83] Chae H, Kang C M, Kim B D, et al. Autonomous braking system via deep reinforcement learning[C]. 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), Yokohama, Japan, October 16-19, 2017.
- [84] An H I, Jung J I. Decision-making system for lane change using deep reinforcement learning in connected and automated driving[J]. *Electronics*, 2019, 8(5): 543.
- [85] Ye Y, Zhang X, Sun J. Automated vehicle's behavior decision making using deep reinforcement learning and high-fidelity simulation environment[J]. *Transportation research*, 2019, 107: 155-170.
- [86] Shalevshwartz S, Shammah S, Shashua A. Safe, MultiAgent, Reinforcement Learning for Autonomous Driving[EB/OL]. 2016 [2021]. <https://arxiv.org/abs/1610.03295>.
- [87] Ostafew C J, Schoellig A P, Barfoot T D. Robust constrained learning-based NMPC enabling reliable mobile robot path tracking[J]. *The International Journal of Robotics Research*, 2016, 35(13): 1547-1563.
- [88] Lefevre S, Carvalho A, Borrelli F. A learning-based framework for velocity control in autonomous driving[J]. *IEEE Transactions on Automation Science & Engineering*, 2016, 13(1): 32-42.
- [89] Chen Y, Yuan Y, Bao S. Optimal control via neural networks: A convex approach[C]. 2019 International Conference on Learning Representations (ICLR), New Orleans, USA, May 6-9, 2019.
- [90] 薛建儒, 李庚欣. 无人车的场景理解与自主运动[J]. *无人系统技术*, 2018, 1(2): 24-33.
- [91] Pomerleau D, Alvin A. An autonomous land vehicle in a neural network[C]. *Neural Inform Proc Syst*, Denver, CO, USA, 1989.
- [92] Bojarski M, Del Testa D, Dworakowski D, et al. End to End Learning for Self-driving Cars [EB/OL]. 2020[2021].<https://arxiv.org/pdf/1604.07316.pdf>.
- [93] Lecun Y, Cosatto E, Ben J, et al. Dave: autonomous off-road vehicle control using end-to-end learning[R]. Technical Report DARPA-IPTO Final Report, Courant Institute: New York University, USA, 2004.
- [94] Eraqi H M, Moustafa M N, Honer J. End-to-end deep learning for steering autonomous vehicles considering temporal dependencies[C]. 2017 31st Annual Conference on Neural Information Processing Systems (NIPS), Long Beach, USA, December 4-9, 2017.
- [95] Sallab A, Abdou M, Perot E, et al. Deep reinforcement learning framework for autonomous driving[J]. *Electronic Imaging*,

- 2017(19): 70-76.
- [96] Satana E, Hotz G. Learning a driving simulator[EB/OL]. 2020[2021].<https://arxiv.org/pdf/1608.01230.pdf>.
- [97] NVIDIA (2020), NVIDIA DRIVE AGX[EB/OL]. 2020[2021]. <https://www.nvidia.cn/self-driving-cars/drive-platform/hardware/>.
- [98] NVIDIA (2020), NVIDIA DRIVE-Software[EB/OL]. 2020[2021]. <https://developer.nvidia.com/drive/drive-software#DRIVEOS>.
- [99] 张肇聿, 王一琳, 李志. 基于人工智能技术的 25 个行业发展趋势[J]. 无人系统技术, 2019, 2(1): 17-22.
- [100] Apollo (2020), apollo cyber RT framework[EB/OL]. 2020 [2021]. https://apollo.auto/cyber_cn.html.
- [101] 郎平, 田大新, 林椿昀. 区块链在车联网中的应用综述[J]. 无人系统技术, 2021, 4(1): 1-7.
- [102] Bao W, Yue J, Rao Y, et al. A deep learning framework for financial time series using stacked autoencoders and long-short term memory[J]. PLoS ONE, 2017, 12(7): e0180944.
- [103] 化盈盈, 张岱擢, 葛仕明. 深度学习模型可解释性的研究进展[J]. 信息安全学报, 2020, 5(3): 1-12.
- [104] 成科扬, 王宁, 师文喜, 等. 深度学习可解释性研究进展[J]. 计算机研究与发展, 2020, 57(6): 1208-1217.
- [105] Castanon G, Byrne J. Visualizing and quantifying discriminative features for face recognition[C]. 2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018), Xi'an, China, May 15-19, 2018.
- [106] Koh P W, Liang P. Understanding black-box predictions via influence functions[C]. 2017 34th International Conference on Machine Learning, Sydney, Australia, August 6-11, 2017.
- [107] Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules[C]. 2017 31st Annual Conference on Neural Information Processing Systems (NIPS), Long Beach, USA, December 4-9, 2017.
- [108] Cheng C H, Nührenberg G, Ruess H. Maximum resilience of artificial neural networks[C]. 2017 International Symposium on Automated Technology for Verification and Analysis (ATVA), Pune, India, October 3-6, 2017.
- [109] 吴桂珍. 无人驾驶汽车交通事故侵权责任问题研究[D]. 济南: 山东大学, 2019.
- [110] 王心钰, 张长青. 无人驾驶汽车的法律冲突探究[J]. 科技导报, 2017, 35(19): 11.
- [111] 刘学宽, 陈李丽. 浅谈产品责任的因果关系认定[J]. 山东审判: 山东法官培训学院学报, 2013, 29 (3): 93-95.
- [112] Wang J X, Kurth-Nelson Z, Tirumala D, et al. Learning to reinforcement learn[EB/OL]. 2021[2021]. <http://arxiv.org/abs/1611.05763>.
- [113] 张朝阳, 李星宏. 5G 在无人驾驶汽车中的应用前景分析[J]. 无人系统技术, 2019, 2(2): 65-68.

作者简介:



段续庭 (1986-), 男, 博士, 讲师, 主要研究方向为车联网与自动驾驶。本文通信作者。



周宇康 (1998-), 男, 硕士研究生, 主要研究方向为车联网与人工智能。



田大新 (1980-), 男, 博士, 教授, 主要研究方向为车联网与车路协同系统。



郑坤贤 (1996-), 男, 硕士, 工程师, 主要研究方向为自动驾驶与强化学习。



周建山 (1990-), 男, 博士, 工程师, 主要研究方向为车联网资源调度与优化。



孙亚夫 (1974-), 男, 硕士, 高级工程师, 主要研究方向为车路协同与自动驾驶。

[引用格式] 常晓飞, 蒋邓怀, 姬晓闯, 等. 无人作战系统仿真发展综述[J]. 无人系统技术, 2021, 4(6): 28-36.

无人作战系统仿真发展综述

常晓飞¹, 蒋邓怀², 姬晓闯², 符文星¹

(1. 西北工业大学无人系统技术研究院, 西安 710072; 2. 西北工业大学航天学院, 西安 710072)

摘要: 随着无人作战系统在当前复杂战场环境中的作战效益逐渐凸显, 无人作战系统的仿真研究工作逐渐受到各国研究学者的重视。介绍了无人作战与传统作战的区别, 分析得出无人作战系统仿真主要包含集群系统仿真与智能自主仿真两个方面。对于集群系统仿真, 分析了集群系统的建模方法、异构系统的模型接口和集群系统的仿真管理 3 个难点问题; 对于智能自主系统, 介绍了智能自主系统建模的主要方法、目前已有的智能自主算法以及智能自主仿真系统。最后, 结合当前无人作战系统的发展趋势, 提出了未来需要进一步加强在多域作战仿真实验、智能自主系统仿真试验鉴定、LVC 训练等方面的研究。

关键词: 无人作战系统; 集群系统; 智能自主系统; 建模与仿真; 人工智能

中图分类号: TJ765.4 **文献标识码:** A **文章编号:** 2096-5915(2021)06-28-09

DOI: 10.19942/j.issn.2096-5915.2021.6.052

Summary of Simulation Development of Unmanned Combat System

CHANG Xiaofei¹, JIANG Denghuai², JI Xiaochuang², FU Wenxing¹

(1. School of Astronautics, Northwestern Polytechnical University, Xi'an 710072, China;

2. Unmanned System Research Institute, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: With the combat effectiveness of unmanned combat system in the current complex battlefield environment, the research on simulation of unmanned combat system has gradually attracted the attention of scholars all over the world. This paper introduces the difference between unmanned combat and traditional combat, and analyzes that unmanned combat system simulation mainly includes cluster system simulation and intelligent autonomous simulation. For cluster system simulation, the modeling method of cluster system, model interface of heterogeneous system and simulation management of cluster system are analyzed. For intelligent autonomous system, the main methods of intelligent autonomous system modeling, existing intelligent autonomous algorithm and intelligent autonomous simulation system are introduced in this paper. Finally, combined with the current development trend of unmanned combat system, it is proposed that the research on multi domain combat simulation theory, intelligent autonomous system simulation test evaluation, LVC training and so on should be further strengthened in the future.

Key words: Unmanned Combat System; Cluster System; Intelligent Autonomous System; Modeling and Simulation; Artificial Intelligence

1 引言

无人系统由单个无人平台或多个无人平台构

成, 具备机械化、信息化和智能化等特征, 能够自主或通过远程操控完成指定任务。典型对象包括无人飞行器、无人车辆、无人舰船、无人潜航

收稿日期: 2021-07-07; 修回日期: 2021-08-16

基金项目: 国家自然科学基金青年基金(61503301); 陕西省自然科学基金(2019ZY-CXPT-03-02)

器等^[1]。随着信息技术、控制技术、人工智能技术的快速发展,无人系统在控制方式上朝着智能化方向发展;在作战规模上朝着集群化方向发展;在应用范围上向陆地、海洋、太空多域进行拓展^[2]。目前,无人系统已经逐步扩展到工业生产、社会治理、战场空间等领域,极大地改变了军事作战样式与社会生产生活方式^[3]。

仿真技术作为系统研制的重要手段,能够在可控的实验环境下开展可重复的试验验证,验证系统关键技术、考核关键技术指标、评估系统作战能力^[4]。因此,仿真与评估在无人系统的研制中依然发挥着重要作用,在美军在最新的《无人系统综合路线图(2017—2042)》中,将“用于自主系统的测试、评估、校核和验证(TEVV)新方法”作为未来的发展方向之一,将“自主性建模和仿真”作为涉及的关键技术之一^[5]。但随着无人作战系统朝着集群化和智能化方向发展,参战规模愈加庞大、任务平台愈加智能、战场环境愈加复杂、战场任务愈加多变、研制进度愈加紧凑,使得传统的试验方法和试验手段难以满足复杂条件下智能无人集群作战的仿真验证评估需求。

2 无人系统仿真面临的问题

无人系统作战是目前各个国家所推崇的作战思想与方式。区别于传统作战模式,一方面,无人作战系统表现为集群化,通过将传统单个完备作战平台所具备的各项功能,如侦察监视、电子干扰、打击与评估等能力分散到大量低成本、功能单一的作战平台中,通过大量异构跨域的个体来实现原本复杂的系统功能,甚至具备远超单一平台的作战能力。另一方面,无人作战系统表现为智能化,无须借助作战人员的指令导引,以高度智能为前提,实现人机协同、智能集群的作战方式,自主完成对战场复杂态势的统一认知、作战决策的分析计算以及作战任务的协调分配。

无人系统集群化和智能化的发展趋势对仿真评估技术提出了新的挑战。一方面,与传统作战

系统相比,无人集群系统的仿真节点逐渐增多,各仿真对象之间呈现异构性,这就给系统建模方法与模型间的接口问题提出了新的挑战,且仿真人员需要对集群系统内部的网络管理进行建模仿真。另一方面,在智能自主系统的仿真中,由于复杂作战环境下的对抗数据稀缺问题,对智能算法的数据提取方法提出了新的要求,作战平台的智能化对于仿真模型的建立、系统仿真的条件与试验环境也提出了全新的要求。

3 集群系统仿真

3.1 无人集群仿真的基本概念分析

无人集群最初是由无人机发展来的,在智能技术以及自组网技术的飞速发展后,美国DOD等将“无人机集群”扩展为“无人集群”,使得该概念能够涵盖海、陆、空、天等各个领域^[6],并逐步向跨域的混合集群方向发展。

由于无人集群系统通常是由异构跨域平台组成的集群网络,其仿真时面临集群系统的建模、异构仿真系统接入、复杂仿真网络管理等诸多问题。

3.2 无人集群仿真的研究现状

3.2.1 集群系统的建模

无人集群系统作为一种由大量实体组成的分布式网络系统,其仿真模型不仅包含了描述无人平台单体行为的运动模型、传感器模型、制导控制模型等,同时还包含了大量描述集群群体行为的网络模型、通信模型、避撞规则模型^[6]。

集群行为的最初建模工作是由生物学家完成的。生物数学家Parr于1927年在解释鱼群的内聚性现象时最先提出了群体中个体间的相互作用由引力、斥力引起的建模思想。

目前,随着建模仿真技术的不断发展,集群系统的建模已经逐渐成熟,出现了较多的建模方法,主要有动力学建模、蚁群优化算法、蜂群算法与狼群算法等智能算法。动力学建模属于自上而下的方法,通过分析系统架构建立微分方程,进而模拟、解释和预测系统在不同情况的变化行

为与趋势。目前,主要有拉格朗日法、欧拉法、仿真法与基于 A/R 作用的集群行为建模方法。近年来,主要使用的 SWARM 平台^[7]就是基于仿真的思想,建立一系列独立个体,通过独立个体之间进行交互,考察和研究系统的行为和演化规律。

蚁群优化算法 (Ant Colony Optimization, ACO) 是由 Dorigo 等在 20 世纪 90 年代提出来的^[8]。目前,基于 ACO 而建立的一系列模型主要都是采用信息激素变化实现问题空间的演化求解问题的。Wan 等^[9]针对基本蚁群算法在机器人路径规划中存在的搜索低、时间长等问题,对其进行改进,实现了更高效率的机器人最优路径搜索。吴鹏等^[10]针对传统的无人艇路径规划算法存在的问题,提出一种结合了势场蚁群算法与人工势场法的组合策略。

狼群算法最早由 Yang^[11]提出,算法基于狼群体智能、模拟狼群捕食行为及其猎物分配方式,抽象出游走、召唤、围攻 3 种智能行为以及“胜者为王”的头狼产生规则和“强者生存”的狼群更新机制。吴虎胜等^[12]基于狼群游走、召唤、围攻 3 种行为提出了狼群算法 (Wolf Pack Algorithm, WPA),头狼通过胜者为王机制产生,种族更新通过优胜劣汰实现,并用马尔科夫链理论验证了其收敛性良好。Chen 等^[13]利用改进的狼群算法,计算了旋翼无人机在真假三维空间内部的复杂三维空间中的准最优轨迹。

蜂群算法由 Karaboga^[14]于 2005 年提出,基本思想是启发于蜂群通过个体分工和信息交流,相互协作完成采蜜任务。赵晓林等^[15]为提高多无人机动态侦察分配效率与实时动态侦察的要求,利用改进的人工蜂群算法对其建立的动态侦察资源模型求解。王海泉等^[16]针对避障环境下的机器人的最优路径规划问题,提出一种基于改进蜂群算法的 3 次 Bezier 曲线优化的路径规划方法。

目前,各国对于集群系统的建模方法已经逐渐成熟且趋向于智能化,出现较多以个体研究为基础,之后再扩展到个体间的智能算法。近年来,群集智能的出现极大地促进了集群系统的建模仿真,但仍未进入成熟的阶段。由于其数学基础理

论薄弱,且实际应用于无人作战系统的算法类型不多,现在仍有许多问题需要进一步分析与讨论。

3.2.2 异构系统的模型接口

随着现代战争从集中式向分布式发展,传统的单一全功能平台将逐渐被多个单功能平台所取代,使得无人集群中的平台对象功能、研制厂家、模型接口均存在较大差异。因此,异构模型接口的标准化问题已经成为困扰集群异构仿真的重要问题。经过多年的发展,异构模型接口的标准化问题已经有了基于高层体系结构 (High Level Architecture, HLA)、统一建模语言与标准接口 (Functional Mockup Interface, FMI) 的 3 种解决模式。

HLA 的多领域建模仿真方法通过运行支撑软件 (Run Time Infrastructure, RTI) 提供通用的、相对独立的支撑服务程序,将仿真应用同底层的支撑环境分开,从而使各部分可以相对独立地进行开发。它克服了基于接口的方法开放性差、无统一标准、难以扩充等缺点^[17]。目前,基于 HLA 的建模仿真方法可以从对非 HLA 仿真系统的 HLA 兼容性改造、中间件技术和扩展联邦成员架构 3 方面入手。盛德号等^[18]对非 HLA 系统的兼容性改造进行了研究,提出了开发仿真对象模型 (Simulation Object Model, SOM)、开发 HLA 软件接口和使联邦成员独立于联邦成员对象模型 (Federate Object Model, FOM) 等方法。中间件技术通过通用的仿真系统框架中间件屏蔽了仿真应用层与仿真平台的实现细节,使仿真应用层的仿真模型组件能够在异构的仿真平台上运行,提高了仿真系统的重用性和互操作性。例如 SIMplicity、SimBulider、KD-SmartSim 等^[19]。龚建兴等^[20]提出可扩展联邦成员运行框架是可扩展联邦成员架构的核心部件,且通过实例构建可扩展的联邦成员架构,从而使联邦成员能够适应不同的联邦。

基于统一建模语言的多领域建模方法具有与领域无关的通用模型描述能力,对于任何确定了领域的,由于采用相同的模型描述形式,都可以实现统一的建模。Modelica 作为一种统一建模语

言, 目前得到广泛使用, 其采用数学方程描述不同领域的物理规律, 可以为任何能够用微分方程或代数方程描述的问题进行建模和仿真^[21]。目前, 较为成熟的是基于 Modelica 语言的仿真工具 Dymola 和 MathModelica。张慧静^[22]利用 Dymola 软件建立了包含电源、动力学和控制等分系统的卫星系统多领域仿真模型。华中科技大学^[23]基于 Modelica 语言建立了 MWorks 平台, 并由实现了在 MWorks 上与外部工具, 如 MATLAB/Simulink 模型进行集成。

Daimler AG 公司为解决异构模型标准化问题提出了 FMI 标准^[24], 该标准可以在不同建模仿真软件中设计出具有统一的模型格式和数据存储方式的模型, 且一个建模仿真软件设计出的模型可以在其他建模仿真软件上使用而不需要进行任何的更改。陆冠华等^[25]针对飞行器设计领域的异构模型问题, 提出采用 FMI 构建多源异构模型的通用通信接口, 从功能模型单元(Functional Mockup Unit, FMU)模型封装与联合仿真两方面, 给出了一种一体化仿真平台解决方案。徐东^[26]针对应用传统分析方法对于异构模型仿真出现的分析结果不准确问题, 提出一种基于 FMI 协议的跨领域多学科仿真系统建模分析方法, 此方法相比于传统方法, 可以得到更为准确的分析结果。

随着多域联合作战概念的不断深入, 异构模型接口问题逐渐成为建模仿真过程中的一大难题, 以上提出的 3 种方法由于其具备标准性、开放性、可扩充性以及支持分布式仿真等特点, 已经在各国得到了充分的应用。

3.2.3 集群体系的仿真管理

随着仿真节点的逐渐增多, 仿真系统也变得愈加复杂, 这就使得仿真人员在仿真过程中对复杂系统的管理提出了新的要求, 本节从对复杂集群仿真系统的时间管理、任务调度以及自组网网络仿真 3 方面展开论述。

对仿真系统的时间管理问题, 在本质上就是要始终确保将消息按顺序发送, 确保仿真执行的正确性与可重复性^[27]。对于时间管理机制, 连续系统最主要采用 HLA 保守时间管理协议, 离散系

统最主要采用的是保守时间推进机制与乐观时间推进机制^[28-29], 与在此基础上发展的受约束的乐观策略、混合策略和自适应策略等。这几种管理策略目前均在特定领域得到较好的实际应用。张翔等^[30]针对含有 DIS、TENA、HLA 的两种及两种以上的多体系结构仿真系统的结构特点, 对实时仿真与非实时仿真分别设计了时间管理方案。Huang 等^[31]提出一种为智能时间管理的代理接口, 可以用来统一 HLA 规范中时间步进、事件驱动和乐观时间推进的时间管理服务。

对仿真系统的任务调度问题, 实质上就是按照一定的规律将多个仿真任务映射至仿真节点上, 重新排列任务的执行顺序, 以符合任务间的相互依赖关系, 并获得最小调度长度^[32]。针对无人机分布式仿真系统, 目前主要采用功能分布式调度方式。该调度方式将命令与数据调度分开, 指令采用集中式调度, 数据则采用分布式调度方式。吴文波^[33]针对多核集群实时仿真系统的任务调度问题, 在遗传算法和模拟退火算法的基础上提出模拟退火算法以解决多核集群系统的网络流问题。Muthsamy 等^[34]为满足多个服务质量指标, 提出一种基于蜂群觅食优化的任务调度方法, 可以获得可用虚拟机的最有任务调度。

对于自组网网络仿真问题, 就是要保证在无人集群系统协同作战时, 多个个体之间要时刻保持互联通信。自组网技术无须固定基础设施, 网络的运行完全由节点自身实现, 能够满足无人集群系统的作战特点与要求。杜晓博^[35]针对由舰船、飞机等平台在海上形成的大规模军用自组织网络, 提出了一种联合仿真方法, 设计了基于连通度的分层分簇路由算法, 解决了其路由仿真工作面临的高计算复杂度和时间复杂度问题, 并通过仿真验证了该方法的可行性。Deng 等^[36]针对传统自组网路由协议存在局限性的问题, 提出一种改进的 CA-DSR 协议。该协议综合考虑利用编码机会、寻找最短路径和灵活地避免长路径时延等因素作为路由选择准则。

对于集群体系的仿真管理问题是当下的一个研究热点, 从本节可以看出, 目前各国研究学者

对此已经提出一些相对成熟的理论,但仍有许多亟待解决的问题。例如,如何更好地实现仿真系统负载均衡与跨平台仿真,以及对于时间推进机制算法中如何保证系统不会有过多的开销与运行成本等。开展集群体系的仿真问题研究对于提高仿真的实时性、可信性、可用性等具有重要意义。

4 智能自主系统仿真

4.1 智能自主系统仿真的基本概念分析

对无人系统而言,智能是指具备自动地获取和应用知识的能力、思维与推理的能力、问题求解的能力和自动学习的能力^[37]。而根据美军2017版《无人系统路线图》中提到的内容,自主是指一个实体根据对世界、自身和情况的了解和理解,自主地开发和选择不同的行动方案以实现目标的能力^[38]。自主性和智能性是智能无人系统最重要的两个特征,智能自主系统是一个具有高等级智能性的自主系统。

未来战争将向着深度信息化、智能无人化、网络体系化的方向发展,智能无人系统将成为未来战场的重要角色。智能自主系统的建模与仿真技术将以大数据资源、高性能计算能力、智能算法为基础,将新一代信息通信技术及各类应用领域专业技术深度融合,以提升仿真系统的整体智能化水平^[39]。

4.2 无人智能自主系统仿真的研究现状

4.2.1 智能自主系统建模

无人作战系统具有智能性、自主性,它是由多个智能个体组成的具有协同作战能力的复杂武器装备系统,对于智能仿真技术提出了全新的要求。随着建模仿真技术的不断发展,对于智能自主系统有很多的建模方法^[40],下面主要对基于Agent、大数据智能与深度学习的建模方法进行介绍。

基于Agent的建模仿真方法为作战模拟仿真提供了一种新方法。它是对复杂系统中基本元素及基本元素间相互作用的建模和仿真,将复杂系统中的微观行为和宏观涌现现象有机地结合,是

一种自顶向下分析、自底向上综合的建模方式^[41]。目前的热点课题主要是Agent的理论模型、多Agent系统(Multi-Agent System, MAS)及其开发应用。意大利热那亚大学 Bruzzone 等^[42]构建了一种基于Agent驱动的异构仿真环境。该环境包括UUV、水下潜艇平台、水面无人船和GPS卫星等仿真作战实体,实现对系统结构、管理过程和人为因素的综合分析。日本东海大学 Watanabe^[43]设计了一个通用化的MAS仿真支撑环境以及半实物仿真平台,可满足UUV系统的水声传感器、推进器、能源以及CCD相机测试工作。哈尔滨工程大学 Liu 等^[44]在BDI-Agent模型的基础上,借鉴神经生理结构模型,提出了包含感知区、反射区和慎思区的AUV心智模型,并通过多AUV编队穿越未知雷区的仿真试验验证了心智模型的有效性。

由于智能自主系统机理具有高度的复杂性,往往难以得到解析解,而需要大量实验与数据对其内部机理进行模拟与仿真。基于大数据智能的建模方法是利用海量观测与应用数据实现对不明机理的智能系统进行有效仿真建模的一类方法。王晓晔等^[45]基于数据聚类分析与利用神经网络进行权重的修正,提出了一种改进的K最近邻分类算法。同时,对于指数式增长的可用数据,可以采用基于深度学习的仿真建模方法,但深度学习高度依赖于数据的样本容量和标记精度,国内外学者在此基础上,结合强化学习,提出深度强化学习理论。Liu 等^[46]基于此方法,设计出战役级智能体训练系统。该系统提供分布式持续学习、大规模训练和计算存储资源等能力,为研究人机混合协作及群体智能涌现提供技术平台。

综上所述,随着人工智能技术的不断发展,仿真人员对于智能自主系统的建模方法正在向以机器学习为算法基础的智能化、数字化建模理论与方法发展,这些算法理论的出现可以有效提高智能自主仿真系统的可靠性。但是由于复杂作战系统数据的稀缺以及战场的不确定性,对机器学习算法提出较大的挑战,并且如何选择与优化机器学习算法以得到期望的模型也是仿真人员需要

解决的一个重要问题。

4.2.2 智能自主算法仿真研究

AI 是未来无人系统提高智能自主性的关键技术。无人系统的智能化主要体现在自主规划路径的能力、执行任务的自主决策能力和与系统内部的自主协作能力^[47]。为了更加快速有效地实现上述3种能力,不同的研究人员提出了不同的实现方式。

路径的自主规划能力是无人系统的第一个智能化趋势。目前的路径规划算法主要分为两类。一类是人为设置,例如A*算法、人工势场法、细胞分解法等。宋雪倩等^[48]提出利用Dubins曲线找到有效节点,结合A*启发式搜索的思想,分别为每架无人机离线构建由Dubins曲线组成的最短避障路径。另一类是系统个体根据自身所处的环境信息,实时规划路径的智能反应算法,例如遗传算法、蜂群算法、粒子群优化算法等。关震宇等^[49]提出一种基于路径的无人机的避障规划算法,采用遗传算法,结合无人机的飞行性能和最小转弯半径得到一种在已知障碍空间位置前提下的无人机路径规划方法。Xie等^[50]提出了布谷鸟算法在无人机探索三维环境尤其是战场环境中的应用,并且在解决三维空中路径规划问题中对布谷鸟算法进行优化。

对于任务的理解与决策能力是无人系统的第二个智能趋势。当面对复杂的任务时,无人系统不需要人为对其进行分配任务或做出决定,而是自主完成任务,是无人系统自主控制的关键技术和智能程度的体现。任佳等^[51]针对不确定环境下的任务决策问题,提出了基于的参数自适应推理算法实现在小样本观测下的动态任务决策,并着重讨论了专家认知程度不确定对该自适应推理算法的影响。赵振宇等^[52]以FRPNs结构实现规则推理,按照规则分析系统的推理过程,建立一种基于模糊推理Petri网的无人机智能决策方法,提高了无人机在动态不确定环境下的自主控制级别。孙楚等^[53]设计了基于连续动作控制变量的无人机机动决策方法,采用共用隐层的NRBF神经网络结构分别逼近效用值与动作控制变量,提出

了基于相对熵距离的神经网络隐层节点自适应构建方法。

无人系统内部可以由许多相同的和不同的个体组成,他们应该有能力和进行自主合作、消除冲突,通过相互配合、协作的作战方式执行任务,具有同时攻击多个敌方目标和能提高杀伤概率的优点。陈侠等^[54]针对多无人机协同打击的攻防博弈问题,建立了多无人机协同打击任务的攻防博弈模型,给出了 h 人有限策略静态博弈模型与纯策略纳什均衡的求解方法。马国欣等^[55]为实现多导弹协同攻击同一目标,提出一种法对于无角度约束和有角度约束的情况均适用时间协同分布式导引律设计方法。Yao等^[56]为解决多无人机在对抗环境下的风险问题,提出一种协同攻击任务分配算法,此算法可降低无人机群在后期的环境风险问题,且较遗传算法有更好的求解结果。

智能无人系统总体上还处于发展初期阶段,智能化是无人系统的重要发展方向。如何提高无人系统的智能自主水平是当下的研究重点^[57]。从目前研究结果可以看出,智能算法的应用有助于解决复杂系统的建模问题,并且将人工智能技术以及网络技术等引入到仿真系统,以此形成智能自主仿真系统是未来智能无人系统的研究重点。

4.2.3 智能自主仿真系统

自20世纪初,美国作为无人作战系统建设领先国家就开始开展无人作战装备智能化转型。随着人工智能技术与战争形态的不断发展,各国已将作战智能认知技术作为关键颠覆性领域,并对其未来发展做出长期规划。

2007年,美国国防预先研究计划局(DARPA)受到“深蓝”计算机在国际象棋比赛中战胜世界冠军加里·卡斯帕罗夫的启发,提出了一套“深绿”计划。深绿由“指挥员助手”人机接口系统、“闪电战”仿真系统和“水晶球”控制系统组成。DARPA利用动态数据驱动应用系统的基本思想,将仿真和实验/试验有机结合,使仿真可以在执行过程中动态地从实际系统接收数据并做出响应^[58]。

2016年6月,美国辛辛那提大学开发的Alpha AI人工智能与美国空军上校吉恩·李通过空战模

拟器对战, Alpha AI 大获全胜。在模拟空战中, 应用厄内斯特在辛辛那提大学开发出的名为“模糊遗传树”的算法, 实现了“动作及简单战术行为”, 凭借着快于人类 200 余倍的反应与计算速度, 最终在虚拟的模拟飞行对战中完胜对手^[59]。

2019 年 5 月, DARPA 发布空战演进 (Air Combat Evolution, ACE) 项目, 项目通过空中格斗的自动化和智能化来增强飞行员对战斗自主性的信任。ACE 采用自下而上的方式开发战斗自主性的性能及对自主能力的信任。如同训练飞行员一样, ACE 通过将空中格斗算法应用到难度和真实感不断增强的任务中来训练算法^[60]。该项目将自动空中格斗的战术应用到更复杂的、异构的、多飞机的战役级模拟场景, 为未来实时、战役级的马赛克战试验奠定基础。

圣塔菲研究所于 1994 年提出并开发的 Swarm 平台, 提供了实现建立基于 Agent 仿真模型的、可共享的基本对象类库以及运行基于 Agent 的仿真模型的控制引擎或虚拟机^[61]。澳大利亚 ADFA 开发了 RABBLE^[62], 采用 MAS 结构, 增加了学习机制, 使仿真群体行为利于决策。澳大利亚的 AOD 开发的 SWARM 和 Battle Model^[63], 可对空战中的飞行员、战斗机管理者、传感器管理者、空战防御指挥官以及地勤人员进行 Agent 建模。

此外, 由于国内对智能自主系统的研究起步较晚, 相比于美国还有很大的差距。目前, 各个高校与研究所之间联合协作也取得了一些成果。由北京理工大学人机交互课题组开发的 BitMod 系统, 采用面向对象的模块化设计, 可以完成自主模型的可视化创建及属性编辑等功能。由国防科学技术大学建立的 JCass 系统^[64], 是一个针对复杂系统的、采用基于 Agent 的建模与仿真方法的分布式仿真平台, 能够满足复杂系统和网络 Cluster 环境特点的要求, 且方便用户的使用。

5 结束语

在目前军事需求与技术进步的推动下, 无人作战系统的仿真研究工作处于快速发展的阶段。

本文从集群系统仿真与智能自主系统仿真入手, 分析其目前研究工作的主要难点, 并对其近年的发展概况进行总结。

随着建模仿真技术的不断发展, 无人作战系统的仿真会对无人作战系统的发展产生极大的推动作用, 是研究无人系统作战不可或缺的支撑手段与重要工具。根据查找相关文献, 以及作者自身在研究过程中的总结, 下面简要介绍未来可能的发展方向以及难点。

(1) 多域作战仿真理论需要进一步发展。对于多域作战这样的新兴概念, 需要建立一种与其形态相适应的指挥控制理论——多域多环嵌套理论, 构建多域作战指挥基本模式, 指导跨域作战指挥控制系统建设^[65]。并且多域作战空间的情报数据存在异构分散、碎片化、不连续和非结构化等问题, 特别是网络、电磁和太空目标的跨域信息融合尚处于空白阶段。未来对于多域作战仿真, 需要对这些认知领域也进行建模, 以尽可能还原作战场景。

(2) 转变对复杂无人作战系统的评估理念。面对无人作战这样的复杂系统, 传统的评估方法难以反映系统的自适应性、整体性、不确定性等特点, 另外, 传统方法的指标选择存在较强的主观性与片面性, 这样会导致评估结果的不准确与不合理。目前, 随着军事大数据与深度学习等方法的出现, 需要转变对体系能力评估理念的理解, 引入新的体系建模理论和效能评估方法。应大力发展以数据驱动为机理的评估方法, 将“指标树”转化为“指标网”, 探索体系能力微观与宏观之间的联系。

(3) 开展智能自主系统仿真试验鉴定技术。随着以深度学习为代表的机器学习研究的兴起, 使得人工智能、大数据与智能自主系统建模仿真之间的深度融合有了进一步的发展。对于智能自主系统仿真, 我国需利用各类新型仿真技术手段开展对于关键性技术的试验评估。通过集成各类仿真技术, 开展连续自主性仿真试验, 实现大样本并行仿真多种想定场景和测试无人自主系统的作战效能。

(4) 进一步重视 LVC 技术在军事训练领域的作用。LVC 技术通过将实装、仿真器、虚拟数字系统整合在一起,构建更加逼真和复杂的训练和复杂任务环境,能够更好地解决多系统融合仿真的难题,以及更好地模拟未来战争,应对未来多域联合作战的挑战。世界各国将 LVC 体系对抗仿真系统应用于军事演习,拓展了军事训练的手段方法,且极大地提升了战役战术联合训练水平。但目前 LVC 集成带来的互操作和安全性问题限制了各国充分利用其实现联合训练的潜力,未来需要进一步重视基于 LVC 的仿真与训练,提出解决现有问题的通用架构与方法。

参 考 文 献

- [1] 陈杰. 多智能体系统中的几个问题[J]. 科学中国人, 2019(12): 40-42.
- [2] 史志富. 智能无人系统集群作战技术发展分析[A]. 北京: 中国指挥与控制学会, 2019.
- [3] 吴勤. 无人系统发展及对国家安全的影响分析[J]. 无人系统技术, 2018, 1(2): 62-68.
- [4] 代耀宗, 沈建京, 郭晓峰. 作战效能评估方法研究[J]. 国防科技, 2017, 38(5): 104-109.
- [5] DOD. Unmanned Systems Integrated Roadmap, FY2017 – 2042[R]. Washington DC: DOD, 2017.
- [6] 刘立辉, 赵彦杰, 赵小虎, 等. 一种无人集群系统仿真平台设计[J]. 中国电子科学研究院学报, 2017, 12(5): 506-512.
- [7] GILES C K. A Framework for integrating the development of swarm unmanned aerial system doctrine and design[R]. Monterey, California: Department of Systems Engineering Naval Postgraduate School, 2017.
- [8] Dorigo M, Maniezzo V, Colomni A. The ant system: Optimization by a colony of cooperating agents[J]. IEEE Transactions on Systems, Man, and Cybernetics-Part B, 1996, 26(1): 29-41.
- [9] Wan X F, Hu W, Fang W Y, et al. Research on path planning of robot based on improved ant colony algorithm[J]. Computer Engineering and Applications, 2014, 50(18): 63-66.
- [10] 吴鹏, 周倩如, 余双, 等. 基于组合策略的无人艇路径规划方法[J]. 常州大学学报(自然科学版), 2020, 32(3): 47-52.
- [11] Yang X S. A new metaheuristic bat-inspired algorithm [M]. Nature Inspired Cooperative Strategies for Optimization. Berlin: Springer, 2010: 65-74.
- [12] 吴虎胜, 张凤鸣, 吴庐山. 一种新的群体智能算法—狼群算法[J]. 系统工程与电子技术, 2013, 35(11): 2430-2438.
- [13] Chen Y B, Mei Y S, Yu J Q, et al. Three-dimensional unmanned aerial vehicle path planning using modified wolf pack search algorithm[J]. Neurocomputing, 2017, 266: 445.
- [14] Karaboga D, Basturk B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony(ABC)algorithm[J]. Journal of Global Optimization, 2007, 39(3): 459-471.
- [15] 赵晓林, 张可为, 李宗哲, 等. 多无人机动态侦察资源分配问题研究[J]. 电光与控制, 2020(6): 11-15.
- [16] 王海泉, 胡瀛月, 廖伍代, 等. 基于改进人工蜂群算法的机器人路径规划[J]. 控制工程, 2016, 23(9): 1407-1411.
- [17] 陈晓波, 熊光楞, 郭斌, 等. 基于 HLA 的多领域建模研究[J]. 系统仿真学报, 2003(11): 1537-1542.
- [18] 盛德号, 邱小刚, 张柯. 对非 HLA 仿真系统的 HLA 兼容性改造的研究[J]. 计算机仿真, 2004(9): 97-100.
- [19] 龚建兴, 黄健, 郝建国, 等. 基于 HLA 的异构仿真系统的快速集成方法综述[J]. 系统仿真学报, 2009, 21(20): 6504-6509.
- [20] 龚建兴, 韩超, 邱晓刚, 等. 构建可扩展的 HLA 联邦成员架构[J]. 系统仿真学报, 2006(11): 3126-3130.
- [21] Peter F. Modelica-A language for equation-based physical modeling and high 59 performance simulation[M]. Applied Parallel Computing Large Scale Scientific and Industrial Problems. Berlin Heidelberg: Springer, 1998.
- [22] 张慧静. 基于 Modelica 的卫星多领域建模与仿真方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2009.
- [23] 吴紫俊, 赵建军. 多领域功能样机可交换模型规范实现研究[J]. 系统仿真学报, 2012, 24(10): 2083-2086.
- [24] 田红芳, 单立志, 李成功. 通用模型接口标准 FMI[C]. 2011 年信息技术、服务技术与工程管理国际学术会议, 北京, 2011.
- [25] 陆冠华, 郝明瑞, 胡松, 等. 基于 FMI 的飞行器分系统多源异构模型一体化仿真[J]. 导航定位与授时, 2018, 5(6): 99-104.
- [26] 徐东. 基于 FMI 协议的跨领域多学科仿真系统建模分析[J]. 电子测试, 2020(8): 34-36.
- [27] 王学慧, 张磊, 方粮. 复杂系统仿真中时间管理技术研究综述[C]. 系统仿真技术及其应用学术论文集(第 15 卷), 福建, 2014.
- [28] 周彦. HLA 仿真程序设计[M]. 北京: 电子工业出版社, 2002.
- [29] 李革. 并行与分布仿真系统[M]. 北京: 电子工业出版社, 2010.
- [30] 张翔, 李革, 王鹏. 多体系结构仿真系统的时间管理问题研究[C]. 第 18 届中国系统仿真技术及其应用学术年会, 兰州, 2017.
- [31] Huang J Y, Tung M C, Wang K M, et al. Smart time management—the unified time synchronization interface for the distributed simulation[J]. Computer Standards & Interfaces, 2005, 27(2): 149-161.
- [32] 潘玉林, 陈勇, 姚新宇, 等. 多层次分布实时仿真系统的静态调度策略[J]. 系统仿真学报, 2011, 23(1): 85-88.
- [33] 吴文波. 并行分布实时仿真平台任务调度技术研究[D]. 长沙: 国防科学技术大学, 2015.
- [34] Muthsamy G, Chandran S R. Task scheduling using artificial bee foraging optimization for load balancing in cloud data centers[J]. Computer Applications in Engineering Education, 2020, 28(4): 769-778.
- [35] 杜晓博. 大规模自组织网络路由联合仿真方法[J]. 舰船电子对抗, 2015, 38(2): 51-55.
- [36] Deng Y Z, Xiao Q L, Jun L W. A protocol for coding aware

- routing in Ad Hoc Network[C]. 12th IEEE International Conference on Communication Technology (ICCT), Nanjing, China, 2010.
- [37] 柳嘉润, 巩庆海, 翟雯婧. 智能自主系统及其航天控制应用[J]. 飞控与探测, 2018, 1(1): 59-62.
- [38] 李磊, 王彤, 蒋琪. 从美军 2042 年无人系统路线图看无人系统关键技术发展动向[J]. 无人系统技术, 2018, 1(4): 79-84.
- [39] 闫杰, 符文星, 张凯, 等. 武器系统仿真技术发展综述[J]. 系统仿真学报, 2019, 31(9): 1775-1789.
- [40] 李伯虎, 柴旭东, 张霖, 等. 面向新型人工智能系统的建模与仿真技术初步研究[J]. 系统仿真学报, 2018, 30(2): 349-362.
- [41] 王辉, 王坤福, 刘淑芬. 多 Agent 的作战模拟体仿真体系结构[J]. 吉林大学学报(理学版), 2015, 53(1): 101-106.
- [42] Bruzzone A G, Merani D, Massei M, et al. Modeling cyber warfare in heterogeneous networks for protection of infrastructures and operations[C]. European Modeling and Simulation Symposium, Athens, Greece, 2013.
- [43] Watanabe K. Design and fabrication of a small test-bed aimed for basin experiment of underwater multi-agent system[C]. Proceedings of UT07-SSC07, 2007.
- [44] Liu H B, Gu G C, Shen J, et al. AUV fuzzy neural BDI[J]. Journal of Marine Science & Application, 2005, 4(3): 37-41.
- [45] 王晓晔, 王正欧. K-最近邻分类技术的改进算法[J]. 电子与信息学报, 2005(3): 487-491.
- [46] Liu X, Lei J M, Shang L. Campaign level agent training system[J]. Command Information System and Technology, 2020, 11(3): 49-54.
- [47] 张涛, 李清, 张长水, 等. 智能无人自主系统的发展趋势[J]. 无人系统技术, 2018, 1(1): 11-22.
- [48] 宋雪倩, 胡士强. 基于 Dubins 路径的 A* 算法的多无人机路径规划[J]. 电光与控制, 2018, 25(11): 29-33.
- [49] 关震宇, 杨东晓, 李杰, 等. 基于 Dubins 路径的无人机避障规划算法[J]. 北京理工大学学报, 2014, 34(6): 570-575.
- [50] Xie C X, Zheng H. Application of improved cuckoo search algorithm to path planning unmanned aerial vehicle[C]. International Conference on Intelligent Computing, Nanning, 2016.
- [51] 任佳, 杜文才, 白勇. 基于贝叶斯网络自适应推理的无人机任务决策[J]. 系统工程理论与实践, 2013, 33(10): 2575-2582.
- [52] 赵振宇, 周锐, 池沛. 基于模糊推理 Petri 网的无人机智能决策方法[J]. 兵工自动化, 2015, 34(3): 71-73.
- [53] 孙楚, 赵辉, 王渊, 等. 基于强化学习的无人机自主机动决策方法[J]. 火力与指挥控制, 2019, 44(4): 142-149.
- [54] 陈侠, 李光耀, 赵谅. 多无人机协同打击任务的攻防博弈策略研究[J]. 火力与指挥控制, 2018, 43(11): 17-23.
- [55] 马国欣, 张友安. 多导弹时间协同分布式导引律设计[J]. 控制与决策, 2014, 29(5): 843-847.
- [56] Yao M, Zhao M. Cooperative attack strategy of unmanned aerial vehicles in adversarial environment[J]. Intelligent Automation & Soft Computing, 2013, 19(3): 487-496.
- [57] 郭行. 智能无人系统发展战略研究[J]. 无人系统技术, 2020, 3(6): 1-11.
- [58] 李风雷, 卢昊, 宋闯, 等. 智能化战争与无人系统技术的发展[J]. 无人系统技术, 2018, 1(2): 14-23.
- [59] Nicholas E, David C, Corey S. Genetic fuzzy based artificial intelligence for unmanned combat aerial vehicle control in simulated air combat missions[J]. Journal of Defense Management, 2016, 6: 1.
- [60] DARPA Air Combat Evolution (ACE) Proposers Day[EB/OL]. 2019[2020]. www.uasvision.com.
- [61] Swarm Development Group. A Tutorial Introduction to Swarm [EB/OL]. 2016[2020]. http://www.swarm.org/csss-tutorial/frames.html.
- [62] Darbyshire P, Abbass H, Barlow M, et al. A prototype design for studying emergent battlefield behaviour through multi-agent simulation[D]. Brac/Icddr B Joint Research Project, 2000.
- [63] Shoham Y. Agent-oriented programming[J]. Artificial Intelligence, 1993, 60(1): 51-92.
- [64] Li H L. The Agent-based distributed simulation for complex systems[D]. Changsha: National University of Defense Technology, 2001.
- [65] 张维明, 黄松平, 黄金才, 等. 多域作战及其指挥控制问题探析[J]. 指挥信息系统与技术, 2020, 11(1): 1-6.

作者简介:



常晓飞 (1983-), 男, 博士, 副教授, 主要研究方向为飞行器控制与仿真等。



蒋邓怀 (1997-), 男, 硕士研究生, 主要研究方向为飞行器控制与仿真等。本文通信作者。



姬晓闯 (1997-), 男, 硕士研究生, 主要研究方向为飞行器控制与仿真等。



符文星 (1974-), 男, 博士, 教授, 主要研究方向为飞行器制导与控制、飞行器先进仿真理论与仿真环境等。

[引用格式] 李 艳, 郭继峰, 罗汝斌. 基于遗传算法与 Dubins 理论的高速无人系统在多障碍环境中的路径规划[J]. 无人系统技术, 2021, 4(6): 37-45.

基于遗传算法与 Dubins 理论的高速无人系统在多障碍环境中的路径规划

李 艳¹, 郭继峰², 罗汝斌¹

(1. 北京宇航系统工程研究所, 北京 100074; 2. 哈尔滨工业大学航天学院, 哈尔滨 150001)

摘 要: 面向未来任意非结构化场景下的自主运行需求, 无人系统在多障碍环境下的快速避障能力尤为重要。针对该迫切需求, 提出了结合遗传算法与 Dubins 理论的满足无人系统运动约束的路径规划算法。算法首先考虑高速无人系统的运动约束, 设计出满足无人系统最小转弯半径约束、起始点与终止点速度矢量约束的 Dubins 路径, 然后使用遗传算法搜索在多障碍环境中的最短路径。在算法设计中, 对路径的编码方式做了深入的研究, 根据无人系统路径与环境障碍物的相切方式, 设计的路径编码方式可以有效编码无人系统路径与环境障碍物的位置关系, 使得其适合采用遗传算法求解。由仿真结果可见, 所提算法可在多障碍环境中求解出满足无人系统运动约束的最优路径。将为高速无人系统的大规模应用提供理论支撑。

关键词: 高速无人系统; 运动约束; 多障碍环境; 遗传算法; Dubins 曲线; 路径规划

中图分类号: V19

文献标识码: A

文章编号: 2096-5915(2021)06-37-09

DOI: 10.19942/j.issn.2096-5915.2021.6.053

Path Planning of High-speed Unmanned System in Multi-obstacle Environment Based on Genetic Algorithm and Dubins Theory

LI Yan¹, GUO Jifeng², LUO Rubin¹

(1. Beijing Institute of Aerospace System Engineering, Beijing 100074, China;

2. School of Astronautics, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Facing the autonomous operation requirements in any unstructured scenario in the future, the rapid obstacle avoidance ability of unmanned system in multi obstacle environment is particularly important. In response to this urgent need, a path planning algorithm combining genetic algorithm and Dubins theory to meet the motion constraints of unmanned systems is proposed. The algorithm first considers the motion constraints of the high-speed unmanned system, designs a Dubins path that meets the minimum turning radius constraint of the unmanned system, and the velocity vector constraints of the start point and end point, and then uses the genetic algorithm to search for the shortest path in a multi-obstacle environment. In the algorithm design, the encoding method of the path is studied in depth, and the designed path encoding method can effectively encode the position relationship between the path of the unmanned system and the environmental obstacles according to the tangency of the path of the unmanned system and the environmental obstacles, making it suitable for solving by genetic algorithm. It can be seen from the simulation results that the proposed algorithm can solve the optimal path that satisfies the motion constraints in a multi-obstacle environment. It will

收稿日期: 2021-07-10; 修回日期: 2021-08-19

基金项目: 航空科学基金 (20180577005)

provide theoretical support for the large-scale application of high-speed unmanned systems.

Key words: High-speed Unmanned System; Motion Constraint; Multi-obstacle Environment; Genetic Algorithm; Dubins Curve; Path Planning

1 引言

美国国防部 2018 年 8 月发布了《2017—2042 财年无人系统综合路线图》^[1]，对无人系统的发展提供了总体战略指南。在此路线图中，无人系统自主性作为 4 个关键主题内容之一，是美军近年来对无人系统重点布局的发展方向。而无人系统自主导航是实现无人系统高度自主性的关键技术。无人系统自主导航包括 4 个基本要求，即感知、定位、路径规划、运动控制，其中路径规划是最重要的部分之一。目前，无人系统的路径规划算法可以分为经典方法和启发式方法^[2-3]，如图 1 所示。

目前，主要的经典方法包括单元分解法 (Cell Decomposition Method, CD)、势场法 (Potential Field Method, PFM)、基于采样的方法 (Sampling-Based Method, SBP) 和 Dubins 算法。在 CD 中，机器人配置的自由空间被划分为称为单元的小区域，目标是提供一条无碰撞路径，以到达目标。基于该方法的机器人路径规划应用见文献[4-5]。在 PFM 中，障碍物和目标分别被赋予排斥力和吸引力，这样机器人就能够在远离障碍物的同时朝着目标移动^[6]。为了解决动力学环境中的路径规划问题，文献[7]中引入了对经典 PFM 的修改。SBP 算法的规划方案由于其在复杂的现实世界规划问题中的能力而受到相当大的关注。目前，应用最多的 SBP 算法包括概率路线图 (Probabilistic Route Map, PRM) 和快速探索随机树 (Rapid-exploration Random Tree, RRT)^[8]。尽管连接随机采样点的概念在这两种方法中都是基本的，但这两种方法在构建连接点的方式上是不同的。文献[9]对 SBP 的工作进行了全面调查。而 RRT 因其计算效率和有效性以及相对快速地找到可行运动计划的能力而受到了相当多的关注，即使在高维空间中也有一定的应用^[10]。上述方法把

机器人当作质点，未考虑其自身的运动约束以及由于其最小转弯半径对于避障带来的影响，而 Dubins 曲线是给定始末方向以及在转弯半径有约束的情况下两点之间的最短曲线，被广泛应用于自主机器人的路径规划中。文献[11]将 Dubins 算法应用到无人机的避障规划中，实现了无人机的实时避障规划。

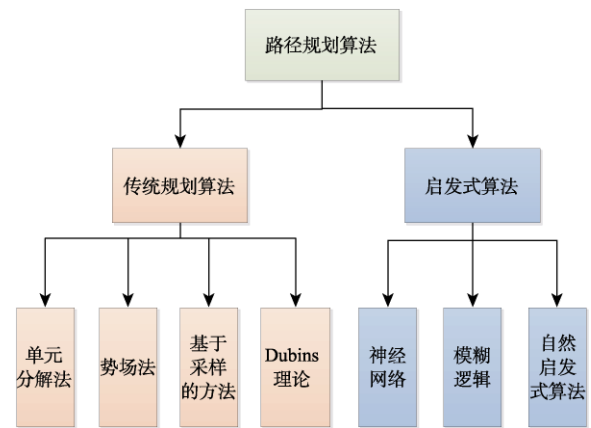


图 1 路径规划算法的基本分类

Fig. 1 Basic classification of path planning algorithms

然而，经典方法应用于实时运动规划时会有一定的缺陷，这些算法容易倾向于锁定在某些局部最优值中而忽略了全局最优路径。而且，它们中的一些可能无法在存在多个障碍物的环境中提供合适的解决方案。启发式方法解决了这一问题。

常用的启发式方法包括神经网络、模糊逻辑和自然启发法。神经网络由于具有非线性映射、学习能力和并行处理等优点，已成功地应用于机器人路径规划中^[12-13]。在模糊逻辑算法中，机器人导航是基于一组 if-then 规则。在文献[14-15]中，引入了基于模糊逻辑的不同方法来解决机器人路径规划问题。一些受生物学行为启发而广为人知的算法已成功地应用于机器人路径规划^[16]，如遗传算法^[11-15,17]、粒子群优化^[18]和蚁群优化^[19]。其中，遗传算法是一种基于自然遗传学的优化工具，

它利用了自然选择、交叉和变异等过程的优势, 在解决组合优化问题上具有很大的潜力。

本文结合遗传算法与 Dubins 理论, 提出了求解高速无人系统在多障碍环境下的路径规划算法。本文首先分别介绍了传统遗传算法和 Dubins 理论, 然后提出了基于遗传算法与 Dubins 理论的路径规划算法, 在算法设计中, 对路径的编码方式做了深入的研究, 使得其适合在多障碍场景中采用遗传算法求解满足高速无人系统运动约束的最优路径。

2 基本问题模型

2.1 遗传算法

遗传算法使用了群体搜索技术, 将种群代表一组问题的解, 通过对当前种群施加选择、交叉和变异等一系列遗传操作, 产生新一代的种群, 并逐步使种群进化到包含近似最优解的状态。遗传算法提供了一种求解复杂系统优化问题的通用框架, 它不依赖于问题的具体领域, 对问题的种类有很强的鲁棒性。该算法主要流程如图 2 所示。

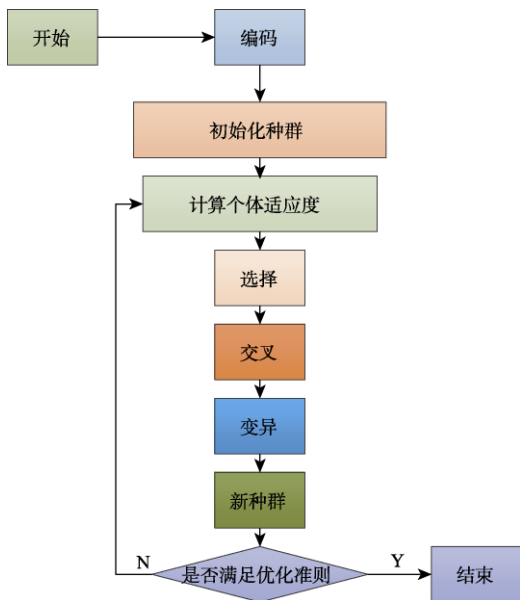


图 2 遗传算法基本流程
Fig. 2 Basic process of genetic algorithm

2.2 Dubins 理论

Dubins 于 1957 年提出了 Dubins 曲线理论,

主要内容是在满足一定曲率条件下, 连接同一平面内具有特定方向向量的任意两点的最短轨迹是曲线^[20]。在没有其他约束因素的情况下, 同一平面上的任意两点的最短路径是直线, 但是在有一定的曲率约束的情况下, 最短的路径则是圆弧。Dubins 曲线理论主要用来求解有曲率约束的最短路径。

通过选择两条与两个圆相切的切线中的一条, 可以得到 Dubins 路径, 其中起始和终止位置都在圆弧上。圆弧的半径是曲率半径, 它由无人系统的转弯半径决定, 圆弧中心就是曲率中心, 于是该问题就简化为寻找两个圆弧的公切线。两圆之间有两种公切线: 内切线、外切线。

在给定位姿点下, 无人系统可以向左转和向右转, 路径可以以顺时针方向和逆时针方向结束。一个给定的位姿点上有两种转弯方式, 因此有两个相切圆, 如图 3 所示。一个向右转弯, 在弧段 $C1$ 上标记 R , 另一个是向左转弯, 在弧段 $C2$ 上标记 L , 一个位姿点可以产生 4 条 Dubins 路径。即 LSL, LSR, RSL, RSR , 如图 4 所示。




图 3 相切圆
Fig. 3 Tangent circles

无人系统路径规划问题是指在已知环境下, 给定起点和终点, 使无人系统在一定的优化目标下无碰撞地由起点飞到终点。在这种情况下, 障碍的位置和大小是已知的, 无人系统的性能是已知的。在本文中, 最优目标是使无人系统的飞行路径最短。本文主要考虑的约束条件是无人系统的最小转弯半径。




图4 4种Dubins路径
Fig. 4 Four Dubins paths

3 基于遗传算法与Dubins理论的路径规划算法

本文提出基于遗传算法和Dubins原理的高速无人系统路径规划方法。其中，遗传算法用于求解最优路径，Dubins原理用于满足无人系统的约束条件。遗传算法可以解决多障碍环境下的路径规划问题，但其规划出的路径没有考虑无人系统最小转弯半径这一约束条件，大多数都是不可飞路径；基于Dubins理论的路径规划算法考虑了无人系统最小转弯半径的约束，求解得到的路径为可飞路径，并且还使得到达终点的速度方向可控，具有很高的实用性，但不能解决多障碍环境下的路径规划问题。将两者结合可得到一种有效解决多障碍环境下路径规划问题的方法，此方法使得规划出的路径平滑可飞，终点速度方向可控，其难点在于对路径的编码上，本文提出了一种针对障碍物的编码方式，有效地解决了上述问题。

3.1 针对障碍物的路径编码方式

在已知无人系统出发点 $P_s(x_s, y_s)$ 、初始速度方向 v_s ，终点 $P_f(x_f, y_f)$ 、终点速度向量 v_f ，最小转弯半径 R 和障碍圆模型 $D_k(k=1, 2, \dots, n)$ 的位置和大小的情况下，所求的路径是一条至少与 $l(l \in [0, n])$ 个障碍圆相切的曲线。则问题转化为求最短路径 $(C_s, C_f) = (C_s, W, C_f)$ 的问题，其中 W 是该路径遍历的各个障碍圆序列组成的集合，其中

有 l 个障碍圆与路径相切。编码方式要包含 W 中的所有可能，一种可行的编码方式是采用冗余二进制编码的方式^[11]。假设有4个障碍物，若要表示所有的情况则至少需要3位二进制编码。编码方式如表1所示。

表1 遗传算法编码表1
Table 1 Genetic algorithm coding table1

编码	含义	编码	含义
000	D_1	100	Blank
001	D_2	101	Blank
010	D_3	110	Blank
011	D_4	111	Blank

利用上述编码方式，可表示的一种路径的编码方式是(001, 100, 011, 111)，其表示的路径序列为(D_2 , Blank, D_4 , Blank)，则这种序列得出的路径为(C_s, D_2, D_4, C_f)，表示由起始点出发，先与第2个障碍圆相切，再与第4个障碍圆相切最后到达终点。这种编码方式只是给出了路径遍历障碍圆的顺序，并没有给出与障碍圆相切的方式，即这种编码方式给出的路径不唯一。为了使得到的路径唯一，本文将向曲线与圆的相切方式也加入到编码方式中。

考虑到有向曲线与圆的相切方式时，路径的编码方式将发生变化。每一个圆都有两种情况，圆在切线左边或者圆在切线右边，在编码时每个圆就有两种编码方式分别代表以上两种情况。根据以上方法对上述4个障碍圆编码，总共有12种情况，需要4位二进制编码。编码方式如表2所示。

表2 遗传算法编码表2
Table 2 Genetic algorithm coding table2

编码	含义	编码	含义
0000	D_1 在切线右边	1000	Blank
0001	D_1 在切线左边	1001	Blank
0010	D_2 在切线右边	1010	Blank
0011	D_2 在切线左边	1011	Blank
0100	D_3 在切线右边	1100	Blank
0101	D_3 在切线左边	1101	Blank
0110	D_4 在切线右边	1110	Blank
0111	D_4 在切线左边	1111	Blank

根据上述编码, 可表示的一条路径是(0000, 0100, 1111, 0111), 即路径序列为(D_1 , D_3 , Blank, D_4), 其表示的路径如图 5 所示。以上编码的路径只能保证路径不与障碍物 D_1 , D_3 与 D_4 发生碰撞, 并不能保证不与其他障碍物发生碰撞。在适应度函数的设计中, 通过增加碰撞检测解决这一问题。




图 5 障碍圆之间的 Dubins 路径
Fig. 5 Dubins paths between obstacle circles

3.2 适应度函数

本文所规划的路径是由起点到终点的无碰撞最短路径。所以, 适应度函数应该能满足无碰撞和最短这两个条件。本文采用路径长度的倒数作为目标函数, 在计算路径长度时, 若当前路径与障碍物相交, 则将当前路径的长度给一个较大值, 以保证所求路径与障碍物不相交。所设计的遗传算法适应度函数为

$$f = K \frac{1}{L} \quad (1)$$

式中, L 为路径的长度; K 为调节系数, 其主要是因为 L 的值远大于 1, 所以求得的适应度函数值非常小, 不利于种群的进化, 所以乘以一个与 L

同量级的数调节适应度函数的值, 保证种群的正常进化。

4 仿真实验

4.1 飞行环境建模

在高速无人系统执行任务的过程中, 将会面临敌方的探测雷达、拦截导弹、电子干扰等威胁, 这些威胁的作用范围一般为不规则的几何形状。在本文研究中, 为了统一威胁障碍建模, 方便计算, 将高速无人系统可能遇到的威胁障碍抽象为圆形模型, 即威胁障碍是以其中心点为圆心的圆形区域, 此圆形区域是包络威胁障碍的最小圆形区域。同时, 考虑到无人系统自身的体积大小以及导航制导控制系统带来的误差, 直接在上述圆形障碍物基础上进行避障将有一定的风险。基于安全性考虑, 我们在障碍物的大小上增加距离为 ΔR_s 的安全距离, 在增加安全距离之后, 障碍物的作用半径将增加至 $R^s(i) = R(i) + \Delta R_s$ 。安全距离 ΔR_s 的取值可根据无人系统的体积大小, 飞行速度, 导航制导控制系统误差等因素综合考虑。综上所述, 经过飞行环境建模之后的威胁区域半径 R_D 为:

$$R_D(i) = \max(r_{\min}, R^s(i)) \quad (2)$$

式中, $R_D(i)$ 为考虑高速无人系统最小转弯半径之后的第 i 个威胁障碍区域的半径; r_{\min} 为无人系统的最小转弯半径; $R(i)$ 为包络第 i 个威胁障碍区

表 3 考虑多种威胁的飞行环境建模

Table 3 Modeling the flight environment under multiple threats

威胁类型	威胁中心 x 方向 坐标/km	威胁中心 y 方向 坐标/km	威胁区域最小包络 圆半径 R /km	威胁区域半径 R_D /km	安全威胁区域半径 R_D^s /km
探测雷达-1	700	300	200	200	220
探测雷达-2	1250	500	200	200	220
探测雷达-3	1750	1200	200	200	220
探测雷达-4	500	1200	200	200	220
电子干扰-1	900	1500	150	173	173
电子干扰-2	2500	400	150	173	173
电子干扰-3	2000	800	200	200	220
电子干扰-4	1200	1000	150	173	173
拦截威胁-1	800	800	100	173	173
拦截威胁-2	1450	1500	150	173	173
拦截威胁-3	2500	1200	250	250	270

域的最小圆的半径。表 3 所示为一个考虑了多种威胁的飞行环境，最小转弯半径取值为 $r_{\min}=173$ km，安全距离取值为 $\Delta R_s=20$ km。

假设飞行器的起点为 (0, 500) km，终点为 (3000, 1000) km，根据上述步骤构建的飞行环境如图 6 所示。其中，红色多边形填充区域为各威胁的实际形状，红色实线圆表示包围实际威胁区域的最小包围圆，粉色点线表示考虑无人系统最小转弯半径之后的威胁圆，绿色虚线圆为增加安全距离之后的威胁圆。




图 6 包含多种威胁的飞行环境

Fig. 6 A flight environment with multiple threats

4.2 无人系统最小转弯半径

假设无人系统定高飞行，速度大小为 v ，受限的最大滚转角为 ϕ_{\max} ，受到的升力为 F_{lift} ，相应的最小转弯半径为 r_{\min} ，则无人系统在转弯时满足以下方程：

$$F_{\text{lift}} \sin \phi_{\max} = m \frac{v^2}{r_{\min}} \quad (3)$$

$$F_{\text{lift}} \cos \phi_{\max} = mg$$

根据上述方程，可以得到无人系统的最小转弯半径 r_{\min} 为：

$$r_{\min} = \frac{v^2}{g \tan \phi_{\max}} \quad (4)$$

式中， g 为重力加速度。

4.3 仿真结果

我们使用第 3 节提出的算法，在 4.1 节描述的飞行环境中规划无人系统从起始状态到终止状态的路径。所求飞行环境中，共有 11 个障碍物，每个障碍物需要 6 个二进制编码表示，所以共需

66 位二进制编码才能表示一条路径。初始种群大小设置为 500，最大进化代数为 50，交配概率为 0.95，变异概率为 0.1，选择步骤选用轮盘赌选择方式，交叉步骤选用单点交叉方式，变异步骤选用基本位变异方式。适应度函数中参数 K 的值设为 1000 km。假设无人系统的飞行速度为 1 km/s，最大滚转角为 30° ，根据式(4)可求得无人系统的最小转弯半径为 173 km。我们将本文提出的算法与两个传统算法进行对比，即 A*算法^[21]与基于 Dubins 曲线修正的 A*算法^[22]。A*算法是一种常用的路径搜索算法，用于在离散环境中搜索从起点到终点的最优路径，但其搜索出的路径由折线段构成，路径连接处不满足无人系统的运动约束条件，故不能单独用于具有运动约束的无人系统路径规划中。基于 Dubins 曲线修正的 A*算法对 A*算法搜索出的路径进行了平滑处理，使路径连接处满足无人系统的运动约束，使其可用于实际应用。

4.3.1 静态环境仿真

在上述静态环境中，进行了算法性能的对比如实验。对于每一种算法，在上述飞行环境中进行了 100 次随机实验，在每次实验中，固定障碍物不变，随机选取无人系统的初始状态以及终点状态，计算规划路径的长度。各算法性能对比结果如表 4 所示。

表 4 路径规划算法性能对比结果

Table 4 Path planning algorithm performance comparison results

算法名称	A*	A*+Dubins	GA+Dubins
路径长度/km	3399.1	4248.9	3467.1

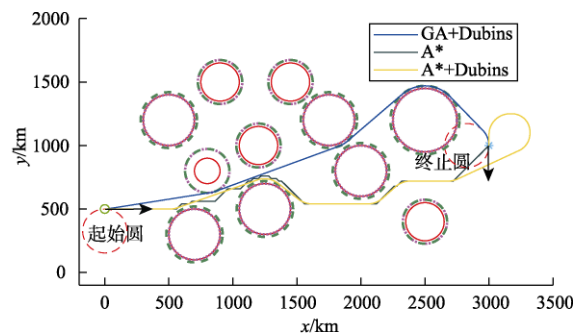
由表 4 可知，A*算法规划的路径最短，使用 Dubins 曲线修正的 A*算法规划的路径最长，基于遗传算法与 Dubins 曲线规划方法规划出的路径长度在两者之间。A*算法能够规划出最短的路径是因为其不考虑无人系统的运动约束，规划出的路径是由直线段连接而成的，无法满足无人系统的最小转弯半径，不可实际应用于高速无人系统的路径规划中。使用 Dubins 曲线修正的 A*算

法规划的路径最长,是由于其直接在 A*规划的路径上进行了修正,无法充分利用飞行环境的特征,只能求得次优解。而基于遗传算法与 Dubins 曲线的规划方法从全局考虑,结合无人系统的约束条件与飞行环境,将可行路径进行编码,使用遗传算法进行搜索求解,理论上在足够大的种群规模与迭代次数下,可以搜索得到最优解。一般规模的问题无须设置大规模种群与高迭代次数即可求解到最优解。通过以上性能对比实验结果分析可知,本文提出的算法可得到满足无人系统运动约束以及初始状态与终止状态约束的最短路径。


以下仿真实例直观地展示了各种规划算法的特点。仿真实验设置为:无人系统初始位置为(0, 500) km,初始速度为(1, 0) km/s,目标位置为(3000, 1000) km,目标速度为(0, -1) km/s,飞行环境中各威胁障碍均为静止状态。仿真结果如图 7 所示。

图 7(a)所示为在上述飞行环境中各算法所规划出的路径。蓝色实线为本文提出的基于遗传算法与 Dubins 曲线规划方法规划出的路径,路径总长为 3460.5 km,路径与 3 个障碍圆相切,同时在起始点与目标点处生成最小转弯半径圆,路径与起始圆以及终止圆相切,满足速度矢量约束。深绿色实线为 A*算法规划出的路径,路径长度为 3369.4 km。可以看出,虽然 A*算法可以规划出更短的路径,但路径由多条折线段构成,在路径连接处不够平滑,无法满足无人系统的运动约束,且在终点处没有满足速度矢量约束,故不能实际应用。黄色实线为在 A*算法规划的路径基础上经过 Dubins 曲线修正后的路径。经过 Dubins 曲线的修正,路径连接处由满足无人系统运动约束的圆弧连接,且在终点处通过圆弧连接直线路径,使规划出的路径满足终点速度矢量约束。通过以上修正过程,路径长度增加到 4208.1 km,长于基于遗传算法与 Dubins 曲线规划方法规划出的路径长度。

图 7(b)所示为基于遗传算法与 Dubins 曲线规划方法的迭代求解过程。曲线所示为种群的适应度函数值变化情况。由图中结果可知,种群的最大适应度与平均适应度在不断增大,表明种群朝着有利的方向进化,所求得的路径逐步变短,最



(a) 各算法所规划出的路径



(b) 基于遗传算法与 Dubins 曲线规划方法的迭代求解过程

图 7 静态环境仿真结果

Fig. 7 Static environment simulation results

后收敛到最短路径。

4.3.2 动态环境仿真

我们使用一次典型的仿真实验说明本文所提算法的动态避障过程。仿真场景设置为:无人系统初始位置为(0, 500) km,初始速度为(1, 0) km/s,目标位置为(3000, 1000) km,目标速度为(0, -1) km/s,飞行环境中探测雷达-2 向 y 轴正向按照 0.2 km/s 的速度运动。仿真结果如图 8 所示。

图 8 展示了基于遗传算法与 Dubins 曲线规划方法在动态环境中的避障过程。在 $t=0$ s 时,首先规划出一条从起始点到终点的路径,与图 8 所示结果一致。随着无人系统以及移动探测雷达-2 的持续运动,无人系统持续更新路径,在 $t=700$ s 时规划的路径如图 8(b)所示,可见由于探测雷达-2 的移动,无人系统在之前的路径上重新规划了新的路径。图 8(c)所示为在 $t=1010$ s 时规划的路径,此时无人系统仍然具有被探测雷达-2 发现的风险,因此规划的路径与其威胁圆相切。随着无人系统的运动以及探

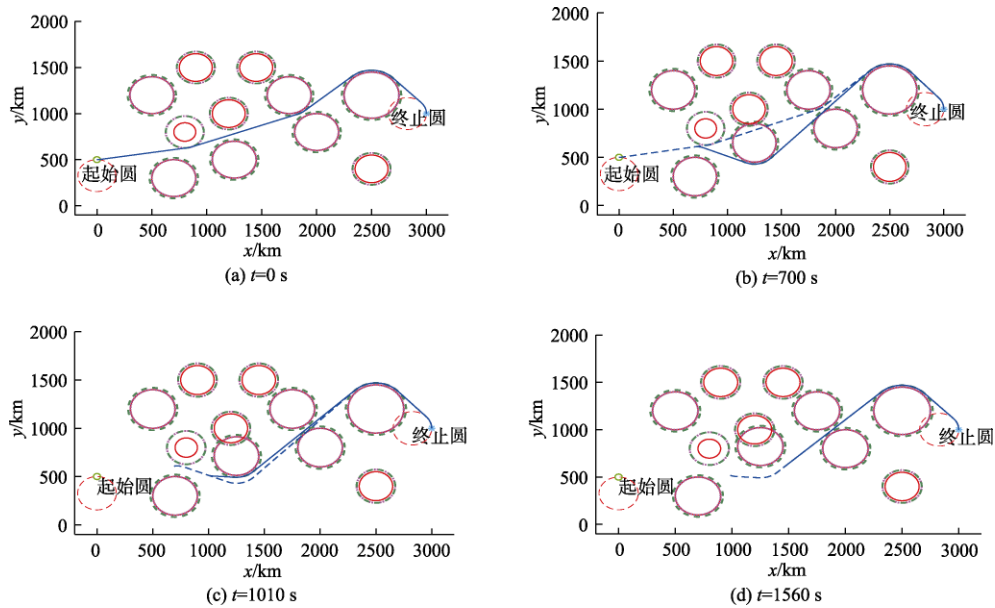


图8 动态环境仿真结果

Fig. 8 Dynamic environment simulation results

测雷达-2的运动,无人系统避开探测雷达-2的探测威胁,在 $t=1560\text{ s}$ 时规划的路径如图8(d)所示。根据以上仿真实例结果,说明基于遗传算法与Dubins曲线的规划方法可应用于动态环境中。

在实际应用中,一个关键问题是算法的实时性问题。而本文所提方法的复杂度与环境中的障碍物个数直接相关,其直接影响表示路径所需的二进制位数,障碍物越多,路径编码越长,运算时间也越长。为此,以下测试障碍物个数对算法实时性的影响。使用的测试平台为笔记本电脑,其CPU具有4个核心,基频为2.1 GHz。种群大小设置为500,最大进化代数为50。仿真结果如图9所示。从结果中可以看到,当障碍物个数小于20时,程序运行时间小于1 s,当障碍物个数等于30时,程序运行时间为1.8992 s。考虑到高速无人系统的运动速度为 km/s 级。因此,若能提前在数十公里外发现威胁障碍,则无人系统具有充足的时间进行规划,满足规划实时性需求。

5 结论

本文结合遗传算法与Dubins理论,提出了求解高速无人系统在多障碍环境下的路径规划算法。所提算法使用遗传算法搜索最短路径,Dubins




图9 算法运行时间测试结果

Fig. 9 Algorithm running time test results

曲线满足无人系统的约束条件。在算法设计中,对路径的编码方式做了深入的研究,使得其适合采用遗传算法求解。由仿真结果可见,所提算法可在多障碍环境中求得最短且平滑可飞的路径。本文在求解最优路径时,假定无人系统在二维平面内运动,没有考虑在三维空间运动的情景,后续将进一步研究求解三维空间中满足无人系统约束的最优路径的方法。

参考文献

- [1] Fahey K, Miller M. Unmanned systems integrated roadmap

- 2017—2042[R]. Department of Defense, 2017.
- [2] Masehian E, Sedighzadeh D. Classic and heuristic approaches in robot motion planning—a chronological review[J]. World Academy of Science, Engineering and Technology, 2007, 23(5): 101-106.
- [3] Mohanty P K, Parhi D R. Controlling the motion of an autonomous mobile robot using various techniques: A review[J]. Journal of Advance Mechanical Engineering, 2013, 1(1): 24-39.
- [4] Rosell J, Iniguez P. Path planning using harmonic functions and probabilistic cell decomposition[C]. Proceedings of the 2005 IEEE international conference on robotics and automation, Barcelona, Spain, 18 April, 2005.
- [5] Šeda M. Roadmap methods vs. Cell decomposition in robot motion planning[C]. Proceedings of the 6th WSEAS international conference on signal processing, robotics and automation, Corfu Island, Greece, 16 February, 2007.
- [6] 成昌巍, 胡劲文, 王策, 等. 基于改进型人工势场的路径规划方法[J]. 无人系统技术, 2019, 2(6): 10-16.
- [7] Zhang Q, Yue S G, Yin Q J, et al. Dynamic obstacle-avoiding path planning for robots based on modified potential field method[C]. International Conference on Intelligent Computing, Nanning, China, 28 July, 2013.
- [8] Lee J, Kwon O, Zhang L, et al. A selective retraction-based RRT planner for various environments[J]. IEEE Transactions on Robotics, 2014, 30(4): 1002-1011.
- [9] Elbanhawi M, Simic M. Sampling-based robot motion planning: A review[J]. IEEE Access, 2014, 2: 56-77.
- [10] Moon C B, Chung W. Kinodynamic planner dual-tree RRT (DT-RRT) for two-wheeled mobile robots using the rapidly exploring random tree[J]. IEEE Transactions on Industrial Electronics, 2014, 62(2): 1080-1090.
- [11] 关震宇, 杨东晓, 李杰, 等. 基于 Dubins 路径的无人机避障规划算法[J]. 北京理工大学学报, 2014, 34(6): 570-575.
- [12] 王延祥, 王宏伦, 吴健发, 等. 基于流体扰动算法与深度神经网络的无人机自适应路径规划[J]. 无人系统技术, 2020, 3(6): 50-58.
- [13] Dezfoulian S H, Wu D, Ahmad I S. A generalized neural network approach to mobile robot navigation and obstacle avoidance[J]. Advances in Intelligent Systems and Computing, 2013, 193: 25-42.
- [14] 俞旻旻, 吴超, 赵敏, 等. 重于水型 AUV 模糊路径规划与优化[J]. 舰船科学技术, 2017, 39(23): 76-80.
- [15] Abdessemed F, Faisal M, Emmadeddine M, et al. A hierarchical fuzzy control design for indoor mobile robot[J]. International Journal of Advanced Robotic Systems, 2014, 11(3): 33.
- [16] 秦小林, 罗刚, 李文博, 等. 集群智能算法综述[J]. 无人系统技术, 2021, 4(3): 1-10.
- [17] Alajlan M, Koubaa A, Chaari I, et al. Global path planning for mobile robots in large-scale grid environments using genetic algorithms[C]. 2013 International Conference on Individual and Collective Behaviors in Robotics (ICBR), Sousse, Tunisia, 15 December, 2013.
- [18] 郭世凯, 孙鑫. 基于改进粒子群算法的机器人路径规划[J]. 电子测量技术, 2019(3): 54-58.
- [19] 刘永建, 曾国辉, 黄勃, 等. 改进蚁群算法的机器人路径规划研究[J]. 电子科技, 2020, 33(1): 13-18.
- [20] Dubins L E. On curves of minimal length with a constraint on average curvature, and with prescribed initial and terminal positions and tangents[J]. American Journal of Mathematics, 1957, 79(3): 497-516.
- [21] 李晓辉, 苗苗, 冉保健, 等. 基于改进 A*算法的无人机避障路径规划[J]. 计算机系统应用, 2021, 30(2): 255-259.
- [22] 胡蕾, 高立娥, 刘卫东, 等. 基于 Dubins 曲线和改进 A*算法的 AUV 路径规划方法[J]. 计算机测量与控制, 2016, 24(8): 259-262.

作者简介:



李 艳 (1976-), 女, 硕士, 高级工程师, 主要研究方向为体系仿真与评估、体系任务规划。



郭继峰 (1977-), 男, 博士, 教授, 主要研究方向为智能感知与自主规划、智能无人系统等。本文通信作者。



罗汝斌 (1981-), 男, 硕士, 研究员, 主要研究方向为体系仿真与评估、体系任务规划。

[引用格式] 李 畅, 张 佳, 孙中奇, 等. 基于模型预测控制的无人车辆轨迹跟踪控制[J]. 无人系统技术, 2021, 4(6): 46-56.

基于模型预测控制的无人车辆轨迹跟踪控制

李 畅¹, 张 佳², 孙中奇^{1,3}, 夏元清¹

(1.北京理工大学自动化学院, 北京 100081; 2.中汽数据(天津)有限公司, 天津 300393;
3.北京理工大学长三角研究院(嘉兴), 嘉兴 314019)

摘 要: 针对无人驾驶车辆轨迹跟踪问题, 研究了基于模型预测控制的阿克曼转向结构车辆的运动控制方法。首先建立车辆的运动学模型, 同时给出相关约束; 在对模型进行线性化离散化处理后, 设计了模型预测控制器, 并进行了迭代可行性和系统稳定性分析; 考虑到参考轨迹的干扰与误差对乘坐体验的影响, 利用跟踪微分器对参考轨迹进行了滤波平滑处理。针对经典 MPC 控制器对变工况适应性差的问题, 提出了基于模糊控制的权重自适应 MPC, 并进行了数值仿真实验和实车控制实验。结果表明, 控制器可以完成轨迹跟踪任务, 并在不同工况下具有一定鲁棒性, 在控制性能和乘坐体验均比经典 MPC 控制器有所提高, 为未来无人车辆轨迹跟踪控制的研究提供了重要参考。

关键词: 模型预测控制; 轨迹跟踪; 无人车辆; 模糊自适应

中图分类号: TP13 **文献标识码:** A **文章编号:** 2096-5915(2021)06-46-11

DOI: 10.19942/j.issn.2096-5915.2021.6.054

Trajectory Tracking Control of Unmanned Vehicle based on Model Predictive Control

LI Chang¹, ZHANG Jia², SUN Zhongqi^{1,3}, XIA Yuanqing¹

(1. School of Automation, Beijing University of Technology, Beijing 100081, China;

2. Automotive Data of China (Tianjin) Co., Ltd., Tianjin 300393, China;

3. Yangtze Delta Region Academy of Beijing Institute of Technology, Jiaxing 314019, China)

Abstract: Aiming at the trajectory tracking problem of driverless vehicle, the motion control method of Ackermann steering structure vehicle based on model predictive control is studied. Firstly, the kinematics model of the vehicle is established, and the related constraints are given; After linearization and discretization of the model, the model predictive controller is designed, and the iterative feasibility and system stability are analyzed; Considering the influence of the disturbance and error of the reference trajectory on the ride experience, the tracking differentiator is used to filter and smooth the reference trajectory. Aiming at the poor adaptability of classical MPC controller to changing conditions, a weight adaptive MPC based on fuzzy control is proposed, and the numerical simulation experiment and real vehicle control experiment are carried out. The results show that the controller can complete the trajectory tracking task, and has a certain robustness under different conditions. The control performance and ride experience of the controller are improved compared with the classical MPC controller. This paper provides an important reference for future research on trajectory tracking control of unmanned vehicles.

Key words: Model Predictive Control; Trajectory Tracking; Unmanned Vehicle; Fuzzy Adaptive

收稿日期: 2021-07-03; 修回日期: 2021-08-12

基金项目: 国家自然科学基金(62003040)

1 引言

无人车辆是指通过搭载先进传感器装置, 运用人工智能等新技术, 具有自动驾驶功能, 逐步成为智能移动空间和应用终端的新一代汽车。随着 5G 通信技术^[1]、泛人工智能芯^[2]片、新型传感器等技术的成熟, 无人驾驶车辆越发成为热点研究方向。同时, 它被广泛认为是一种验证视觉、听觉、认知以及人工智能技术的通用实验平台^[3]。运动控制是无人车辆的核心技术之一, 高效精准的运动控制系统是智能无人车辆实现功能行为的重要保障。在运动控制领域, 应用比较成功的控制算法有: 比例积分微分控制^[4]、纯跟踪控制^[5]、预瞄控制^[6]、模糊控制^[7]、滑模控制^[8]、模型预测控制 (Model Predictive Control, MPC)^[9]及神经网络控制^[10-11]等。无人车辆自身有着非线性和欠驱动性^[12-13]、系统内外部存在诸多的约束条件。模型预测控制具有预测模型、滚动优化和反馈校正等基本特征, 具有全面考虑预测信息和处理多约束优化问题的能力, 被认为是最具应用前景的控制方法之一。

近年来, 模型预测控制得到了很快的发展, 产生了鲁棒模型预测控制算法、自适应模型预测控制算法^[14]、数据驱动模型预测控制算法和分布式模型预测控制算法^[15]等新方向。应用领域也从传统过程控制领域延伸到航空、车辆、交通、网络等众多应用领域。文献[16]设计了一种模型预测控制方法, 使车辆在满足其物理约束的情况下沿期望路径稳定行驶。龚建伟等^[17]介绍了模型预测控制在无人驾驶车辆运动控制的基础应用。但是大部分研究基于软件仿真实验和硬件在环仿真实验, 缺少实车实验验证和测试。无人驾驶车辆往往有乘客乘坐, 其乘坐体验是跟踪效果的重要考量。限于参考轨迹的质量、传感器的噪声和控制机器人性能, 实际实验中往往存在着方向盘高频抖动, 降低乘坐体验。由于经典模型预测控制器的成本函数中权重固定不变, 难以在变化工况下得到最佳控制效果。往往出现高速状态控制量变化大、直线游动、大曲率弯道跟踪误差大等现

象, 造成乘坐体验不佳、跟踪效果不佳。

本文首先通过机理分析建立了车辆的运动学模型。在对模型进行合理假设后进行了线性化和离散化处理。基于上述模型和无人车辆的物理结构约束、控制量约束, 设计了模型预测控制器, 并对控制器的迭代可行性和系统稳定性进行了分析。针对实际乘坐体验不佳的问题, 提出利用跟踪微分器处理参考轨迹的方法, 针对经典模型预测控制变化工况的适配问题, 提出了一种改进的 MPC 策略, 采用模糊自适应控制算法, 自适应的改变成本函数的权值。通过软件仿真, 验证了算法可行性。最后进行了实车实验, 测试了算法的控制效果、鲁棒性和可靠性。

2 问题描述

通过对无人车辆进行运动学分析, 得到无人车辆的运动学模型, 同时得到车辆物理约束、控制量约束, 给出了无人车辆轨迹跟踪问题的描述。

2.1 无人车辆运动学模型

无人车辆是具有非完整性约束的欠驱动系统。本文主要讨论的是具有阿克曼转向结构的无人车辆。车辆结构及转向原理如图 1 所示。车辆后轮驱动, 前轮转向, 由于阿克曼结构, 4 个车轮转向圆共点。 N 是车辆前轴中点, M 为后轴中点, φ 是车身横摆角 (航向角), δ_f 是前轴中心偏转角, v_f 是前轴中心速度, v_r 是后轴中心速度, L 是前后轴距。 R 是后轴中心转向半径, P 是车辆的瞬时转向中心。




图 1 车辆运动原理示意图

Fig. 1 Principle of vehicle motion

车辆运动学模型可进一步简化：仅考虑前后轴的中点 M 和 N ，并将两点连线看作车身，忽略车宽。通过分析可以得到车辆运动学方程^[17]：

$$\begin{bmatrix} \dot{X}_r \\ \dot{Y}_r \\ \dot{\varphi} \end{bmatrix} = \begin{bmatrix} \cos \varphi \\ \sin \varphi \\ \tan \delta_r / L \end{bmatrix} v_r \quad (1)$$

模型可以写成一般非线性形式：

$$\dot{\xi} = f(\xi, u) \quad (2)$$

式中，状态量 $\xi = [X_r, Y_r, \varphi]^T$ ，位置信息写作 $p = [X_r, Y_r]^T$ ，控制量 $u = [v_r, \delta_r]^T$ 。

2.2 无人车辆轨迹跟踪问题

无人车辆在轨迹跟踪过程中，需要尽快跟踪上参考轨迹，同时需要尽可能降低能量的损耗。在跟踪过程中，要满足车辆物理约束和跟踪问题约束。车辆的给定轨迹可以由状态信息来描述，状态信息满足系统动态方程，状态量和控制量满足约束：

$$\dot{\xi}_r(t) = f(\xi_r(t), u_r(t)) \quad (3)$$

$$u_r(t) = [v_r(t), \delta_r(t)]^T \in U \quad (4)$$

$$\xi_r(t) = \begin{bmatrix} X_r(t) \\ Y_r(t) \\ \varphi_r(t) \end{bmatrix} \in \mathbf{R}^2 \times (-\pi, \pi) \quad (5)$$

车辆实际的轨迹满足动态方程，状态量和控制量满足约束：

$$\dot{\xi}_f(t) = f(\xi_f(t), u_f(t)) \quad (6)$$

$$u_f(t) = [v_f(t), \delta_f(t)]^T \in U \quad (7)$$

$$\xi_f(t) = \begin{bmatrix} X_f(t) \\ Y_f(t) \\ \varphi_f(t) \end{bmatrix} \in \mathbf{R}^2 \times (-\pi, \pi) \quad (8)$$

定义跟踪误差：

$$\tilde{\xi} = [X - X_r, Y - Y_r, \varphi - \varphi_r]^T \quad (9)$$

轨迹跟踪问题可以描述为：在满足各类约束条件下，通过建立并求解优化问题得到最优控制量，控制车辆状态量跟踪误差 $\tilde{\xi}$ 收敛到零平衡点。

3 控制器设计

模型预测控制器主要由预测模型、目标函数

和约束条件组成，通过构建并求解最优化问题，从而得到最优控制量。本节首先对车辆运动学模型进行了线性离散化处理，然后适当简化设计了模型预测控制器。

3.1 运动学车辆模型线性化与离散化

非线性的模型预测控制带来了控制算法的设计难度，同时使得计算量增加，加大了计算机的计算负担，使得系统控制的实时性减低，可靠性减弱。所以本节首先对模型进行了线性化和离散化处理。给定轨迹始终满足式(3)，在任意点 (ξ_r, u_r) 处进行泰勒展开，保留一阶项，忽略高阶项得到：

$$\dot{\xi} = f(\xi_r, u_r) + \left. \frac{\partial f}{\partial \xi} \right|_{\xi=\xi_r} (\xi - \xi_r) + \left. \frac{\partial f}{\partial u} \right|_{u=u_r} (u - u_r) \quad (10)$$

将式(3)与式(10)做差，可以得到跟踪误差的状态方程：

$$\dot{\tilde{\xi}} = \begin{bmatrix} \dot{X} - \dot{X}_r \\ \dot{Y} - \dot{Y}_r \\ \dot{\varphi} - \dot{\varphi}_r \end{bmatrix} = \begin{bmatrix} 0 & 0 & -v_r \sin \varphi_r \\ 0 & 0 & v_r \cos \varphi_r \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} X - X_r \\ Y - Y_r \\ \varphi - \varphi_r \end{bmatrix} + \begin{bmatrix} \cos \varphi_r & 0 \\ \sin \varphi_r & 0 \\ \tan \delta_r / L & v_r / (L \cos^2 \delta_r) \end{bmatrix} \begin{bmatrix} v - v_r \\ \delta - \delta_r \end{bmatrix} \quad (11)$$

对连续的状态方程(11)进行离散化得到线性离散状态方程：

$$\tilde{\xi}(k+1|t) = A_{k,t} \tilde{\xi}(k|t) + B_{k,t} \tilde{u}(k|t) \quad (12)$$

$$A_{k,t} = \begin{bmatrix} 1 & 0 & -v_r \sin \varphi_r T \\ 0 & 1 & v_r \cos \varphi_r T \\ 0 & 0 & 1 \end{bmatrix} B_{k,t} = \begin{bmatrix} \cos \varphi_r T & 0 \\ \sin \varphi_r T & 0 \\ \frac{\tan \delta_r T}{L} & \frac{v_r T}{L \cos^2 \delta_r} \end{bmatrix} \quad (13)$$

式中， T 是采样时间， L 是车辆轴距。

3.2 预测模型设计

误差系统的离散状态方程由式(13)可知。已知当前时刻的实际状态量，利用状态方程，我们可以滚动预测未来一段时间的状态量。为了简化计算，假设单次迭代过程中系统方程和输入方程不变，即：

$$A_{k,t} = A_{t,t}, B_{k,t} = B_{t,t}, k=1,2,\dots,N-1 \quad (14)$$

简化后的系统方程可以表示为:

$$\dot{\tilde{\xi}}(t) = A_t \tilde{\xi}(t) + B_t \tilde{u}(t) \quad (15)$$

控制器的预测模型可以表示为(N 是预测时域):

$$\tilde{\xi}(t) = \psi_t \tilde{\xi}(k|t) + \Theta_t \tilde{U}(t) \quad (16)$$

$$\tilde{\xi}(t) = \begin{bmatrix} \tilde{\xi}(t+1|t) \\ \tilde{\xi}(t+2|t) \\ \dots \\ \tilde{\xi}(t+N|t) \end{bmatrix}, \psi_t = \begin{bmatrix} A_t \\ A_t^2 \\ \dots \\ A_t^N \end{bmatrix}, \tilde{U}(t) = \begin{bmatrix} \tilde{u}(t|t) \\ \tilde{u}(t+1|t) \\ \dots \\ \tilde{u}(t+N-1|t) \end{bmatrix} \quad (17)$$

$$\Theta_t = \begin{bmatrix} B_t & 0 & 0 & 0 \\ A_t B_t & B_t & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots \\ A_t^{N-1} B_t & A_t^{N-2} B_t & \dots & B_t \end{bmatrix} \quad (18)$$

3.3 目标函数设计

目标函数要同时反映跟随能力和控制量变化和系统的终端成本。采用如下形式的目标函数:

$$J(k) = \sum_{j=1}^N \tilde{\xi}^T(k+j|k) Q \tilde{\xi}(k+j|k) + \sum_{i=1}^{N-1} \tilde{u}^T(k+i) R \tilde{u}(k+i) + g(\tilde{\xi}(k+N)) \quad (19)$$

式中, N 是预测时域, $\sum_{j=1}^N \tilde{\xi}^T(k+j|k) Q \tilde{\xi}(k+j|k)$ 是

误差项, 表征了系统对参考轨迹的跟踪能力,

$\sum_{i=1}^{N-1} \tilde{u}^T(k+i) R \tilde{u}(k+i)$ 表示控制量的变化表征控制

的平稳性, $g(\tilde{\xi}(k+N))$ 是终端成本, 和算法的迭代可行性和系统稳定性有关。

3.4 约束条件设计

对于实际的控制对象, 有着多种约束, 对于本节建立的控制器的主要的约束是控制量极限约束和状态量极限约束。形式是:

$$\begin{aligned} \mathbf{u}_{\min}(t+k) \leq \mathbf{u}(t+k) \leq \mathbf{u}_{\max}(t+k), k=0 \sim N-1 \\ \xi_{\min}(t+k) \leq \xi(t+k) \leq \xi_{\max}(t+k), k=0 \sim N-1 \end{aligned} \quad (20)$$

4 迭代可行性与稳定性分析

本节将对模型预测控制器的迭代可行性和

稳定性进行简要的说明。模型预测控制可行, 意味着在 t_k 时刻优化问题可以解得一个优化控制序列 $\mathbf{u}_f^*(t_k)$, 采用该优化控制序列控制无人车辆可以使其沿着一条在 t_k 时刻的最优轨迹 $\xi_f^*(\tau|t_k), \tau \in [t_k, t_k+T]$ 进入终端集 $\mathbf{p}_e^*(t_k+T|t_k) \in \Omega$ 中。稳定意味着代价函数不递增, 状态最终收敛到平衡点。分析中涉及不同含义的控制量和状态量, 在此进行说明:

$(\tilde{\xi}(t), \tilde{u}(t))$ 是实际车辆的状态量和控制量;

$(\tilde{\xi}^*(t), \tilde{u}^*(t))$ 是求解得出的最优预测状态量和最优控制量;

$(\bar{\xi}(t), \bar{u}(t))$ 表示的是构造出的可行状态和可行控制量。

系统动态方程由式(15)给出。在式(15)可稳定的条件下, 在终端区域内可以确定线性状态反馈控制器: $\tilde{u}(t) = K \tilde{\xi}(t)$ 使得 $A_{k,t} = A_k + B_k K$ 是渐进稳定的^[18]。

控制器求解的最优问题可以如下:

$$\min_{\tilde{u}(\tau|t_k)} J(\tilde{\xi}(t), \tilde{u}(\cdot)) \quad (21)$$

$$J(\tilde{\xi}(t), \tilde{u}(\cdot)) = \int_t^{t+NT} (\|\tilde{\xi}(\tau)\|_Q^2 + \|\tilde{u}(\tau)\|_R^2) d\tau + \|\tilde{\xi}(t+NT)\|_P^2 \quad (22)$$

$$\dot{\tilde{\xi}} = f(\tilde{\xi}, \tilde{u})$$

$$\tilde{u}(\tau) \in \mathbf{U} \quad \tau \in [t, t+NT]$$

$$\tilde{\xi}(t+NT) \in \Omega$$

式中, Q, R 阵为加权矩阵, N 是预测时域, T 是采样控制周期, Ω 是终端区域。 $\int_t^{t+NT} (\|\tilde{\xi}(\tau)\|_Q^2 + \|\tilde{u}(\tau)\|_R^2) d\tau$ 是有限层控制成本, $\|\tilde{\xi}(t+NT)\|_P^2$ 是惩罚有限层末端状态的终端成本, 满足:

$$\|\tilde{\xi}(t+NT)\|_P^2 \geq \int_{t+NT}^{\infty} (\|\tilde{\xi}(\tau)\|_Q^2 + \|\tilde{u}(\tau)\|_R^2) d\tau \quad (23)$$

定理 4.1: 假设线性化后的系统(15)在原点是可稳定的^[18]。那么有以下结论:

(1) Lyapunov 方程

$$(A_{K,t} + \kappa I)^T P + P(A_{K,t} + \kappa I) = -Q^* \quad (24)$$

对于正定对称 $Q^* = Q + K^T R K \in \mathbf{R}^{n \times n}$ 存在唯一正

定对称解 P , 其中 $\kappa \in [0, \infty)$ 且 $\kappa < -\lambda_{\max}(A_K)$ 。

(2) 存在一个常数 $\alpha \in (0, \infty)$ 来指定一个原点的邻域:

$$\Omega_\alpha = \{ \tilde{\xi}_t \in \mathbf{R}^n \mid \tilde{\xi}_t^T P \tilde{\xi}_t \leq \alpha \} \quad (25)$$

式中, $K\tilde{\xi}_t \in U$, 该线性反馈控制器在 Ω_α 内满足控制量约束。 Ω_α 在控制器 $\tilde{u}(t) = K\tilde{\xi}(t)$ 控制下是不变的。对于任意的 $\tilde{\xi}(t_1) \in \Omega_\alpha$, 在 $\tilde{u}(t) = K\tilde{\xi}(t)$ 的控制下, 无限时域成本写作:

$$\begin{aligned} J^\infty(\tilde{\xi}_1, \tilde{u}) &= \int_{t_1}^{\infty} (\|\tilde{\xi}(t)\|_Q^2 + \|\tilde{u}(t)\|_R^2) dt \\ J^\infty(\tilde{\xi}_1, \tilde{u}) &\leq \tilde{\xi}_1^T P \tilde{\xi}_1 \\ \tilde{\xi}(t_1) &= \tilde{\xi}_1 \end{aligned} \quad (26)$$

应用终端控制器后, 在终端集内有

$$\frac{d}{dt} \tilde{\xi}(t)^T P \tilde{\xi}(t) \leq -\tilde{\xi}(t)^T Q^* \tilde{\xi}(t) \quad (27)$$

定理详细证明过程参考文献^[18]。

定理 4.2 (迭代可行性): 对于具有完全状态测量且无扰动的标称系统, 且采样时间足够小的情况下, 优化问题在 $t=0$ 时刻可行, 意味着它对所有 $t>0$ 时刻都是可行的。

证. 假设在 t 时刻有最优控制序列 $\tilde{u}^*(t): [t, t+NT]$ 满足约束。当开环应用该控制序列后, 可以使得状态量 $\tilde{\xi}(t)$ 沿着开环的最优轨迹进入终端集 $\tilde{\xi}^*(t+NT) \in \Omega$ 。那么, 在实际的控制中, 最优控制序列 $\tilde{u}^*(t): [t, t+NT]$ 在 t 到 $t+T$ 时段被实际应用。由于考虑的系统是没有扰动的标称系统, 所以实际的状态量等于最优轨迹中的状态量: $\tilde{\xi}(t+T) = \tilde{\xi}^*(t+T)$, 为保证在 $t+T$ 时刻问题仍然有解, 可以预先设计可行解 $\bar{u}(\cdot): [t+T, t+NT+T]$:

$$\bar{u}(\tau) = \begin{cases} \tilde{u}^*(\tau; \tilde{\xi}(t)) & \tau \in [t+T, t_k+NT) \\ K\tilde{\xi}(\tau; \tilde{\xi}(t+T)) & \tau \in [t+NT, t+NT+T) \end{cases} \quad (28)$$

式中, K 是为用于确定 P 和 Ω 的局部线性状态反馈增益。由定理 4.1 可知终端区域是不变的, 当设计的可行解应用后, 可以使得 $\tilde{\xi}(t+T+NT) \in \Omega$ 。控制量是阶段执行的, 每次只执行第一个控制量, 所以 $\bar{u}(\tau) = K\tilde{\xi}(\tau; \tilde{\xi}(t+T))$ 几乎不会被应用。对于轨迹的连续性, 我们可以假设对于一个足够小的

$T > 0$ 来满足。至此算法的可行性得证。

定理 4.3 (稳定性): 假设优化问题在 $t=0$ 时是可行的, 对于没有扰动的标称系统, 由定理 4.2 可知, 对于任何 $t \geq 0, \tau \in (t, t+T]$ 可行, 且最优值函数满足:

$$J^*(\tilde{\xi}(\tau)) \leq J^*(\tilde{\xi}(t)) - \int_t^\tau (\|\tilde{\xi}(s)\|_Q^2 + \|\tilde{u}^*(s)\|_R^2) ds \quad (29)$$

证. 在 t 时刻有最优控制序列 $\tilde{u}^*(\tilde{\xi}(t)): [t, t+NT]$ 开环控制后得到最优状态轨迹 $\tilde{\xi}^*(\tau | \tilde{\xi}(t)): [t, t+NT]$, 此时的目标函数的最优值可以写成:

$$J^*(\tilde{\xi}(t)) = \int_t^{t+NT} (\|\tilde{\xi}^*(\tau)\|_Q^2 + \|\tilde{u}^*(\tau)\|_R^2) d\tau + \|\tilde{\xi}^*(t+NT)\|_P^2 \quad (30)$$

由于是标称系统, 将控制序列应用后得到实际状态与最优状态相等:

$$\tilde{\xi}(s) = \tilde{\xi}^*(s), s \in [t, \tau] \quad (31)$$

在 $t+T$ 时设计可行的控制序列:

$$\bar{u}(s) = \begin{cases} \tilde{u}^*(s; \tilde{\xi}(t)) & \tau \in [\tau, t+NT) \\ K\tilde{\xi}(s; \tilde{\xi}(t+T)) & \tau \in [t+NT, \tau+NT) \end{cases} \quad (32)$$

应用了可行控制序列后实际的轨迹除了 $[t+NT, \tau+NT)$ 之外和预测的最优轨迹相同:

$$\tilde{\xi}(s) = \tilde{\xi}^*(s), s \in [\tau, t+NT) \quad (33)$$

对定理 4.1 中的式(27)从 $t+NT$ 到 $\tau+NT$ 进行积分:

$$\|\tilde{\xi}(\tau+NT)\|_P^2 \leq \|\tilde{\xi}^*(t+NT)\|_P^2 - \int_{t+NT}^{\tau+NT} (\|\tilde{\xi}(s)\|_Q^2) ds \quad (34)$$

在 $\tau \in (t, t+T]$ 中时:

$$\begin{aligned} J(\tilde{\xi}(\tau)) &= \int_\tau^{\tau+NT} (\|\tilde{\xi}(s)\|_Q^2 + \|\tilde{u}(s)\|_R^2) ds + \|\tilde{\xi}(\tau+NT)\|_P^2 \\ &= \int_\tau^{t+NT} (\|\tilde{\xi}^*(s)\|_Q^2 + \|\tilde{u}^*(s)\|_R^2) ds \\ &\quad + \int_{t+NT}^{\tau+NT} (\|\tilde{\xi}(s)\|_Q^2) ds + \|\tilde{\xi}(\tau+NT)\|_P^2 \\ &\leq \int_\tau^{t+NT} (\|\tilde{\xi}^*(s)\|_Q^2 + \|\tilde{u}^*(s)\|_R^2) ds + \|\tilde{\xi}^*(t+NT)\|_P^2 \end{aligned} \quad (35)$$

对比式(30)、(31)可知:

$$J(\tilde{\xi}(\tau)) \leq J^*(\tilde{\xi}(t)) - \int_t^\tau (\|\tilde{\xi}^*(s)\|_Q^2 + \|\tilde{u}^*(s)\|_R^2) ds \quad (36)$$

$$J(\tilde{\xi}(\tau)) \leq J^*(\tilde{\xi}(t)) - \int_t^\tau (\|\tilde{\xi}(s)\|_Q^2 + \|\tilde{u}^*(s)\|_R^2) ds$$

进一步推得:

$$J^*(\tilde{\xi}(\tau)) \leq J(\tilde{\xi}(\tau)) \leq J^*(\tilde{\xi}(t)) - \int_t^\tau (\|\tilde{\xi}(s)\|_Q^2 + \|\tilde{u}^*(s)\|_R^2) ds \quad (37)$$

式中, $Q > 0, R > 0$ 。至此, 我们证明了最优值函数 J 是不递增的。我们可以给出该闭环系统是渐近稳定的结论。

5 参考轨迹预处理

参考轨迹的质量直接影响跟踪控制效果。参考轨迹可由函数生成^[19], 也可由驾驶员驾驶车辆进行采集。直接采集的数据高效便捷的同时满足车辆的动力学特性, 这保证了轨迹在车辆极限状态的可行性。但采集数据同时存在着随机误差和传感器噪声干扰, 导致驾驶机器人方向盘出现高频抖震乘坐体验变差。本节在参考轨迹的预处理过程中使用了跟踪微分器^[20]进行处理, 取得了不错的效果。跟踪微分器有去除噪声污染, 去除异常值的能力, 具体函数由式(38)给出:

$$\begin{cases} fh = fhan(x_1(k) - x_1(k)_r, x_2(k), r, h) \\ x_1(k+1) = x_1(k) + hx_2(k) \\ x_2(k+1) = x_2(k) + h \times fh \end{cases} \quad (38)$$

式中, $fhan(x_1, x_2, r, h)$ 是最速控制综合函数, $x_1(k)$ 是状态跟踪序列, $x_2(k)$ 是跟踪序列的微分(跟踪速度), $x_1(k)_r$ 是原参考轨迹, r, h 是跟踪微分器的两个参数, r 是速度因子, h 是跟踪步长。通过循环执行式(38), 序列 $x_1(k)$ 即表示处理后的参考轨迹。其他具体函数形式由式(39)给出, 具体推导过程参考^[20]。

$$\begin{cases} d = rh^2 \\ a_0 = hx_2 \\ y = x_1 + a_0 \\ a_1 = \sqrt{d(d+8|y|)} \\ a_2 = a_0 + \text{sign}(y)(a_1 - d)/2 \\ a = (a_0 + y) \text{fsg}(y, d) + a_2(1 - \text{fsg}(y, d)) \\ fhan = -r \left(\frac{a}{d} \right) \text{fsg}(a, d) - r \text{sign}(a)(1 - \text{fsg}(a, d)) \\ \text{fsg}(x, d) = (\text{sign}(x+d) - \text{sign}(x-d))/2 \end{cases} \quad (39)$$

离散参考轨迹点间距为 2 cm, 实验中采取

$r=5, h=0.02$ 。图 2 给出了跟踪微分器处理前后的参考轨迹对比。可以发现, 处理后, 新轨迹与原轨迹偏差较小(1~2 cm), 在保留了原轨迹信息的同时使轨迹变得光滑, 去除了传感器和人为因素的误差干扰和异常值点, 大幅减少了机器人抖震, 提高了跟踪控制效果。




图 2 参考轨迹处理结果

Fig. 2 Reference trajectory processing results

6 权重自适应控制

经典的模型预测控制器在轨迹跟踪过程中存在效果不佳的问题, 其中重要的原因之一是式(19)中权重矩阵 Q 和 R 固定不变, 难以在多种不同的工况下达到最优的控制效果, 本节为同时保证较高的跟踪精度和较好的乘坐体验, 提出了基于模糊自适应控制的改进 MPC 控制器。该控制器可以根据速度和地图曲率自适应调整代价函数的权值。

FLC 可以模拟人类驾驶员的程序性知识, 实现自适应的控制。例如, 在高速行驶状态下避免大幅度转向保证车身稳定, 在直线行驶避免反复调整, 在发生侧滑后迅速调整消除误差等。FLC 主要可分为 3 个阶段: 模糊化、模糊推理和解模糊。第一步, 根据相关隶属度函数, 将当前输入值模糊化为具有一定真实性的语言或模糊值。第二步, 确定模糊输入值转换为模糊输出值的模糊规则。第三步将模糊输出去模糊化为最终的实际输出。本节定义了两个模糊控制输入: 车辆实时速度和地图曲率。考虑参考路径跟踪中车辆的行驶状态, 将速度输入模糊化为 2 个模糊集: VS(速

度小)、VB (速度大), 曲率输入模糊化为 3 个模糊集: CB (曲率大)、CM (曲率中)、CS (曲率小)。隶属度函数采用双高斯混合函数。将式(19)中的权重矩阵元素 Q_y, Q_ϕ, R_δ 作为模糊控制器的输出。分别将其模糊化为 5 个模糊集: VSCB (低速大曲率)、VSCS (低速小曲率)、VBCB (高速大曲率)、VBCM (高速中曲率)、VBCS (高速小曲率)。

表 1 权重的模糊规则
Table 1 Fuzzy rules of weight

Q_y, Q_ϕ, R_δ		道路曲率		
		CB	CM	CS
速度	VS	VSCB	VSCB	VSCS
	VB	VBCB	VBCM	VBCS

模糊规则由表 1 给出, Q_y, Q_ϕ, R_δ 这 3 个参数的模糊输出均采用了同一套模糊规则。去模糊化方法采用了重心法。参数 $Q_x = Q_y$, R_v 是常值。

图 3 分别给出了 Q_y, Q_ϕ, R_δ 在模糊规则下输出和输入之间的关系的面。根据车身速度和道路曲率, 可以自适应地调整参数。实验中, $Q_x = Q_y$, R_v 是一个常数。

7 仿真实验与实车实验

7.1 仿真轨迹跟踪控制实验

仿真实验搭建了一套联合仿真平台 (图 4)。采用 Simulink 作为控制算法实现的平台, 版本为 Matlab2019a, 同时联合了车辆动力学仿真软件 Carsim, 建立仿真控制车辆和仿真工况, 版本为 Carsim8.02。

实验选取车型是 B 型车, 设定参数为: 整车质量 1723 kg; 车身总长为 4 m; 车身宽 2 m; 质心至前轴 1.232 m; 质心至后轴 1.468 m; 绕 Z 轴转动惯量为 $4175 \text{ kg} \cdot \text{m}^2$; 前轮胎侧偏刚度为 66900; 后轮胎侧偏刚度为 62700。实验采用自定义的仿真环境, 为 $1 \times 1 \text{ km}^2$ 面积, 摩擦系数为 0.8 的平整水泥地面。Simulink 中模型控制算法的输入量为车辆位置信息 (X, Y) 、纵向速度 v_f 、车身

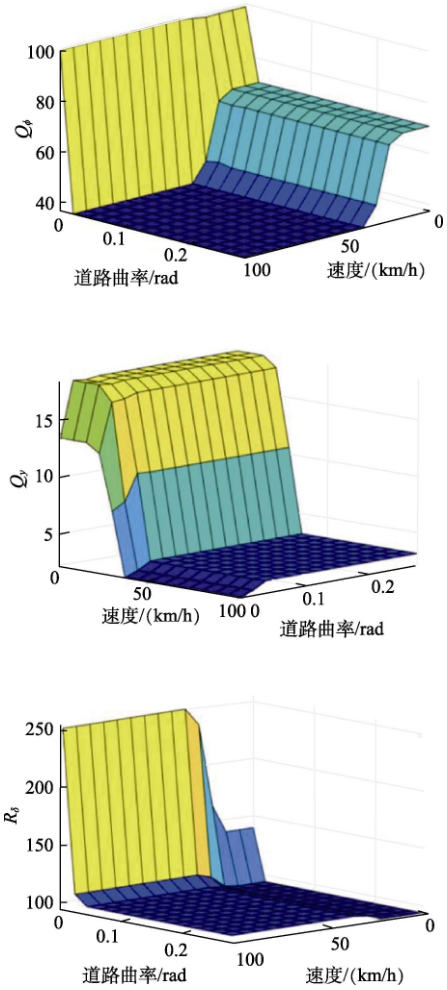


图 3 模糊规则的响应面

Fig. 3 Response surface of fuzzy rules

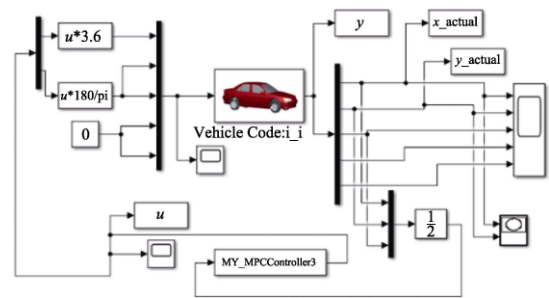


图 4 联合仿真平台

Fig. 4 Union simulation platform

横摆角 ϕ 等。输出量是纵向速度 v 与车辆前轮转角 δ 。

仿真实验 1: 参考轨迹为一圆心 $(0, 30)$, 半径 25 m 的圆形, 期望速度 v_f 为匀速 10.8 km/h, 初始状态为 $\xi_0 = [0, 0, 0]^T$, 初始速度为 $v_0 = 10.8 \text{ km/h}$ 。

实验 1 中,图 5 是仿真软件 Carsim 的仿真实验动画,图 6 是圆形轨迹跟踪的仿真实验数据。由图 6 可知,仿真车辆跟踪效果良好,控制量满足控制量约束且处于较小的波动范围内。在跟踪后期效果平稳,误差较小。




图 5 仿真实验 1 结果 (Carsim 动画)
Fig. 5 Simulation results data 1 (Carsim)




图 6 仿真 1 实验数据
Fig. 6 Numerical simulation data 1

仿真实验 2: 参考轨迹由驾驶员录制,包括位姿和速度信息,输入数据至 Carsim 中可以构建仿真道路。本节截取了实验跟踪轨迹的一部分(掉头弯路)进行说明。

在实验 2 中截取了跟踪轨迹的一段大曲率弯道。图 5 展示了仿真实验的动画效果。图 7 给出了实验的数据,该弯道的最大曲率是 0.078,仿真通过速度在 46 km/h 以上,最大横向误差小于 0.43 m,整体跟踪效果良好。通过仿真实验验证了算法的可行性。




图 7 仿真 2 实验数据
Fig. 7 Numerical simulation data 2

7.2 实车轨迹跟踪控制实验

为进一步测试算法性能,搭建了无人车辆测试平台。参考轨迹由专业驾驶员采集。车辆位姿由高精组合导航给出,控制算法由车载工控机计算,控制量由自动机驾驶机器人执行。主要进行了高速直线、高速弯道、低速直线和低速弯道等测试。测试车辆为前轮驱动四座乘用车。实车实验中进行了不同速度、不同路况的全面测试,文中给出了具有代表性的实验结果。图 8 展示了搭建的无人车辆测试平台。

图 9~10 给出了高速直线跟踪效果。可以发现,在最高速度 95.7 km/h 情况下,跟踪误差始终较低,纵向误差在 1.5 cm 内,最大横向偏差在 7 cm 内,航行角偏差在 0.005 rad 内。车辆平均偏左



图 8 无人车辆测试平台
Fig. 8 Unmanned vehicle test platform

3 cm 是由转向机器人的 2.6° 静态偏差导致。图 11~12 给出了高速弯道跟踪效果, 弯道最大曲率为 0.056 (半径 17.8 m) 在平均速度 55 km/h, 最低速度 44 km/h 过弯时, 纵向误差在 4 cm 内, 横向偏差在 28.2 cm 内, 航向角偏差在 0.056 rad 内。由图 9~12 可以发现, 控制算法具有良好的控制性能, 并且在不同工况下有着不错的鲁棒性。

对比权值固定的经典 MPC 控制器, 本文提出的权重自适应 MPC 控制器控制效果有着明显的




图 9 高速直线轨迹跟踪对比
Fig. 9 High speed linear trajectory tracking




图 10 高速直线跟踪误差
Fig. 10 High speed line tracking error




图 11 高速弯道轨迹跟踪对比
Fig. 11 High speed curve trajectory tracking




图 12 高速曲线跟踪误差
Fig. 12 Tracking error of high speed curve

提升, 主要表现为低速运行跟踪误差大大缩小、极限工况稳定性提升等。

图 13 是低速大曲率弯道的跟踪轨迹, 行驶速度为 8 km/h, 曲率最大处为 0.24。红色轨迹是权重自适应 MPC 跟踪轨迹, 蓝色是权重固定 MPC。通过对比可以发现, 权重自适应 MPC 跟踪误差最大值在 30 cm 内, 明显小于权重固定 MPC 效果。




图 13 低速大曲率弯道控制轨迹对比
Fig. 13 Control trajectory comparison

图14是高速直线工况下前轮转角控制量的对比。黑色线条是当前道路曲率。可以发现, 权重固定MPC在直线跟踪时出现反复调整, 出现“游动现象”, 而权重自适应MPC在直线段主要通过自适应增大航向角权重使车辆姿态稳定, 避免了“直线游动”, 提高了乘坐体验。




图14 高速直线方向盘转角控制量对比

Fig. 14 Comparison of front wheel angle control

图15是转弯滑移测试轨迹对比。车速在25 km/h以上, 要求在转弯处达到车辆转向极限(500°)。车辆会因惯性发生轮胎滑移。目的是测试滑移后车辆姿态恢复能力。通过对比可以发现, 权重自适应MPC在发生滑移后有更好的恢复速度, 而固定权重MPC出现了失稳现象, 并且恢复慢。

通过以上对比实验可以发现, 本文提出的基于模糊控制的权重自适应MPC控制器对比经典MPC控制器有着更优的控制效果和乘坐体验。

文献[21]中提出了纵向模糊PID和横向航向预估式的控制算法, 在跟踪实验过程中, 速度在




图15 转弯滑移测试轨迹对比

Fig. 15 Turn slip test trajectory comparison

10 km/h左右, 跟踪轨迹波动较为明显在直线出现“游走”, 弯道跟踪不够紧密, 最大误差在0.8 m。通过对比可以发现, 本文提出的模型预测轨迹跟踪器有明显优势。

8 结 论

本文主要基于模型预测控制的无人车辆的轨迹跟踪问题进行了相关的研究, 通过机理分析对阿克曼结构的无人车辆进行基于运动学建模。设计了模型预测控制器, 并通过设计终端约束的和终端集的方法对迭代可行性和系统稳定性进行了分析。针对参考轨迹的随机误差和噪声干扰导致的乘坐体验变差问题, 提出来利用跟踪微分器处理参考轨迹的方法, 有效消除了方向盘高频抖动问题, 提高了乘坐体验。针对经典MPC控制器由于优化函数中权值固定导致变化工况适应性低的问题, 提出了基于模糊控制的权重自适应MPC。通过搭建软件仿真平台, 验证了算法的可行性, 同时进行了大量实车实验。实验表明, 本文设计模型预测控制器可以完成轨迹跟踪任务, 同时在不同工况具有较强的鲁棒性。对比经典MPC, 在控制精度和乘坐体验上均有明显提高。

参 考 文 献

- [1] 张朝阳, 李星宏. 5G在无人驾驶汽车中的应用前景分析[J]. 无人系统技术, 2019, 2(2): 65-68.
- [2] 葛悦涛, 任彦. 2020年人工智能芯片技术发展综述[J]. 无人系统技术, 2021, 4(2): 14-19.
- [3] 张涛, 李清, 张长水, 等. 智能无人自主系统的发展趋势[J]. 无人系统技术, 2018, 1(1): 11-22.
- [4] 赵会超, 师五喜. 基于变增益模糊PID控制的移动机器人轨迹跟踪[J]. 自动化与仪表, 2020, 35(2): 32-36.
- [5] 彭之川, 朱田, 易慧斌. 基于改进的Pure Pursuit智能客车轨迹跟踪算法研究[J]. 客车技术与研究, 2019, 41(5): 21-24.
- [6] Peng H, Tomizuka M. Preview control for vehicle lateral guidance in highway automation[J]. Journal of Dynamic Systems, Measurement, and Control, 1993, 115 (4): 679-686.
- [7] 陈一凡. 基于自适应模糊控制的AGV轨迹跟踪系统[J]. 汽车实用技术, 2021, 46(2): 22-24.
- [8] 张晓峰, 于登秀, 冯喆, 等. 全向移动小车编队轨迹跟踪及防撞控制系统研究[J]. 无人系统技术, 2020, 3(6): 43-49.
- [9] Yang H, Guo M, Xia Y, et al. Trajectory tracking for wheeled

- mobile robots via model predictive control with softening constraints[J]. IET Control Theory & Applications, 2018, 12(2): 206-214.
- [10] Van Pham C, Wang, Y N. Robust adaptive trajectory tracking sliding mode control based on neural networks for cleaning and detecting robot manipulators[J]. Journal of Intelligent & Robotic Systems, 2015, 79(1): 101-114.
- [11] 吴琦, 于海靖, 谢勇, 等. 人工智能在自动驾驶领域的应用及启示[J]. 无人系统技术, 2019, 2(1): 23-28.
- [12] 孙宁, 方勇纯. 一类欠驱动系统的控制方法综述[J]. 智能系统学报, 2011(3): 16-23.
- [13] Brockett R W. Asymptotic stability and feedback stabilization[J]. Differential Geometric Control Theory, 1983, 27 (1): 181-191.
- [14] 杨俊, 樊继东. 基于自适应模型预测控制的智能车轨迹跟踪[J]. 湖北汽车工业学院学报, 2021, 35(1): 6-10.
- [15] Zheng Y, Li S, Li N. Distributed model predictive control over network information exchange for large-scale systems[J]. Control Engineering Practice, 2011, 19 (7): 757-769.
- [16] Borrelli F, Falcone P, Keviczky T, et al. MPC-based approach to active steering for autonomous vehicle systems[J]. International Journal of Vehicle Autonomous Systems, 2005, 3(2/3/4): 265-291.
- [17] 龚建伟, 姜岩, 徐威. 无人驾驶车辆模型预测控制[M]. 北京: 北京理工大学出版社, 2014.
- [18] Chen H, ALLGÖWER F. A quasi-infinite horizon nonlinear model predictive control scheme with guaranteed stability[J]. Automatica, 1998, 34(10): 1205-1217.
- [19] 陈智伟, 胡劲文, 赵春晖, 等. 野外无人车路径规划与轨迹规划技术[J]. 无人系统技术, 2021, 4(2): 40-48.
- [20] 韩京清. 自抗扰控制技术[M]. 北京: 国防工业出版社, 2008.
- [21] 王振. 无人车运动控制系统设计与实现[D]. 西安: 长安大学, 2016.

作者简介:



李畅 (1997-), 男, 硕士研究生, 主要研究方向为模型预测控制。



张佳 (1990-), 男, 硕士, 工程师, 主要研究方向为自动驾驶系统控制与决策技术。



孙中奇 (1986-), 男, 博士, 助理教授, 主要研究方向为多智能体模型预测控制。本文通信作者。



夏元清 (1971-), 男, 博士, 教授, 主要研究方向为网络化信息处理与控制。

[引用格式] 刘宇飞, 江磊, 邢伯阳, 等. 基于全局 SLAM 的四足机器人路径规划研究[J]. 无人系统技术, 2021, 4(6): 57-64.

基于全局 SLAM 的四足机器人路径规划研究

刘宇飞, 江磊, 邢伯阳, 王志瑞

(中国北方车辆研究所兵器地面平台无人中心, 北京 100072)

摘要: 感知与导航控制是足式机器人适应复杂地形、实现自主行走、达到人机交互的核心关键技术, 是足式机器人区别于有人装备、成为地面无人系统的关键。首先, 针对野外复杂环境的地形重建和定位难题, 采用基于雷达点云信息的全局 SLAM 定位系统, 提出了一种基于拓扑度量相结合的定位框架, 实现了在室外环境的地形建模和定位。其次, 针对四足机器人的运动和高频振动的情况, 采用全局地形下基于 Dijkstra 算法的路径规划实现了四足机器人的自主导航任务, 利用局部地形下基于人工势场理论的自主避障策略, 实现了四足机器人在全局地形下的定位导航及局部实时避障。试验结果表明, 四足机器人可以准确地在全局地图中定位并实现导航, 在局部地图中可以完成实时最优路径避障, 证明了所提方法的有效性, 实现了四足机器人的野外环境全局地图自主行走。所提定位规划方法有利于地面机器人导航能力的提升。

关键词: 全局 SLAM; Dijkstra 算法; 人工势场理论; 四足机器人; 自主行走

中图分类号: TP24

文献标识码: A

文章编号: 2096-5915(2021)06-57-08

DOI: 10.19942/j.issn.2096-5915.2021.6.055

Research on Path Planning of Quadruped Robot Based on Globally SLAM

LIU Yufei, JIANG Lei, XING Boyang, WANG Zhirui

(Unmanned Center, China North Vehicle Research Institute, Beijing 100072, China)

Abstract: Perception and navigation control is core key technology for the legged robot to adapt to complex terrain and achieve autonomous walking. It is the key to distinguish the legged robot from manned equipment and become a ground unmanned system. Firstly, the globally SLAM localization system based on the double lidar point cloud is established in this paper, and the localization framework based on the combination of topological measurements is proposed to achieve the map reconstruction and localization problem of the wild environment. Secondly, considering the movement and high frequency vibration of the quadruped robot, the path planning based on Dijkstra algorithm for globally terrain is adopted to realize the autonomous navigation task of quadruped robot. Autonomous obstacle avoidance strategy of the local map for quadruped robot based on the artificial potential field theory is applied, and it realizes the localization and navigation of the quadruped robot for the globally terrain and the local real-time obstacle avoidance. The experimental results show that the globally localization and path navigation can accurately plan the optimal path and complete the autonomous obstacle avoidance of the local map. The results have demonstrated the effectiveness of the proposed method and realize the globally and local field autonomous walking of the quadruped robot. The localization and navigation method is helpful to improve the navigation capabilities of ground robots.

收稿日期: 2021-07-06; 修回日期: 2021-08-18

基金项目: 国家重点研发计划, 高性能仿生足式机器人研究(2019YFB1309500; 2019YFB1309502); 国家自然科学基金(91748211); 机器人技术与系统国家重点实验室(SKLR201501B; SKLR20164B)

Key words: Globally SLAM; Dijkstra Algorithm; Artificial Potential Field Theory; Quadruped Robot; Autonomous Walking

1 引言

为了实现四足机器人在未知崎岖地形行走，尽管可以通过本体传感器获得机器人的行走状态，但如果没有感知系统，机器人将无法在崎岖地形上自主行走。基于环境感知的四足机器人路径规划可以实现足式机器人的自主行走。

波士顿动力公司开发的小狗机器人是经典的四足机器人，此机器人已经在环境建模和运动规划中进行了研究^[1-2]。研究人员使用视觉传感器来构建地形环境，并基于视觉传感器生成三维地图以完成路径规划^[3]。波士顿动力公司开发的大型四足机器人配备了 GPS、IMU、激光和双目相机传感器^[4]。实现了视觉测量、环境地图构建和定位，可以通过感知信息判断机器人的合适落足点^[5]。

Belter^[6]研究了基于视觉传感器的机器人环境感知和建模。视觉和惯性导航传感器的组合可以实现姿态和运动参数的估计。研究内容包括模拟环境中的地形识别与感知、落足点选择和路径规划^[7]。Fankhauser^[8]提出了一种基于外部视觉感知的四足机器人运动规划方法。根据获得的地形高程图，规划摆动腿落足点未知，并且基于优化方法完成四足机器人攀爬障碍物和楼梯。控制框架包含地图建模、状态估计、运动控制和规划，并将所提出的方法在四足机器人上进行了验证。

基于 EKF 的 SLAM 方法是解决定位问题的最早方法^[9]，但由于 EKF 的计算复杂度较高，因此会降低定位效率。早期的稀疏 EIF 算法使用稀疏结构来减少计算量，但结构的稀疏性将导致结果的发散，因此学者开始研究 SLAM 问题的稀疏结构^[10-11]。基于姿态滤波和稀疏特征点提出了稀疏滤波方法^[12]。为了提高滤波算法的精度，提出了一种滑动窗口滤波的方法来提高精度，包含了前一时刻的姿态信息。

足式机器人的导航规划可以分为全局地图的路径规划和局部地图的落足点规划两部分。全局

路径规划可以归结为优化问题，其中优化的目标函数是路径。优化问题的约束条件是速度约束以及起点和终点的位置约束，学者们通过将约束问题转化为非约束问题来解决此优化问题^[13]。路径规划问题转化为一种图形方法，包括几何方法和采样方法。在成本函数方面，采用了人为设计的成本函数^[13]，但是人为设计的函数很难覆盖潜在的问题空间，因此最终提出了一种基于示教的成本函数方法。

本文的主要贡献是开发一种旨在实现自主行走的感知和导航算法，提出了全局 SLAM 定位算法来实现地图的重建和定位，提出了用于全局和局部地图的路径规划以实现自主导航和避障任务。

2 基于激光雷达的地形构建

激光雷达可以得到地形环境下的点云信息，通过对点云信息的分析和处理，建立三维地形图。为了更准确地描述地形信息，建立了基于地形建模的 4 个坐标系系统，如图 1 所示。坐标系系统分别为大地坐标系 O_W 、本体坐标系 O_B 、传感器坐标系 O_V 和腿部坐标系 O_L ^[14]。




图 1 地形建模框架下的坐标系系统

Fig. 1 Coordinate system for terrain modeling framework

相对于大地坐标系，机体坐标系的坐标为 ${}^B P({}^B P_X, {}^B P_Y, {}^B P_Z)$ ，腿部坐标系为 ${}^L P({}^L P_X, {}^L P_Y, {}^L P_Z)$ ，传感坐标系为 ${}^V P({}^V P_X, {}^V P_Y, {}^V P_Z)$ 。为了建立基于机体质心的地形信息，将激光雷达信息转换到机体坐标系下：

$${}^B\mathbf{P} = \mathbf{T}_B^W \mathbf{T}_V^{B V} \mathbf{P} \quad (1)$$

式中, \mathbf{T}_B^W 为机体坐标系和大地坐标系之间的转换矩阵, 它通过 IMU 数据和机器人本体数据得到; \mathbf{T}_V^W 为传感坐标系和大地坐标系之间的转换矩阵。

通过激光雷达得到的点云信息生成地形高程图。在地形坐标系上, 高度测量被近似成一个高斯概率分布, 其中高度平均值为 p , 标准差为 σ_p^2 。如果通过激光传感器可以得到障碍物在传感器坐标系下的位置 ${}^V\mathbf{r}_{VP}$, 即可以得到在大地坐标系下的高度测量值:

$$\mathbf{p} = \mathbf{P}(\mathbf{T}_B^W \mathbf{T}_V^{B V} \mathbf{r}_{VP} - {}^W\mathbf{r}_{WP}) \quad (2)$$

由于在高度测量过程中, 物体在两个坐标系下的横纵坐标不变, 因此矩阵 $\mathbf{P} = [0 \ 0 \ 1]$ 。高度测量的标准差如下所示:

$$\sigma^2 = \mathbf{J}_V \boldsymbol{\Sigma}_V \mathbf{J}_V^T + \mathbf{J}_q \boldsymbol{\Sigma}_{P,q} \mathbf{J}_q^T \quad (3)$$

式中, $\boldsymbol{\Sigma}_V$ 为激光传感器模型的协方差矩阵; $\boldsymbol{\Sigma}_{P,q}$ 为传感器坐标系旋转的协方差矩阵; \mathbf{J}_V 为传感器测量的雅可比矩阵; \mathbf{J}_q 为传感器坐标旋转的雅可比矩阵。

针对地形高程图的云图更新, 采用扩展卡尔曼滤波的方式对更新数据进行数据融合。扩展卡尔曼滤波方程中的状态变量等同于地图信息中的高度信息。扩展卡尔曼滤波更新方程如下所示:

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k^- \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad (4)$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{Z}_k - \mathbf{H}_k \hat{\mathbf{x}}_k^-) \quad (5)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k^- \quad (6)$$

在状态更新方程中, 状态变量 $\hat{\mathbf{x}}_k$ 即是高度信息, \mathbf{H}_k 为单位矩阵, 协方差矩阵 \mathbf{P}_k 等同于高度估计的标准差 σ_p^2 。因此, 将地形高程图估计值 (\hat{h}, σ_h^2) 通过扩展卡尔曼滤波的方式融合到高度测量值 (p, σ_p^2) 中。

$$\hat{h}^+ = \frac{\sigma_p^2 \hat{h}^- + \sigma_h^2 \tilde{p}}{\sigma_p^2 + \sigma_h^2} \quad (7)$$

$$\hat{\sigma}_h^{2+} = \frac{\hat{\sigma}_h^{2-} \sigma_p^2}{\hat{\sigma}_h^{2-} + \sigma_p^2} \quad (8)$$

最终可以得到实时更新的地形建模高度信息和高度的标准差, 从而得到实时的地形信息。

3 SLAM 全局定位模块构建

3.1 自主定位模块化设计

自主定位模块将融合 GPS、IMU、里程计等导航定位信息与全局地图信息、激光雷达信息, 完成四足机器人自主行走中准确位姿信息的自主获取, 保证机器人能够进行准确的人员与轨迹跟踪。

在本系统的自主定位中, 考虑足式机器人环境自足行走时, 需要考虑环境过大带来的地图全局一致性无法满足的问题, 以及地图过大带来的占用内存过大的问题。本系统采用拓扑度量定位框架下的地图动态加载方法, 将全局地图划分成一系列局部地图, 并以带尺度的拓扑地图表示。在定位中, 系统采用当前定位结果动态加载邻近地图的方式进行信息融合, 并采用记忆机制来克服运动中定位融合匹配失败问题。

3.2 拓扑度量定位框架设计

在已有全局地图的前提下, 系统将全局地图划分成一系列局部地图, 并保证有一定的重叠。地图的表示形式为拓扑地图, 具体为无向图, 图中的节点为局部地图, 边为局部地图之间的相对变换。在定位过程中, 主要分为两层定位步骤, 其中第一层负责选取一个节点作为参考点, 即根据前一次定位结果, 融合 GPS、IMU、里程计信息, 推算距离当前位姿最近的一个节点作为参考点, 用于后续定位的子地图, 并将机器人表示在该节点的坐标系下; 随着机器人的不断移动, 参考点不断变化, 即子地图将不断切换。第二层将融合地图信息, 通过选取参考点一定大小邻域的若干子地图, 并与实时获得的激光数据进行迭代最近点法 (ICP) 匹配, 根据匹配结果, 得到当前机器人在参考点下的位姿, 完成系统自主定位。

对于 C_{odom} , 该项约束由多传感器插值里程获

得。即从上一个获取激光的时刻开始的 IMU 数据，在下一个激光数据获得前，均通过四足机器人的运动模型积分得到相对于上一个时刻的位姿。当下一次激光获取时，以 IMU 积分的数据为初值，通过和上一个时刻的激光数据进行迭代最近点法 (ICP) 匹配，得到相邻两帧的增量式相对变换。作为当前时刻相对于上一个时刻的位姿，IMU 数据的积分清零，清除 IMU 积分的累积误差。通过累积一系列相对变换可以最终得到机器人的里程轨迹。有了该轨迹，可以约束变量位姿之间的相对位姿变换需要尽可能和里程一致。以长度为 3 的窗口为例，定义里程轨迹的位姿为 U ，优化代价函数 C_{odom} 如下：

$$C_{\text{odom}} = \left\| U_{t-1}^T X_{t-1}^{-1} X_t \right\| + \left\| U_{t-2}^T X_{t-2}^{-1} X_{t-1} \right\| \quad (9)$$

根据代价函数，取当前时刻和子地图之间的位姿变换，即为当前在子地图下的定位。生成的全局定位地图如图 2 所示，机器人可以根据全局地图来规划自己的运动轨迹。




图 2 全局地图生成

Fig. 2 Global map generation

4 全局和局部地图的路径规划

4.1 基于 Dijkstra 算法的全局路径导航

路径规划模块将完成四足机器人在全局导航定位地图下的全局路径规划任务，其将跟踪指定的人为设定轨迹点或行人轨迹，根据局部环境信息、障碍物信息等规划安全无碰撞的局部行走路径点信息。系统将采用 Dijkstra 算法进行局部路径点规划，再采用 TEB 平滑算法进行全局路径的平滑优化处理。

系统采用 Dijkstra 算法在局部地图构建输出

的实时局部栅格地图中进行路径规划，Dijkstra 算法的起点为机器人当前所在栅格，目标点为下一个要到达的目标节点所在栅格。启发式算法 (如 A* 算法) 相比于 Dijkstra 的搜索空间缩小很多，即在计算量上大大降低。Dijkstra 算法的具体步骤如下。

记栅格地图为 $G=\{V,E\}$ ， V 为栅格，即顶点， E 为两点之间的边：

- (1) 初始时令 $S=\{V_0\}, T=V-S=\{\text{其余顶点}\}$ ；
- (2) 从 T 中选取一个与 S 中顶点有关联边且权值最小的顶点 W ，加入到 S 中；
- (3) 对其余 T 中顶点的距离值进行修改：若加进 W 作中间顶点，从 V_0 到 V_i 的距离值缩短，则修改此距离值；
- (4) 重复上述步骤 2、3，直到 S 中包含目标顶点。

经过 Dijkstra 搜索，从当前栅格到目标栅格的路径可以得到。

由于栅格地图的分辨率较低，生成的局部路径需要进一步处理。先将栅格路径进行离散采样，再放入 TEB 算法进行优化处理。TEB 算法是一个相对较新的全局导航算法，可以输出移动机器人的路径点以及速度，它采用了 g2o 优化：将局部路径节点当作节点，即待解量；将节点之间的约束作为条件。经过优化后，局部路径相对会更加平滑，并且可以调节距离障碍物之间的距离。

4.2 基于势场理论的局部地图避障

在局部地图中通过相邻的网格信息来判断障碍物的位置和高度信息，当检测到障碍物高度和尺寸超过了腿部摆动阈值，需要通过避障实现局部地图通过。通过障碍检测的方式去感知物体在全局坐标系下的位置，并依据势场理论完成机器人的自主避障^[15]。

设定地图的栅格尺寸为 $m \times n$ ，单个栅格尺寸为 $a \times a$ ，设置栅格信息格式为 $g^{[p,q]} = \{x_i^W, y_i^W, z_i^W\}$ ，如式(10)所示：

$$g^{[p,q]} = \left\{ \begin{array}{l} P_i^W \mid (p-1)a \leq x_i^W \leq pa, \\ (q-1)a \leq y_i^W \leq qa, i=1, \dots, k \end{array} \right\} \quad (10)$$

障碍物在栅格地图中的高度信息可以表示为 $h^{[p,q]}$, 代表了指定区域地形范围内的平均高度。

$$h^{[p,q]} = \frac{\sum_{i=1}^k z_i^W}{k} \quad (11)$$

式中, k 为指定栅格中的点云数量。

通过变量 $h^{[p,q]}$ 去评价所在地形区域的平坦程度和地形的几何信息。根据采集得到的点云数据, 通过各个区域的点云平均高度差进行比较, 变量 $\delta_h^W(i)$ 为每个栅格间的高度差:

$$\delta_h^W(i) = z_i^W - z_{i-1}^W \quad (12)$$

栅格信息包含了采集区域的水平和高度值, 首先对采集区域的地形综合评估, 对高度差 $\delta_h^W(i)$ 进行检测, 得到前方路面的高度最低区域, 此区域即为机器人的安全通过区域。本文把机器人本体和四条腿近似等价成一个虚拟机体模型, 提出了基于人工势场理论的四足机器人自主避障策略, 模拟引力场的原理来表达目标位置、障碍物位置以及机器人运动方向的关系。定义障碍物对机器人产生排斥力 F_o , 目标对机器人产生吸引力 F_d , 系统的势场 U_s 可以表示为:

$$U_s = U_o + U_d \quad (13)$$

根据 Khatib 提出的模型, 吸引力产生的势函数为:

$$U_d = \frac{1}{2} \cdot k_d \cdot (\mathbf{X}_r^W - \mathbf{X}_d^W)^2 \quad (14)$$

障碍物和机器人之间的排斥力产生的势函数为:

$$U_o = \frac{1}{2} \cdot k_o \cdot \left(\frac{1}{\rho} - \frac{1}{\rho_0} \right) \quad (15)$$

根据势函数可得, 机器人和障碍物产生的排斥力为:

$$\mathbf{F}_o = -\nabla U_o = k_o \cdot \frac{1}{\rho_0} \cdot \left(\frac{1}{\rho} - \frac{1}{\rho_0} \right) \cdot \frac{\partial \rho}{\partial X} \quad (16)$$

为了保证障碍物和目标的安全距离, 在势场函数中考虑障碍物和目标的距离, 修改后的势函数为:

$$U_o = \frac{1}{2} \cdot k_o \cdot \left(\frac{1}{\rho} - \frac{1}{\rho_0} \right) (\mathbf{X}_o^W - \mathbf{X}_d^W)^n \quad (17)$$

结合吸引力和排斥力产生的势函数, 可以得到机器人避障的评价函数:

$$f(n) = \frac{1}{2} \cdot k_o \cdot \left(\frac{1}{\rho} - \frac{1}{\rho_0} \right) (\mathbf{X}_o^W - \mathbf{X}_d^W)^n + \frac{1}{2} \cdot k_d \cdot (\mathbf{X}_r^W - \mathbf{X}_d^W)^2 \quad (18)$$

取机器人在地图中的位置为 $G_{n,n}$, 如图 3 所示。对于备选的 5 个备选栅格单元, 其邻域单元分别为 $G_{n-1,n-1}$ 和 $G_{n+1,n}$ 。通过势场法计算机器人的行走方向, 建立虚拟机体模型包络本体和各腿的运动范围, 根据机器人和障碍物之间的安全距离得到四足机器人最优避障运动方向。




图 3 虚拟机体模型最优运动方向

Fig. 3 Optimal locomotion direction for virtual trunk body model

基于本体传感器采集得到的数据, 建立一个以机器人本体质心为圆心, 质心到腿部足端位置为半径的虚拟机体模型; 以包络的虚拟机体模型作为避障运动的采样区域, 根据地形高程图得到的数据, 计算机器人质心和障碍物之间的垂直距离 d_{OV} 和质心沿最优方向的距离 d_{OT} , 基于人工势场理论建立避障评价函数, 得到四足机器人的避障最优方向和最短距离, 通过计算圆切点 M 和障碍边界点 N 的连线, 得到四足机器人避障偏航角度 φ :

$$\varphi = \arccos \left(\frac{d_{OV}}{d_{OT}} \right) \quad (19)$$

四足机器人根据感知得到的避障偏航角度实现最优运动方向的局部地图避障。

5 试验验证

根据提出的全局和局部地图导航定位和路径规划方法,将感知系统安装在四足机器人上,并进行了野外环境自主试验,四足机器人和感知系统如图4所示。



图4 四足机器人和感知系统

Fig. 4 Quadruped robot and perception system

试验结果证明,四足机器人满足上述路径跟踪和速度要求,感知规划决策频率为5 Hz,障碍避障决策频率和定位迭代频率分别为10 Hz和50 Hz。四足机器人的野外环境性能试验如图5所示。




图5 四足机器人野外环境性能试验

Fig. 5 Field experimental performance test of quadruped robot

如图5所示,感知生成的路径点为20个,第一个目标点为47.25 m,机器人跟踪的最近路径点为0.3 m,基于Dijkstra算法生成的最优绿色轨迹保证了四足机器人可以根据全局SLAM定位中的最优路径行走,四足机器人在行走过程中的路径变化如图6所示。

基于拓扑度量相结合的定位方法减少了整体采集特征点的数量,采用了点特征和鲁棒线特征。为了显示定位方法的效果,作者计算了特定轨迹




图6 四足机器人在行走过程中的路径跟踪

Fig. 6 Path tracking diversification of quadruped robot during walking

上不同方法的成功定位次数,并找到了相应的正确特征匹配的数量。将所提出的方法与P3P定位方法进行了对比分析,从统计结果可以看出,提出的定位方法可以利用点特征和更鲁棒的线特征进行定位,总体定位成功的次数比其他方法多,绝对轨迹误差更低。对比了P3P方法与本论文方法的成功定位特征匹配的数量,结果如图7所示,箭头所指红色代表定位成功地点,蓝色代表定位失败地点。可以看出,本文的定位成功次数明显更多,且找到的正确特征匹配的数量也更多,从而表明本论文的定位方法的鲁棒性更强。




图7 两种方法的成功定位次数

Fig. 7 Number of successful localization between two methods

为了验证四足机器人可以根据雷达信息自主避开局部地图中的障碍物,将基于雷达的偏航角与基于运动学的偏航角进行了对比,如图8所示。图中的红色实线代表通过雷达信息和评价函数得到的机器人最优可行转向角度,蓝色星线代表了四足机器人本体传感计算得到的偏航角度,通过对比验证了机器人本体可以实时跟踪雷达反馈回的偏航角度。四足机器人运动过程中由于足端运动离散性会有一定的滞后,导致跟踪效果无法实

时。由试验结果得知, 四足机器人最初与障碍物的距离很近为不可通过地形, 通过避障评价函数计算得出机器人的偏航角度, 当避开障碍物后偏航角度逐渐减小并继续沿目标点行走。

四足机器人的避障运动过程如图 9 所示, 由于局部地图中障碍物的包络较大, 因此机器人会根据局部地图和雷达检测的障碍物信息, 实时完成自主避障运动。




图 8 四足机器人偏航角对比试验

Fig. 8 Comparative experiment of quadruped robot for the yaw angle



图 9 四足机器人虚拟机体模型最优避障运动方向

Fig. 9 Optimal locomotion direction for virtual trunk body model

6 结 论

本文针对四足机器人感知定位和导航算法旨在完成野外自主导航任务, 并在四足原理样机上

进行了试验验证, 得出了以下主要结论:

(1) 提出了 SLAM 全局定位算法, 实现了野外环境的地图重构和定位;

(2) 采用了基于 Dijkstra 算法的路径规划, 以实现四足机器人的全局地形自主导航任务;

(3) 在考虑四足机器人的运动和振动前提下, 应用了基于人工势场理论的四足机器人局部地图自主避障策略;

(4) 对所提出的算法进行了综合性试验, 试验结果验证了理论分析的有效性。

未来将对四足机器人在野外地形环境下的局部地图落脚点规划进行进一步的研究, 并考虑自主避障的高跟踪特性。

参 考 文 献

- [1] Kolter J, Rodgers M, Ng A. A control architecture for quadruped locomotion over rough terrain[C]. Proceedings of the International Conference on Robotics and Automation, Pasadena, USA, May 2008.
- [2] Kalakrishnan M, Buchli J, Pastor P. Learning locomotion over rough terrain using terrain templates[C]. Proceedings of the International Conference on Intelligent Robots and Systems, St. Louis, USA, December 2009.
- [3] Filitchkin P, Byl K. Feature-based terrain classification for littledog[C]. Proceedings of the International Conference on Intelligent Robots and Systems, Vilamoura-Algarve, Portugal, October 2012.
- [4] Mitchell B, Hofmann A, Williams B. Search-based foot placement for quadrupedal traversal of challenging terrain[C]. Proceedings of the International Conference on Robotics and Automation, Rome, Italy, April 2007.
- [5] Raibert M, Blankespoor K, Nelson G. Bigdog, the rough-terrain quadruped robot[J]. IFAC Proceedings Volumes, 2008, 41(2): 10822-10825.
- [6] Belter D, Labecki P, Skrzypczynski P. Map-based adaptive foothold planning for unstructured terrain walking[C]. Proceedings of the International Conference on Robotics and Automation, Anchorage, USA, May, 2010.
- [7] Belter D, Skrzypczynski P. Rough terrain mapping and classification for foothold selection in a walking robot[J]. Journal of Field Robotics, 2011, 28: 497-528.
- [8] Fankhauser P, Bjelonic M, Bellicoso C. Robust rough-terrain locomotion with a quadrupedal robot[C]. Proceedings of the In-

- ternational Conference on Robotics and Automation, Brisbane, Australia, May 2018.
- [9] Dissanayake M, Gamini. A solution to the simultaneous localization and map building (SLAM) problem[J]. IEEE Transactions on Robotics & Automation, 2013, 17(3): 229-241.
- [10] 王玉茜, 张雪涛, 闫飞, 等. 基于视觉的无人机大范围室外道路检测及拓扑地图构建[J]. 无人系统技术, 2021, 4(4): 30-39.
- [11] 尹昊, 侯婷婷, 李东光. 面向典型任务的有人/无人机协同效能评估[J]. 无人系统技术, 2021, 4(1): 62-70.
- [12] Matthew R, Ryan M. Exactly sparse extended information filters for feature-based slam[J]. The International Journal of Robotics Research, 2007, 26(4): 335-359.
- [13] Fankhauser P, Bjelonic M, Bellicoso C D. Robust rough-terrain locomotion with a quadrupedal robot[C]. Proceedings of the International Conference on Robotics and Automation, Brisbane, Australia, May 2018.
- [14] Kanoulas D, Stumpf A, Raghavan V S. Footstep planning in rough terrain for bipedal robots using curved contact patches[C]. Proceedings of the International Conference on Robotics and

Automation, Brisbane, Australia, May 2018.

- [15] 刘宇飞. 面向非预知地形的六足机器人足力优化及滑移抑制研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.

作者简介:



刘宇飞 (1988-), 男, 博士, 副研究员, 主要研究方向为仿生足式机器人技术与感知导航技术。



江 磊 (1980-), 硕士, 研究员, 主要研究方向为特种仿生机器人、地面自主系统。本文通信作者。



邢伯阳 (1990-), 男, 博士, 副研究员, 主要研究方向为仿生机器人理论与技术。



王志瑞 (1990-), 男, 博士, 副研究员, 主要研究方向为仿生机器人机械构型设计。

[引用格式] 陈洁卿, 孙瑞胜, 陈 伟. 超声速导弹群协同博弈突防制导研究[J]. 无人系统技术, 2021, 4(6): 65-74.

超声速导弹群协同博弈突防制导研究

陈洁卿, 孙瑞胜, 陈 伟

(南京理工大学能源与动力工程学院, 南京 210094)

摘要: 超声速导弹具有飞行速度快、突防能力强的特点。随着一体化防御体系的发展, 超声速导弹集群突防具有重大研究价值和现实意义。针对超声速导弹集群系统, 提出了一种协同博弈突防制导律。该制导律利用最小转弯半径思想, 将对导弹过载指令的研究转换为对导弹机动空间的研究。为了保证超声速导弹集群在突防后仍具有目标打击能力并且在协同攻击时不发生碰撞, 将目标点纳入防御方集群系统中, 并在收益函数的设计中引入目标打击能力函数和防碰撞能力函数, 使得超声速导弹集群在博弈中保留对目标打击的机动能力, 同时安全突防。最后, 利用三自由度超声速导弹模型进行仿真, 以验证所提出的协同突防制导律的有效性。所提出的协同博弈突防制导方法将目标纳入博弈模型, 拓展了矩阵博弈在协同突防方向的应用, 进一步贴近实际应用场景, 为协同突防制导的研究提供新的研究思路。

关键词: 超声速导弹群; 博弈论; 集群突防; 协同制导; 收益函数; 多拦截器

中图分类号: TJ765

文献标识码: A

文章编号: 2096-5915(2021)06-65-10

DOI: 10.19942/j.issn.2096-5915.2021.6.056

Research on Cooperative Penetration Game Guidance of Supersonic Missile Group

CHEN Jieqing, SUN Ruisheng, CHEN Wei

(The School of Energy and Power Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: Supersonic missiles have the characteristics of fast flight speed and strong penetration ability. With the development of the integrated defense system, supersonic missile swarm penetration has great research value and practical significance. Aiming at the supersonic missile cluster system, a cooperative game guidance law is proposed in this paper. The idea of minimum turning radius is used in the guidance law to convert the study of missile overload commands into the study of missile maneuver space. In order to ensure that the supersonic missile swarm still has the target strike capability after penetration and does not collide in the coordinated attack, the target position is incorporated into the defender's swarm and the target strike capability and anti-collision functions are introduced in the design of the payoff function. The capability function enables the supersonic missile swarm to retain the maneuverability to attack the target in the game, and to safely penetrate the defense at the same time. Finally, a three-degree-of-freedom high-speed unmanned aerial vehicle model is used for simulation to verify the effectiveness of the proposed cooperative guidance law. The cooperative game penetration guidance method proposed in this paper incorporates the target into the game model, expands the application of matrix game in cooperative penetration field, and is closer to actual application, providing new research ideas for the research of cooperative penetration guidance..

收稿日期: 2021-07-16; 修回日期: 2021-08-18

基金项目: 国家自然科学基金(51809138)

Key words: Supersonic Missile Group; Game Theory; Swarm Penetration; Cooperative Guidance; Payoff Function; Multiple Interceptors.

1 引言

超声速导弹已经成为一种有效的快速反应和全球打击手段,引起了各国研究者的广泛关注^[1]。鉴于其飞行速度快、突防能力强、飞行距离远、命中精度高、侵彻能力强等优势,未来的战争中,它将担负对时敏目标、移动目标和严密设防的高价值军事目标实施远程精确打击的任务。

超声速导弹飞行速度极快,大大缩短了敌防空系统反应时间,可有效击破敌防空反导系统^[2],实现有效突防。现阶段,突防研究大多是将机动突防过程抽象为二人追逃问题,进攻方突防成功与否的衡量标准是拦截导弹的最大脱靶量,从而运用最优控制和微分对策等相关理论求解得到突防策略^[3-8]。然而,用最优控制方法和微分对策来研究突防策略时,若系统模型过于复杂,即使问题的最优解存在,但在限定时间内通常也求不到解。因此,有学者提出将博弈论思想引入进突防问题的研究中。雷刚等^[9]将博弈论方法运用到导弹与动能拦截武器(EKV)的攻防问题中。陈侠等^[10]利用有限策略静态博弈模型解决了多无人机协同打击的攻防博弈问题。由于超声速导弹集群的系统模型较为复杂,且对实时性要求较高,所以本文提出一种博弈框架下的超声速导弹协同博弈突防制导律,以解决快速集群突防机动策略求解问题。值得注意的是,上述研究只考虑到攻防过程结束为止,并未进一步考虑到突防后对原定目标打击精度的影响。考虑到该需求,本文提出一种全过程收益函数,该函数将目标视为敌方博弈局中人的组成部分,建立打击能力评价函数,达到兼顾目标打击精度的目的。

除此之外,上述研究的主要对象以一对一攻防为主,并未进一步讨论集群攻防形式。伴随着战争由机械化转向信息化的过程,现代战争逐渐

变成了各体系之间的对峙^[11-14]。熊思宇等^[15]提出了基于逃逸机动并释放一枚防御器的主动防御策略的离散协同追踪-逃逸导引律。王少平等^[16]采用人工设置虚拟目标的方式进行单平台多弹多方向协同突防制导律设计。在目前的集群博弈研究中,学者更加关注目标分配的问题^[17-18],而采用集群博弈算法研究机动问题的较少^[19]。针对以上问题,本文将对机动策略的研究转换为对机动空间的研究,以简化多弹机动策略研究的复杂度,并在收益函数中引入防碰撞能力评价函数,使得超声速导弹群可以在减少自身损耗的情况下成功突防。本文的主要贡献如下。

(1)为了解决超声速导弹集群突防的问题,本文引入博弈思想,提出了一种博弈框架下超声速导弹群协同突防制导算法。该算法利用最小转弯半径这一概念,将对机动过载的研究转换为对机动空间的研究,从而简化集群博弈模型。

(2)为了保证超声速导弹群在突防后仍具有目标打击能力,本文将目标点纳入防御方集群系统中,在收益函数的设计中引入目标打击能力函数,使得我方超声速导弹群在博弈突防过程中能够最大程度地保留对目标的打击能力。

(3)为了避免集群在协同攻击时发生碰撞,削弱我方战斗力,本文将集群成员之间的空间关系考虑进收益函数的计算中,保证超声速导弹群可以安全突防。

2 超声速导弹机动能力建模

2.1 超声速导弹模型建立

由于对突防问题的研究主要考虑弹道的位置而不是姿态,因此本文忽略绕质心的转动运动,对超声速导弹的质心运动进行研究,采用如下三自由度质点运动模型^[20]:

$$\begin{cases} \frac{dV}{gdt} = n_x - \sin\theta \\ V \frac{d\theta}{gdt} = n_y - \cos\theta - V \cos\theta \frac{d\psi_V}{gdt} = n_z \\ \frac{dx}{dt} = V \cos\theta \cos\psi_V \\ \frac{dy}{dt} = V \sin\theta \\ \frac{dz}{dt} = -V \cos\theta \sin\psi_V \end{cases} \quad (1)$$

式中, V 为超声速导弹飞行速度, g 为重力加速度, θ 为弹道倾角, ψ_V 为弹道偏角, x, y, z 为超声速导弹在地面系下的位置坐标, n_x, n_y, n_z 为弹道系下的过载。

机动突防的策略核心是采用最优机动增大拦截导弹制导系统负担, 使得拦截导弹制导指令超过最大机动过载^[6]。从这一特点出发, 我们可以利用过载约束对机动能力的影响建立超声速导弹的机动能力函数。

为了描述超声速导弹的机动能力, 我们引入最小转弯半径的概念^[20]:

$$\begin{cases} \rho_y = \frac{V^2}{g(n_y - \cos\theta)} \\ \rho_z = \frac{V^2 \cos\theta}{gn_z} \end{cases} \quad (2)$$

式中, ρ_y, ρ_z 分别为当前过载条件下纵向面和水平面内最小转弯半径 (如图 1)。




图 1 转弯半径示意图

Fig. 1 Diagram of turning radius

从式(2)中可以看出, 在给定速度和弹道倾角的情况下, 过载越大, 转弯半径越小, 即最大可用过载可以得到最小转弯半径。如图 1 所示, 以水平面运动为例, 当我方超声速导弹进入拦截弹

的最小转弯半径区域内时, 敌方拦截弹无法对我方超声速导弹群进行有效拦截, 即突防成功。本文针对这一特性, 在 2.2 节建立了超声速导弹性能评价函数。

2.2 性能评价函数建立

根据 2.1 节的分析, 超声速导弹的机动能力与弹目距离、方位和过载约束等因素有关。首先定义超声速导弹 i 的纵向最小转弯半径原点 $(x_{iy0}, y_{iy0}, z_{iy0})$ 和侧向最小转弯半径原点 $(x_{iz0}, y_{iz0}, z_{iz0})$ 如下:

$$\begin{cases} x_{iy0} = x_i - \rho_{yi} \sin\theta \\ y_{iy0} = y_i + \rho_{yi} \cos\theta \\ z_{iy0} = z_i \\ x_{iz0} = x_i + \rho_{zi} \sin\psi_V \\ y_{iz0} = y_i \\ z_{iz0} = z_i + \rho_{zi} \cos\psi_V \end{cases} \quad (3)$$

导弹 i 在纵向和侧向的最小转弯半径原点与超声速导弹 j 之间的距离向量 $\bar{r}_{ijy}, \bar{r}_{ijz}$ 分别定义为:

$$\begin{cases} \bar{r}_{ijy} = (x_j, y_j, z_j) - (x_{iy0}, y_{iy0}, z_{iy0}) = (x_{ijy}, y_{ijy}, z_{ijy}) \\ \bar{r}_{ijz} = (x_j, y_j, z_j) - (x_{iz0}, y_{iz0}, z_{iz0}) = (x_{ijz}, y_{ijz}, z_{ijz}) \end{cases} \quad (4)$$

式中, (x_j, y_j, z_j) 是导弹 j 的坐标。接着对超声速导弹的攻击能力进行描述, 超声速导弹 i 对导弹 j 在纵向平面和水平面投影内的攻击能力函数 C_{yij}, C_{zij} 分别为:

$$\begin{cases} C_{yij} = \begin{cases} \frac{\sqrt{x_{ijy}^2 + y_{ijy}^2} - |\rho_{yi}|}{|\rho_{yi}|}, \sqrt{x_{ijy}^2 + y_{ijy}^2} \leq |\rho_{yi}| \\ \frac{\sqrt{x_{ijy}^2 + y_{ijy}^2} - |\rho_{yi}|}{\sqrt{x_{ijy}^2 + y_{ijy}^2}}, \sqrt{x_{ijy}^2 + y_{ijy}^2} > |\rho_{yi}| \end{cases} \\ C_{zij} = \begin{cases} \frac{\sqrt{x_{ijz}^2 + z_{ijz}^2} - |\rho_{zi}|}{|\rho_{zi}|}, \sqrt{x_{ijz}^2 + z_{ijz}^2} \leq |\rho_{zi}| \\ \frac{\sqrt{x_{ijz}^2 + z_{ijz}^2} - |\rho_{zi}|}{\sqrt{x_{ijz}^2 + z_{ijz}^2}}, \sqrt{x_{ijz}^2 + z_{ijz}^2} > |\rho_{zi}| \end{cases} \end{cases} \quad (5)$$

从式(5)中可以看出, 能力函数 C_{yij}, C_{zij} 小于 0 说明超声速导弹 i 没有能力命中导弹 j ; 反之, 能力函数大于 0 说明超声速导弹 i 具有命中导弹 j 的能力。由于在实际飞行中, 存在如掉头反向飞

行等特殊情况。因此,本文对特殊位置下的能力函数进行如下约束:

- (1) 当 $|\bar{r}_{ij}| < \varepsilon$ 时 (ε 为极小值), C_{yij}, C_{yji} 均为 1, 当 $|\bar{r}_{iz}| < \varepsilon$ 时 (ε 为极小值), C_{zij}, C_{zji} 均为 1;
- (2) 当 $|n_y - \cos\theta| < \varepsilon$ 时, $C_{yij} = 0$;
- (3) 当 $\rho_{yi} < 0$, $y_{ij} < x_{ij} \tan\theta$ 或 $\rho_{yi} > 0$, $y_{ij} > x_{ij} \tan\theta$ 时, $C_{yij} = -1$; 当 $\rho_{zi} < 0$, $z_i < z_j$ 或 $\rho_{zi} > 0$, $z_i > z_j$ 时, $C_{zij} = -1$ 。

3 超声速导弹群攻防博弈模型建立

博弈模型的建立在于博弈三要素的设计,本文局中人的集为{我方超声速导弹集群,敌方防御系统}。其中,敌方防御系统包括拦截弹集群和目标。局中人的策略集在 3.1 节建立,局中人的收益函数在 3.2 节建立。

3.1 攻防双方的策略集

超声速导弹群作为进攻方,作战目的是使自己生存率最大的情况下命中敌方目标;防御方由拦截弹集群和目标组成,作战目的是减少超声速导弹集群对自己造成的损失。考虑到敌方作为防守方,可以通过探测设备提前获取我方攻击弹数量并做出反应。因此,本文假设拦截弹个数为 n_2 , 我方超声速导弹个数为 n_1 , 且 $n_2 \geq n_1$, 同时将三维运动分解为纵向面和水平面的运动,分别进行博弈策略的计算。由于本文的研究对象是集群整体,因此这里采用的策略集为集群成员的策略组合。我方集群法向和侧向机动策略集分别为 S_{1y} 和 S_{1z} , 敌方集群法向和侧向机动策略集分别为 S_{2y} 和 S_{2z} 。

3.2 零和博弈收益函数设计

在博弈机动的研究中,多数学者将收益函数设计为拦截面脱靶量,但没有考虑到突防后继续打击目标的能力以及协同突防中遇到的集群碰撞问题。针对以上问题,本节提出了一种收益函数的构造方法。这种收益函数由 3 部分组成,分别为突防能力、目标打击能力和防碰撞能力。由于

攻防博弈问题是一种典型的零和博弈问题,因此本节只对我方收益函数进行描述,并且纵向和侧向机动博弈的收益函数构造方法一致。

3.2.1 突防能力

超声速导弹 i 的突防能力可以由下式得到:

$$T_i = \frac{\sum_{j=1}^{n_2} -C_{ji}}{n_2} \quad (6)$$

式中,下标 j 表示拦截弹集群成员。考虑我方超声速导弹群整体应保证尽量多的超声速导弹成功突防,因此我方集群突防总能力 T_1 设计为:

$$T_1 = \min(T_i), i=1, \dots, n_1 \quad (7)$$

3.2.2 目标打击能力

目标打击能力是指超声速导弹在突防后仍能打击目标的能力。从过载角度来说,只要目标在当前过载策略打击范围内,就可以采用一定的制导律实现精确打击。因此,本文将超声速导弹群对目标的打击能力 D_1 定义为:

$$D_1 = \frac{\sum_{i=1}^{n_1} C_{it}}{n_1} \quad (8)$$

式中,下标 t 表示目标。

3.2.3 防碰撞能力

防碰撞能力是指集群成员之间保持安全距离的能力。本文采用防碰撞预警范围(如图 2)对集群成员间距离进行描述。




图 2 防碰撞预警范围示意图

Fig. 2 Diagram of anti-collision warning ranges

图 2 中, R 为成员间距离, R_1 为碰撞警告半径, R_2 为碰撞预警半径。描述防碰撞能力 P 如下:

$$P = \begin{cases} -1, & R \leq R_1 \\ \frac{R - R_1}{R_2 - R_1}, & R_1 < R \leq R_2 \\ 0, & R > R_2 \end{cases} \quad (9)$$

除了我方集群的防碰撞能力会影响我方最终收益,敌方集群的防碰撞能力也会影响整体局势,从而对我方收益造成影响。考虑超声速导弹群整体,防碰撞能力 P_1 设计为:

$$P_1 = \min(P_i) - \min(P_j), i = 1, \dots, n_1, j = 1, \dots, n_2 \quad (10)$$

式中, P_i 和 P_j 分别为我方和敌方成员导弹的防碰撞能力值。

3.2.4 收益函数计算

以上 3 部分对收益函数的影响比重不一样,且随着两个集群间距离的变化而变化。因此,收益函数定义如下:

$$W_1 = \eta_T(t)T_1 + \eta_D(t)D_1 + \eta_P(t)P_1 \quad (11)$$

式中, $\eta_T(t)$ 、 $\eta_D(t)$ 、 $\eta_P(t)$ 为权值函数,满足 $\eta_T(t) + \eta_D(t) + \eta_P(t) = 1$ 。

对上述收益函数求解纳什均衡解,就可以得到机动策略。需要说明的是,在博弈初期,各策略集的收益函数差别不大,可以选择任意一个纳什均衡解作为试探性机动策略。

3.3 零和博弈纳什均衡解求解

博弈问题的求解就是要寻找一个稳定的策略组合,这个策略组合有一个特点,即每个博弈方的策略选择,都是相对于其他博弈方的最优策略选择,这就引出了纳什均衡的概念。

定义 1^[21]: 对于有 2 个博弈方参与的博弈 $Z = \{S_1, S_2; W_1, W_2\}$ 中,其中 S_1, S_2 分别为局中人 1 和局中人 2 的策略集合, W_1, W_2 分别为局中人 1 和局中人 2 的收益,如果在由每个博弈方的一个策略所组成的策略组合 (z_1^*, z_2^*) 中,其中任一博弈方 i 的策略 z_i^* , 都是应对其他博弈方组合的最佳策略,也即

$$W_i(z_i^*) \geq W_i(z_i^j) \quad (12)$$

对任意 $z_i^j \in S_i$ 都成立,则称 (z_1^*, z_2^*) 为博弈的一个纳什均衡。

本文将纳什均衡求解过程简化为最优问题,采用如下优化过程进行求解。

如图 3 所示,图中是以敌我双方为自变量的我方收益值。首先对每列求最大值,找到在同一敌方策略条件下我方能获得的最大收益;然后对每行求最小值,找到在同一我方策略条件下敌方能获得的最大收益。对两组最优值的位置进行分析,得出同时满足两个条件的策略值。若无解,则对次优解进行分析,直至找到双方满意的策略。在这个过程中,存在两种特殊情况,一是有多个策略满足最优解,二是找到最后没有纳什均衡解。在上述情况下,设定双方选择各自策略集中的第一个策略解。




图 3 纳什均衡解求解示意图

Fig. 3 Diagram of solving Nash equilibrium solution

4 仿真实验

4.1 仿真条件

本章分别从拦截弹采用拦截策略和比例导引律两种情况对本文提出的突防制导律进行仿真实验。为了区分敌我双方仿真条件及结果,记下标 1 为我方,下标 2 为敌方。敌我双方集群成员初始状态如表 1 所示。

我方轴向过载为 $n_{x1} = -0.8$, 我方轴向过载为 $n_{x2} = 0.2$, 目标点坐标为 $(60, 0, 0)$ km。权值函数设置为 $\eta_T = 0.0000067(\max(x_2) - \min(x_1)) + 0.4$,

表1 敌我双方集群成员初始状态
Table 1 Attacker and defender's initial states

状态 编号	$\theta_0/(^\circ)$	$\psi_0/(^\circ)$	$V_0/(m/s)$	x_0/km	y_0/km	z_0/km
我方#1	-20	0	2500	0	40	1.5
我方#2	-20	0	2500	0	40.5	0.5
我方#3	-25	0	2500	0	39.5	-0.5
敌方#1	60	0	2000	60	0	-0.1
敌方#2	60	0	2000	60	0.5	0.05
敌方#3	60	0	2000	60	0.2	0
敌方#4	60	0	2000	60	0.3	-0.01

$\eta_T(0)=0.8, \eta_P=0.05$ 。警告距离 $R_1=200$ m, 预警距离 $R_2=1000$ m。设每个博弈阶段持续时间为 0.5 s, 拦截弹个数为 4 , 我方导弹个数为 3 。当拦截弹与目标机动比大于 2 时, 就能产生较小的拦截脱靶量^[22], 不利于突防。因此这里假设拦截弹侧向最大过载为 $6g$, 法向最大过载为 $20g$; 超声速导弹侧向最大过载为 $3g$, 法向最大过载为 $10g$, 这里采用的策略集为集群成员的策略组合(见表2~表3)。其中, $n_{yk\#m}, n_{zk\#m}(k=1,2;m=1,2,3,4)$ 为集

群成员导弹的过载指令, $n_{yk\#m} < 0$ 表示导弹垂直向下机动, $n_{yk\#m} > 0$ 表示导弹垂直向上机动, $n_{zk\#m} < 0$ 表示导弹从导弹尾部看向左机动, $n_{zk\#m} > 0$ 表示导弹从导弹尾部看向右机动。策略集分别为 $S_{1y} = \{S_{1y1} \cdots S_{1y8}\}, S_{1z} = \{S_{1z1} \cdots S_{1z8}\}, S_{2y} = \{S_{2y1} \cdots S_{2y16}\}, S_{2z} = \{S_{2z1} \cdots S_{2z16}\}$ 。

4.2 仿真结果

4.2.1 拦截弹采用拦截策略下的验证结果

从图4可以看出, 在突防/拦截结束时, 我方纵向面和水平面的收益值都大于 0 , 这意味着我方集群在攻防博弈中处于有利形势。在博弈初始阶段, 我方收益值小于 0 , 这说明在博弈初期, 攻防双方都有着较大的机动空间, 拦截集群的机动性能优于我方超声速导弹集群, 具备拦截能力。但是随着我方集群根据当前空间位置关系进行实时机动, 收益值随之增加, 到了突防/拦截结束时, 获得了正收益。

从图5~6中可以看出, 突防能力、目标打

表2 敌我双方纵向机动博弈策略集
Table 2 Attacker and defender's longitudinal game strategy sets

策略号	$n_{y1\#1}$	$n_{y1\#2}$	$n_{y1\#3}$	策略号	$n_{y2\#1}$	$n_{y2\#2}$	$n_{y2\#3}$	$n_{y2\#4}$	策略号	$n_{y2\#1}$	$n_{y2\#2}$	$n_{y2\#3}$	$n_{y2\#4}$
S_{1y1}	-10	10	10	S_{2y1}	-20	-20	-20	-20	S_{2y9}	20	-20	-20	-20
S_{1y2}	-10	10	-10	S_{2y2}	-20	-20	-20	20	S_{2y10}	20	-20	-20	20
S_{1y3}	-10	-10	10	S_{2y3}	-20	-20	20	-20	S_{2y11}	20	-20	20	-20
S_{1y4}	-10	-10	-10	S_{2y4}	-20	-20	20	20	S_{2y12}	20	-20	20	20
S_{1y5}	10	10	10	S_{2y5}	-20	20	-20	-20	S_{2y13}	20	20	-20	-20
S_{1y6}	10	10	-10	S_{2y6}	-20	20	-20	20	S_{2y14}	20	20	-20	20
S_{1y7}	10	-10	10	S_{2y7}	-20	20	20	-20	S_{2y15}	20	20	20	-20
S_{1y8}	10	-10	-10	S_{2y8}	-20	20	20	20	S_{2y16}	20	20	20	20

表3 敌我双方集群侧向机动博弈策略集
Table 3 Attacker and defender's lateral game strategy sets

策略号	$n_{z1\#1}$	$n_{z1\#2}$	$n_{z1\#3}$	策略号	$n_{z2\#1}$	$n_{z2\#2}$	$n_{z2\#3}$	$n_{z2\#4}$	策略号	$n_{z2\#1}$	$n_{z2\#2}$	$n_{z2\#3}$	$n_{z2\#4}$
S_{1z1}	3	3	3	S_{2z1}	-6	-6	-6	-6	S_{2z9}	6	-6	-6	-6
S_{1z2}	3	3	-3	S_{2z2}	-6	-6	-6	6	S_{2z10}	6	-6	-6	6
S_{1z3}	3	-3	3	S_{2z3}	-6	-6	6	-6	S_{2z11}	6	-6	6	-6
S_{1z4}	3	-3	-3	S_{2z4}	-6	-6	6	6	S_{2z12}	6	-6	6	6
S_{1z5}	-3	3	3	S_{2z5}	-6	6	-6	-6	S_{2z13}	6	6	-6	-6
S_{1z6}	-3	3	-3	S_{2z6}	-6	6	-6	6	S_{2z14}	6	6	-6	6
S_{1z7}	-3	-3	3	S_{2z7}	-6	6	6	-6	S_{2z15}	6	6	6	-6
S_{1z8}	-3	-3	-3	S_{2z8}	-6	6	6	6	S_{2z16}	6	6	6	6

击能力和防碰撞能力的收益值在突防/拦截结束时皆大于 0，这表明我方集群在具备对目标打击能力的情况下可以成功突防，且集群内无碰撞。其中，水平面内突防收益值较小，这是由于水平面速度分量较小，且在侧向机动能力小于纵向机动能力的情况下，水平面机动空间远小于纵向面机动空间，超声速导弹集群躲避困难。




图 4 我方收益值
Fig. 4 Attacker's payoff value





图 5 我方纵向面收益值分量
Fig. 5 Attacker's longitudinal payoff value

图 7~8 是敌我双方的机动指令曲线。由于本文只给了有限策略集，因此导弹为了达到期望的机动效果，会不断切换指令。并且策略集中的机动指令越大，切换的越频繁，这一现象在图 8 的法向过载图中尤为明显。图 9~10 是弹道轨迹图，可以看出，在整个博弈过程中，我方超声速导弹




图 6 我方水平面收益值分量
Fig. 6 Attacker's lateral payoff value

集群没有出现碰撞和被拦截的情况。在图 9 中可以看到，由于突防能力(7)设计为超声速弹群突防能力的最小值，因此拦截弹群主要对超声速导弹 #3 进行拦截，且拦截弹群在后期已经不具备拦截能力。因此，弹道向下，以期望拉开与超声速导弹集群之间的距离，使得超声速导弹集群回到自己的攻击区内。由于导弹速度快，弹目距离短，我方导弹为了打中目标，机动指令切换次数较少。超声速导弹 #1 和 #2 的初始弹道倾角绝对值较小，在一开始采用正过载来躲避拦截，在敌我集群距离进一步缩短后，探测到拦截弹威胁降低，采用负过载用于打击目标。超声速导弹 #3 初始弹道倾角绝对值较大，为了避免与拦截弹正面碰撞，采用低伸弹道进行躲避，后期采用正过载以保证打击目标的射程要求。从图 8 中可以看到，在博弈初期，敌我集群相距较远，各方处在试探机动阶段。随着距离缩短，双方开始出现目的性机动。在博弈初期，由于超声速导弹群不在目标点 $z=0$ 附近，因此初始试探机动主要目的为打中目标。随着拦截弹群向超声速导弹集群方向移动，超声速导弹 #3 先进行了躲避，安全后调整为打击目标。超声速导弹 #1 大部分时间用于躲避拦截，在后期打击目标的需求增大后，进行了侧向指令的切换。




图7 我方超声速导弹最大需用过载
Fig. 7 Attacker's maximum overload




图8 敌方拦截弹最大需用过载
Fig. 8 Defender's maximum overload




图9 纵向面运动轨迹
Fig. 9 Longitudinal trajectory

4.2.2 拦截弹采用比例导引律下的验证结果

相比于使用拦截策略，采用比例导引律制导的拦截弹由于加入了针对突防弹的导引，使得突防形势更为严峻。从图 11 可以看出，在突防/拦截结束时，我方集群在攻防博弈中处于有利形势。

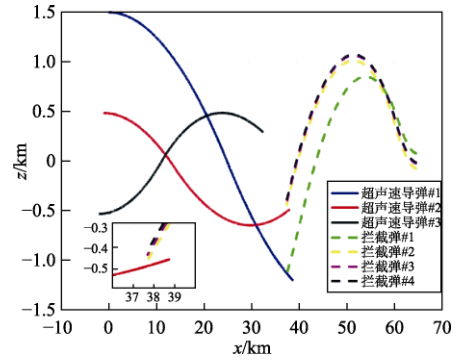


图10 水平面运动轨迹
Fig. 10 Lateral trajectory

从图12~13中可以看出，能力收益值在突防/拦截结束时皆大于0，数值上相比于4.2.1节更接近于0。这是由于超声速导弹群为了尽可能躲避拦截弹，牺牲了较多打击能力。




图11 我方收益值
Fig. 11 Attacker's payoff value




图12 我方纵向面收益值分量
Fig. 12 Attacker's longitudinal payoff value




图 13 我方水平面收益值分量
Fig. 13 Attacker's lateral payoff value

由于超声速导弹群在博弈时仍假想拦截弹群采用博弈策略, 因此在指令的切换规律以及弹道规律上与 4.2.1 节基本一致 (图 14)。从图 15 可以看出, 拦截弹群越靠近超声速弹群, 其制导指令越大, 在末段进行较大机动, 但仍未拦截成功。从图 16~17 可以看出, 拦截弹有针对性地进行了目标分配, 并实施拦截打击, 但由于博弈过程速度快, 时间短, 拦截弹群在超声速导弹突防机动的情况下未能及时抓住拦截时机。




图 14 我方超声速导弹最大需用过载
Fig. 14 Attacker's maximum overload




图 15 敌方拦截弹最大需用过载
Fig. 15 Defender's maximum overload




图 16 纵向面运动轨迹
Fig. 16 Longitudinal trajectory




图 17 水平面运动轨迹
Fig. 17 Lateral trajectory

5 结 论

本文研究的目的是针对超声速导弹群设计一种基于博弈思想的协同制导律。所提出的博弈制导律的主要优点是将导弹的机动能力作为博弈的收益函数的主要设计依据,从而简化设计。所设计的收益函数的主要贡献是考虑了突防后目标打击能力和群组间防碰撞能力,更加具备实战化的应用优势。仿真结果验证了所提出的博弈协同制导律可以有效安全突防并具备目标打击能力。本文为超声速导弹集群多对多攻防研究提供了一种新的解决方案。

参 考 文 献

- [1] Xu B, Shi Z K. An overview on flight dynamics and control approaches for hypersonic vehicles[J]. Science China Information Sciences, 2015, 58(7): 1-19.
- [2] 叶喜发, 张欧亚, 李新其, 等. 高超声速巡航导弹的作战运用及对未来战争的影响[J]. 飞航导弹, 2019, 412(4): 47-50.
- [3] 雍恩米, 唐国金, 罗亚中. 弹道导弹中段机动突防制导问题的仿真研究[J]. 导弹与航天运载技术, 2005(4): 13-18.
- [4] 周啟航, 张刘, 霍明英, 等. 弹道导弹中段突防弹道设计与验证[J]. 光学精密工程, 2015(9): 2645-2655.
- [5] 孙守明, 汤国建, 周伯昭. 基于微分对策的弹道导弹机动突防研究[J]. 弹箭与制导学报, 2010, 30(4): 65-68.
- [6] 史晓丽, 刘永才, 王长青. 飞航导弹反拦截最优机动策略研究[J]. 战术导弹技术, 2007(3): 7-11.
- [7] 郭杨, 姚郁, 王仕成, 等. 基于有限时间 H_2 性能指标的导弹机动突防策略设计[J]. 宇航学报, 2010(10): 2289-2294.
- [8] 时晨光, 丁琳涛, 周建江. 基于 Stackelberg 博弈的有人机/无人机混合集群辐射功率控制算法[J]. 无人系统技术, 2020, 3(4): 29-41.
- [9] 雷刚, 田海鹏, 鲜勇, 等. 基于博弈论的导弹机动突防策略研究[J]. 固体火箭技术, 2014(3): 291-294.
- [10] 陈侠, 李光耀, 赵凉. 多无人机协同打击任务的攻防博弈策略研究[J]. 火力与指挥控制, 2018, 43(11): 17-23.
- [11] 张凯杰, 林浩申, 夏冰. 导弹集群智能突防技术的新发展[J]. 战术导弹技术, 2018, 191(5): 1-5.
- [12] 赵启伦, 陈建, 董希旺, 等. 拦截高超声速目标的异类导弹协同制导律[J]. 航空学报, 2016, 37(3): 936-948.
- [13] 肖增博, 雷虎民. 防区外多导弹协同突防复合制导研究[J]. 现代防御技术, 2011, 39(1): 63-67.
- [14] 丁达理, 谢磊, 王渊. 有人机/无人机协同作战运用及对战争形态影响[J]. 无人系统技术, 2020, 3(4): 1-9.
- [15] 熊思宇, 李刚, 王华吉, 等. 三体对抗中的微分对策协同突防策略[J]. 空军工程大学学报(自然科学版), 2018, 19(4): 83-89.
- [16] 王少平, 董受全, 李晓阳, 等. 助推滑翔高超声速反舰导弹多方向协同突防可行性研究[J]. 指挥控制与仿真, 2017, 39(2): 55-60.
- [17] 韩玉龙, 严建钢, 陈榕, 等. 改进博弈论的舰载无人机编队协同对海突击目标分配[J]. 火力与指挥控制, 2016(7): 65-70.
- [18] 任敏, 王克波, 沈林成. 多UAV协同突防规划与仿真[J]. 控制与决策, 2011(1): 157-160.
- [19] 谭目来, 朱文强, 刘远飞. 基于机动动作库的UCAV逃逸机动决策[J]. 无人系统技术, 2020, 3(4): 73-92.
- [20] 钱杏芳, 林瑞雄, 赵亚男. 导弹飞行力学[M]. 北京: 北京理工大学出版社, 2013.
- [21] 郎艳怀. 博弈论及其应用[M]. 上海: 上海财经大学出版社, 2015.
- [22] 马骏声. 博弈论——机动弹头攻防的核心[J]. 航天电子对抗, 2006, 22(1): 4-6.

作者简介:



陈洁卿 (1996-), 女, 博士研究生, 主要研究方向为导弹制导与控制理论与技术。



孙瑞胜 (1978-), 男, 博士, 教授, 主要研究方向为导弹制导与控制理论与技术。本文通信作者。



陈伟 (1987-), 男, 博士, 副教授, 主要研究方向为导航理论与技术。

[引用格式] 刘华伟, 田百义, 呼延奇, 等. 一种火星多任务探测器系统概念设计[J]. 无人系统技术, 2021, 4(6): 75-81.

一种火星多任务探测器系统概念设计

刘华伟, 田百义, 呼延奇, 李伟杰

(北京空间飞行器总体设计部, 北京 100094)

摘要: 随着在轨组装技术的发展, 大型空间系统设计及其空间应用逐渐受到关注。大型模块化火星探测器可以同时执行多种探测任务, 实现对火星的综合勘察。首先调研分析了国外关于火星轨道空间环境的相关探测任务, 对探测器载荷、轨道策略进行了分析。其次, 针对前期模块化深空探测器研究基础, 重点分析了火星探测的多项任务规划, 提出了一种火星多任务探测器系统的任务序列设想, 包括表面遥感、环境详查、表面详查以及数据中继等。然后, 通过对火星多任务探测器系统的功能分析与定义, 给出了探测器系统的初步概念设计, 包括母体飞行器、中继星、多类型探测器、轨道转移飞行器等。最后, 按照地火转移、火星捕获、轨道转移以及探测器任务轨道部署等开展了初步策略分析, 为多任务探测器系统的各模块探测与轨道转移等提出了轨道方案。关于火星多任务探测实施、探测器系统功能定义以及系统轨道策略分析等, 有望为我国后续深空探测任务规划以及新型深空探测器论证提供参考。

关键词: 火星探测; 多任务探测; 模块化; 在轨组装; 轨道策略; 电推进

中图分类号: V19 **文献标识码:** A **文章编号:** 2096-5915(2021)06-75-07

DOI: 10.19942/j.issn.2096-5915.2021.6.057

Conceptual Design of A Probe System for the Mars Multitask Exploration

LIU Huawei, TIAN Baiyi, HU Yanqi, LI Weijie

(Beijing Institute of Spacecraft System Engineering, Beijing 100094, China)

Abstract: With the development of on-orbit assembly technology, the design of large-scale space system and its application in space have been paid more and more attention. The large modular Mars probe will be able to carry out multiple missions at the same time to achieve a comprehensive exploration of Mars. A logic review is first conducted for the reported missions for the space exploration around the Mars orbit, and related payloads and orbit strategy are further investigated. Then, based on the existing research on the modular spacecraft for deep space exploration, main attention is paid to with the analysis of mission task and potential list of multitask exploration including space condition, and this paper addresses a probe system for the Mars multitask exploration, including remote sensing detection, detailed survey of the environment, detailed investigation of the surface, communication relay. Conceptual design is then presented for the probe system on the function analysis, including main vehicle, TDRS, multitype detector, orbital transfer vehicle. Detailed orbit strategy is proposed from the orbit to the Mars, orbital acquisition and the final exploration for the detection and transferring of the module in the multitask exploration system. Those investigations of multitask exploration plan, analysis of the function and orbit strategy will be favorable for the task plan and development of new probes for deep space exploration.

Key words: Mars Exploration; Multitask Exploration; Modular; On-orbit Assembly; Orbit Strategy; Electric Propulsion

1 引言

国外火星探测已经历半个多世纪的发展^[1],开展火星探测和研究,对于认识人类居住的地球环境,特别是认识地球的长期演化过程,具有非常重要的科学意义。根据火星及其他深空探测任务经验,人类开展火星探测的主要科学目标包括^[2-6]:寻找生命存在痕迹;了解火星上水的存在及消失的过程;了解火星大气和气候的演化过程;了解火星物理场和内部结构的演变;掌握火星的地貌和地质特征。

国外已成功开展的火星环绕探测任务包括早期的水手3号、水手4号、水手9号、火星全球勘探者、火星探路者、火星奥德赛轨道器、欧洲“火星快车”、火星勘测轨道器,以及后来的火星大气与挥发物演化轨道器等。上述任务的顺利实施为火星着陆探测提供了必要的火星大气、地形地貌等空间环境数据支撑,如典型火星着陆探测任务海盗号、勇气号、机遇号、凤凰号、好奇号、洞察号等。2021年5月15日,天问一号“祝融号”火星车成功着陆于火星乌托邦平原南部预选着陆区。中国首次火星探测任务着陆火星取得圆满成功,成为继美国后,第二个成功着陆在火星上的国家。

目前,火星探测任务普遍相对单一,主要针对轨道空间及着陆巡视进行既定的、相对有限的探测任务进行开展。随着在轨组装与服务技术发展,未来通过大型探测器系统对火星及其他深空领域进行探测将逐渐成为可能。例如,美国已提出深空关口站、大型火星探测转移飞行器、布置于SEL2的超大型空间望远镜系统构建及其在轨服务任务设想等。统计和研究发现^[7],国内外关于在轨组装、在轨服务的系统级航天器任务,包括已成功实施的和其他公开报道的,已经超过130个。且随着空间机器人和航天器工程技术的飞速发展,这个领域的发展将日趋受到关注。

在地火转移策略研究方面,从地球到火星的飞行方式包括脉冲转移和小推力转移等,其中最常采用的方式是脉冲转移^[8],并在已经实施的火

星探测任务中广泛采用。近年来,随着以电推进、太阳帆等为代表的小推力推进系统的发展和应用,小推力推进以其高比冲、低消耗的优势,逐渐成为深空探测任务的首选推进方式^[9]。

在前期研究的基础上^[10],本文进一步论证火星探测的必要性,分析研究火星探测的任务序列,确定火星多任务探测器的功能体系,提出火星多任务探测器概念设计和任务实施设想,并分析其关键技术体系,为后续相关研究做好支撑,也为我国火星及深空探测器任务规划提供参考。

2 多任务探测设想

通过对国外已成功实施的火星探测任务的调研分析(如表1所示)可以看出,探测任务主要包括火星表面形貌、大气成分、射线、离子体、磁场等火星空间环境探测。探测器的轨道设计主要包括:飞越探测、环火探测,以及正圆形约400 km高、大椭圆轨道近火500 km/远火80000 km等,这些轨道都是针对特定的火星空间环境探测需求进行设计的。同时,由于火星探测的长距离通信难题,使得有些火星探测器还兼顾与地球数据中继的任务,比如火星奥德赛探测器。此外,火星空间环境探测的有效载荷主要包括以下几类^[11-12]。

(1) 成像探测:火星彩色相机、雷达、高分辨率成像仪、热红外成像光谱仪、小型勘测成像光谱仪等;

(2) 大气探测:气候探测仪、火星外层大气中性成分分析仪、火星甲烷探测器、离子体探测包、莱曼-阿尔法光度计、电子反射计等;

(3) 射线探测:射线谱仪、发射频谱仪、辐射测试仪、紫外稳定振荡器、高能中子探测器等;

(4) 磁场探测:磁强计等;

(5) 高度探测:激光高度计等。

受限于运载,火星探测器一般仅配置有限几种有效载荷,对火星大气或星表进行探测,难以实现火星的全面探测。本文在在轨组装的基础上,开展多任务探测系统设计,提高火星探测任务的系统效能。在陆空协同情况下^[13],考虑火星环绕、

表 1 国外已成功实施的火星空间环境典型探测任务
Table 1 Typical missions to the Martian space environment successfully carried out abroad

序号	任务	年份	主要任务	轨道高度	备注
1	水手-4 (Mariner 4)	1964	火星轨道环境探测	距火星表面 9846 km, 飞越探测	任务成功
2	火星全球勘测者 (Mars Global Surveyor, MGS)	1996	火星表面大气层和磁层的情况	轨道高度 378 km, 接近正圆形, 且经过极点正上方附近 (倾斜角度 93°), 以太阳同步轨道环绕火星	任务成功
3	火星奥德赛 (Mars Odyssey)	2001	寻找水与火山活动的迹象, “奥德赛”号同样扮演了通信中继站的角色	一个接近太阳同步轨道的 400 km 圆形极轨道; 又—报道: 距火星表面不到 157 km, 半长轴 3785 km, 轨道倾角 93.2°	任务成功
4	火星勘测轨道器计划 (Mars Reconnaissance Orbiter, MRO)	2005	继续寻找火星上存在水的证据, 并表征火星、气候与地质特征, 还将承担火星着陆探测	环绕轨道, 离表面最近点的高度约 420 km	任务成功
5	“曼加里安”火星探测轨道器 (Mars Orbiter Mission, MOM)	2013	探索火星表面地形、矿物分布和火星大气。	近火点 500 km、远火点 80,000 km 的火星轨道	任务成功

着陆、采样等任务过程, 火星多任务探测器系统的任务序列设想主要包括:

(1) 兼顾地火数据中继: 通过中继星多星系统配置, 建立火星与地球间的中继数据传输链路, 为安全高效地实施火星多任务探测提供全天时数据链路保障;

(2) 火星表面详查: 通过配置相应数量的遥感探测器, 实现火星表面的全球覆盖, 绘制详实的火星表面形貌图, 也可为后续火星表面着陆探测提供数据支撑;

(3) 火星空间环境详查: 主要是火星大气环境的详查, 通过配置相应探测器, 获取不同高度火星大气环境的立体数据, 建立丰富的火星大气环境数据库, 为更安全更合理的火星 EDL (进入、减速和着陆) 探测任务规划与实施奠定重要基础;

(4) 火星表面探测: 通过着陆巡视器着陆至火星表面并进行巡视探测, 获取火星表面的探测数据, 可按任务配置对火星表面样品及一定深度的土壤、岩石等进行特性研究。

3 探测器组成与功能定义

随着智能自主在轨组装技术的发展^[14], 模块化航天器系统设计水平逐渐提高^[15]。根据上述火星探测任务分析研究, 结合前期基于模块化在轨组装与维护技术所构建的火星多任务探测器系统设想^[10], 火星多任务探测器可以配置多种类型,

分批发射并在近地轨道在轨组装^[16]。整个探测器系统除包含上述着陆巡视探测器、全球遥感探测器、大气详查探测器、数据中继星之外, 还包括母体飞行器以及轨道转移飞行器, 初步构型设想如图 1 所示。轨道转移飞行器位于组合体最下端, 为不同阶段组合体及各类探测器的轨道转移提供动力, 母体飞行器为组合体的组装与转移等提供基本基体, 其上配置大型柔性太阳翼、可展开辐射器、可移动操作机器人等模块, 解决大型系统供电、热控和组装操作等问题。母体飞行器上端配置扩展桁架, 扩展桁架侧面可安装多类探测器、敏感器等, 如全球遥感探测器、大气详查探测器、数据中继星等, 组合体最上端安装着陆巡视器, 可在火星表面着陆执行星表巡视探测任务。各类探测器的具体功能详见表 2。通过各类飞行器任务实施及按需接受服务, 实现系统的火星探测任务。




图 1 火星多任务探测器 (组合体) 基本构型设想及其组成
Fig. 1 Basic configuration and composition of the Mars multi-mission probe (combination)

表2 火星多任务探测器系统组成、功能定义及配置数量

Table 2 System composition, function definition and configurations of Mars multi-mission

序号	模块探测器名称	对应功能	配置数量
1	母体飞行器	为组合体组装、地火转移提供母体功能，同时也为后续其他探测器维护提供燃料储存与能源保证	1
2	数据中继星	提供地火间数据链路	9
3	火星全球遥感探测器	火星全球表面形貌等基本特征的遥感探测	3
4	火星大气详查探测器	利用火星大气摄动效应缓慢进入，并在此过程中实时进行火星大气环境探测	1
5	着陆巡视器	实施 EDL，进行火星表面巡视探测	1
6	轨道转移飞行器	在组合体到达火星轨道后，除母体飞行器外，由转移飞行器将各类飞行器运输转移至任务轨道，并在后续任务中，按需为各类飞行器实施轨道转移	1

4 探测器飞行任务轨道分析

4.1 地火转移策略

火星多任务探测器系统有别于一般的火星探测任务，该系统由母体飞行器、轨道运输飞行器和多个不同的任务探测器组合而成，系统总质量将达数十吨的规模。文献[10]对该系统用于地火转移的推进提出了初步的需求。本文主要瞄准未来火星在轨服务为目标，根据相关研究报告^[17-20]，为实现长周期、火星多任务探测，采用小推力转移策略是本项工作的优选方案，本文重点开展小推力飞行轨道的优化设计。以卫星总质量 10 t 为例，地火转移阶段分别采用 100 kW 和 200 kW 推力器，则探测器由地球飞往火星的星际转移段燃料和时间需求见表 3。探测器地火转移阶段的燃料消耗随推力器功率的增大而减小；发动机比冲越大，对应所需的燃料也越少。例如，200 kW 的 2 N 推力器完成星际转移所需燃料最少，约

0.62 t，探测器到达火星时的剩余质量为 9.38 t，整个星际飞行时间约 852 天。地火转移轨道示意图如图 2 所示。

4.2 火星捕获及轨道间转移任务

4.2.1 环火轨道选择

一般地，环火轨道可以选择极轨圆轨道、冻结大椭圆轨道、火星倾斜同步轨道、静止轨道等。除了静止轨道，其余轨道均存在倾角，火星的非球形摄动将造成轨道升交点赤经的进动。这一特点将造成探测器向其他轨道转移时，除进行倾角调整外，还需进行升交点赤经的调整，这对系统的整体优化设计不利。此外，从火星捕获的速度增量需求角度考虑，探测器进入火星引力范围时的到达 C3 为零，环火轨道倾角等参数在到达火星引力范围附近即可达到目标值，无须额外的变轨。不妨取探测器始终沿速度反向进行减速，则探测器所需的速度增量仅与目标环火轨道的半长轴相关。因此，选择不同类型轨道对火星捕获的

表3 地火转移方案

Table 3 Transfer program from earth to Mars

项目	地火转移推进方案			
	2N 推力 (5000 s 比冲)	2N 推力 (10000 s 比冲)	5N 推力 (2000 s 比冲)	5N 推力 (4000 s 比冲)
推进系统功率需求/kW	100	200	100	200
探测器初始质量/t	10	10	10	10
发射日期/(年/月/日)	2033-01-25	2033-01-24	2033-3-11	2033-03-10
到达日期/(年/月/日)	2034-01-28	2034-02-02	2033-12-04	2033-12-08
飞行时间/天	369	374	268	274
点火时间/天	315	324	121	130
燃料消耗/t	1.12	0.6	2.66	1.43
到达火星剩余质量/t	8.88	9.40	7.34	8.57

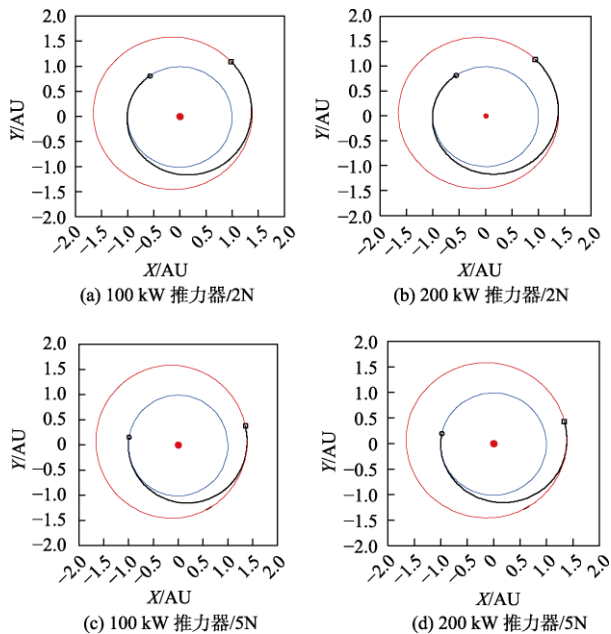


图 2 地火转移轨道示意图
Fig. 2 Schematic diagram of transfer track from earth to Mars

速度增量影响较小。为便于母体飞行器释放各项任务探测器,同时减小轨道摄动对环火轨道的影响,初步设计母体飞行器的轨道为火星静止轨道。火星静止轨道参数如下:

- (1) 轨道半长轴: 20427.71 km;
- (2) 轨道高度: 17030.71 km;
- (3) 偏心: 0;
- (4) 倾角: 0;
- (5) 轨道周期: 24.623 h。

4.2.2 火星捕获策略

探测器由星际空间进入火星引力范围,根据地火转移策略的设计结果,探测器到达火星的C3能量为零,探测器依靠电推力器工作逐渐进入目标环火轨道。由于火星捕获是火星逃逸的逆过程,且环火轨道为确定的目标,因此,可采用逆向设计的思路开展火星捕获轨道分析,火星捕获分析时,以目标轨道为初始轨道,探测器沿速度方向加速逃逸火星,逃逸的目标C3为0。表4给出了不同功率的推力器完成火星捕获所需的时间和燃料需求情况。分析表明,若采用比冲为5000s的2N推力器,完成火星捕获并到达目标环火轨道需推力器工作长达64.2天,燃料消耗约0.23t。

为缩短探测器火星捕获时间,减小推进剂消耗,可以通过增大推力器功率,从而增大发动机推力和比冲实现。例如,采用比冲为4000s的5N推力器,完成火星捕获并到达目标环火轨道推力器工作时间可缩短至24.2天,燃料消耗约0.27t。

表 4 火星捕获方案
Table 4 Scheme of Mars capture

项目	火星捕获方案			
	2N 推力 (5000 s 比冲)	2N 推力 (10000 s 比冲)	5N 推力 (2000 s 比冲)	5N 推力 (4000 s 比冲)
探测器初始质量/t	9.38	9.40	9.38	9.38
连续点火减速时间 /天	64.18	64.62	23.84	24.22
燃料消耗/t	0.23	0.12	0.53	0.27
到达目标轨道剩余 质量/t	9.15	9.28	8.85	9.11

4.3 轨道间转移与探测任务轨道分析

在被火星捕获后,火星多任务探测器的母体飞行器与各探测器形成分布式^[21]火星探测系统,可完成火星的综合探测。

4.3.1 数据中继星座

火星数据中继星座如图3所示,由3颗静止轨道卫星和6颗火星闪电轨道卫星组成。9星星座可对火星任意地区连续实时覆盖,实现星间实时通信,可作为地火数据链路的一部分。星座中的每颗探测器与母体飞行器分离,由轨间转移飞行器运送至工作轨道。轨间转移飞行器具有6N推力器、6000s比冲的推进系统,将探测器运输至闪电工作轨道,往返一次预计所需速度增量为5000m/s。假设轨间转移飞行器和探测器质量均为1000kg,转移飞行器完成往返一次所需燃料为82kg;由于母体飞行器位于静止轨道,轨间飞行器转运静止轨道中继星的燃料消耗较少,预留2kg即可。因此,轨间转移飞行器完成9颗中继星的运输,往返18次,燃料需求约500kg。

4.3.2 全火遥感

全火遥感卫星采用3星组网,单颗星采用太阳同步圆轨道,轨道高度800km,预计轨道转移飞行器往返一次所需速度增量为5600m/s,所需




图3 火星数据中继星座示意图

Fig. 3 Constellations of Mars data relay

燃料约 100 kg, 完成 3 颗全球遥感卫星转运的燃料需求约为 300 kg。全火遥感卫星星下点轨迹示意图如图 4 所示。




图4 全火遥感卫星星下点轨迹示意图

Fig. 4 Subsatellite point track of remote sensing satellites for Mars

4.3.3 火星大气详查探测器

火星大气详查探测器位于大椭圆轨道, 缓慢进入火星大气, 利用火星大气摄动效应缓慢进入, 并在此过程中实时进行火星大气环境探测, 将探测数据传回地面。参考 MOM 探测器轨道, 同时考虑到母体飞行器轨道, 火星大气详查探测器可采用 $500 \text{ km} \times 17031 \text{ km}$ 大椭圆极轨轨道。运输器往返运输所需速度增量为 3600 m/s , 所需燃料约 60 kg。

4.3.4 着陆巡视器

实施 EDL, 进行火星表面巡视探测, 完成着陆巡视探测的燃料需求与着陆纬度相关, 为保证全火任意位置的着陆地目标, 运输器应具备倾角调整 90° 和轨道近地点高度调整为零的能力, 运输器往返运输所需速度增量为 4000 m/s , 所需燃料约 65 kg。

综上所述, 多任务火星探测器在静止轨道上

运行, 完成各项任务探测, 预计总的推进剂需求为 925 kg。

5 结论

本文提出了一种火星多任务探测器系统设想, 介绍了系统基本组成、任务架构及轨道策略等。通过分析研究, 得出以下结论:

(1) 火星探测是深空探测领域从月球探测发展至行星探测的关键环节, 而模块化多任务火星探测器系统是实现火星探测跨越式、可持续发展的重要途径;

(2) 模块化多任务火星探测系统发展既可以带动深空探测技术与模块化航天器设计技术的发展, 又可以促进火星探测的科学发现;

(3) 发展模块化深空探测器, 还需开展深空探测顶层任务设计、模块化航天器总体设计、在轨组装维护系统设计等关键技术攻关;

(4) 所设计的火星多任务探测器表明, 利用电推进技术开展未来大型复杂深空探测具有较高的可行性, 且随着电推进技术的发展, 探测器的入轨周期将进一步缩短, 以满足探测周期需求。

参考文献

- [1] 郭晓博. 火星探测 50 年[J]. 中国国家天文, 2015(4): 14-23.
- [2] 刘建忠, 欧阳自远, 李春来, 等. 火星探测的科学目标及优选原则初探[C]. 中国科协年会, 北京, 2006: 124-131.
- [3] 李春来, 刘建军, 耿言, 等. 中国首次火星探测任务科学目标与有效载荷配置[J]. 深空探测学报, 2018, 5(5): 406-413.
- [4] 于登云, 孙泽洲, 孟林智, 等. 火星探测发展历程与未来展望[J]. 深空探测学报, 2016, 3(2): 108-113.
- [5] 吴伟仁, 于登云. 深空探测发展与未来关键技术[J]. 深空探测学报, 2014, 1(1): 5-17.
- [6] 郑永春, 欧阳自远. 太阳系探测的发展趋势与科学问题分析[J]. 深空探测学报, 2014, 1(2): 83-92.
- [7] Li W J, Chen D Y, Liu X G, et al. On-orbit service(OOS)of spacecraft: A review of engineering developments[J]. Progress in Aerospace Sciences, 2019(108): 32-120.
- [8] 于登云, 孙泽洲, 孟林智, 等. 火星探测发展历程与未来展望[J]. 深空探测学报, 2016, 3(2): 108-113.
- [9] 杨彬, 李爽. 火星探测转移轨道初始设计与分析[J]. 中国空间科学技术, 2017, 37(4): 18-27.
- [10] 刘华伟, 李伟杰, 田百义, 等. 基于在轨组装维护的模块化深

- 空探测器技术进展与应用研究[J]. 深空探测学报, 2019, 6(6): 598-601.
- [11] 袁子, 王慧, 王立, 等. 火星探测有效载荷概述[C]. 中国宇航学会深空探测技术专业委员会第七届学术年会, 哈尔滨, 2010.
- [12] 朱岩, 白云飞, 王连国, 等. 中国首次火星探测工程有效载荷总体设计[J]. 深空探测学报, 2017, 4(6): 510-514.
- [13] 王涛. 火星探测陆空协同无人系统的研究发展分析[J]. 无人系统技术, 2020, 3(5): 5-12.
- [14] 张涛, 李清, 张长水, 等. 智能无人自主系统的发展趋势[J]. 无人系统技术, 2018, 1(1): 11-22.
- [15] 贾平, 刘笛. 国外无人在轨服务和模块化可重构航天器发展分析[J]. 无人系统技术, 2019, 2(3): 60-65.
- [16] 郑红星, 周思雨, 李伟杰. “一对多”的空间在轨服务序列规划研究[J]. 无人系统技术, 2019, 2(6): 34-39.
- [17] Bret G. Drake. Human exploration of mars design reference architecture 5.0[R]. Houston: NASA Johnson Space Center, 2010 (NASA/SP-2009-566).
- [18] 尚海滨. 小推力转移轨道设计与优化方法及其应用研究[D]. 哈尔滨: 哈尔滨工业大学, 2008.
- [19] 田百义. 小推力借力转移轨道设计与优化方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2012.
- [20] 任远, 崔平远, 栾恩杰. 基于混合法的小推力地球-火星转移轨道设计[J]. 哈尔滨工业大学学报, 2007, 39(3): 359-362.
- [21] 董勇, 张治彬, 李新洪, 等. 分布式空间系统研究进展与应用分析[J]. 无人系统技术, 2020, 3(5): 13-20.

作者简介:



刘华伟 (1987-), 女, 博士, 工程师, 主要研究方向为在轨服务航天器总体技术。



田百义 (1988-), 男, 硕士, 高级工程师, 主要研究方向为航天器轨道动力学技术。



呼延奇 (1982-), 男, 博士, 高级工程师, 主要研究方向为航天器轨道动力学技术。



李伟杰 (1981-), 男, 博士, 研究员, 主要研究方向为在轨服务航天器总体技术。本文通信作者。

致谢

2021年度审稿专家

2021年度，《无人系统技术》的审稿专家学风严谨，审阅认真，判断准确，评价中肯，为《无人系统技术》的学术水平和质量不断提高做出了重要贡献。编辑部全体人员衷心感谢各位审稿专家在百忙之中仍然以严谨治学的态度和奉献精神，促进稿件审理工作顺利进行，帮助刊物赢得更多读者和作者的信赖。

在此，《无人系统技术》编辑部真诚地向审稿专家致以深深的谢意！祝您在新的一年里工作顺利，阖家安康！现将审稿专家名单附上（按姓氏首字母拼音排序），以示答谢。

白成超 晁涛 陈希亮 陈征 丁达理 段续庭 房建武 冯跃 符文星
符小卫 甘文彪 高兵兵 韩勇强 何成龙 何玉庆 胡高歌 胡劲文 胡桥
黄海滨 黄蜀玲 蒋琪 李兵 李俊豪 李磊 梁桥康 梁宵 廖煜雷
刘锦涛 陆科林 吕石 吕跃勇 毛耀 闵海根 聂凯 彭星光 荣明
邵星灵 时晨光 苏子康 孙大洋 孙景亮 孙中奇 田大新 王博 王融
王汝鹏 王涛 王一祝 武炎明 夏敏 肖良华 谢杨柳 熊波 徐红丽
闫晟 杨庆凯 杨少龙 杨绍琼 姚鹏 张栋 张思齐 张涛 张兴龙
赵林 甄子洋 周建山 周乐来 朱建雄 朱曼

顾 问

李德毅 封锡盛 李伯虎 徐德民 刘永才 费爱国 樊邦奎 陈 杰
魏毅寅 向锦武 王长青 王飞跃

第二届编委会

主 任 李风雷

副 主 任 谷满仓 符文星 宋 斌 张 涛

常务委员 (按姓氏拼音排序)

邓宏彬 郭继峰 李东光 潘 泉 王宏伦 徐 昕

委 员 (按姓氏拼音排序)

昂海松 陈 斌 陈家斌 程 进 戴江勇 方 浩 冯伟强 符小卫 黄长强
姜 梁 李必军 李伟杰 李贻斌 林 平 刘 莉 刘培志 麻广林 马洪忠
孟凡彬 牛轶峰 齐俊桐 任 章 时兆峰 苏玉民 孙富春 孙智孝 陶 溢
田大新 韦锦峰 吴向阳 夏元清 谢少荣 徐海刚 薛建儒 颜国正 杨宏晖
于林宇 张 宁 张卫平 赵 杰 朱小燕 Dan ZHANG Simon X.YANG
Yang SHI Youmin ZHANG

无人系统技术

2018年创刊 (双月刊)

主管单位: 中国航天科工集团有限公司
主办单位: 北京海鹰科技情报研究所
协办单位: 中国无人系统产业联盟 (筹)
西北工业大学无人系统发展战略研究中心
西北工业大学无人系统技术研究院
主 编: 张冬青
副 主 编: 蔡顺才 孙柏原 李东光 陈少春
执行主编: 王一琳
编辑出版: 《无人系统技术》编辑部
地 址: 北京7254信箱4分箱 (100074)
电 话: 010-68191488 (编辑部)
010-68375084 (发行部)
邮 箱: chinauas310@163.com
网 址: <http://umst.cbpt.cnki.net>
国内发行: 北京海鹰科技情报研究所
印刷单位: 北京博海升彩色印刷有限公司

Administrated by: China Aerospace Science & Industry Corporation Limited
Sponsored by: Beijing HIWING Scientific and Technological Information Institute
Co-organized by: Association for Unmanned Vehicle Systems of China
Research Center for Unmanned System Strategy Development, NWPU
Unmanned System Research Institute, NWPU
Editor-in-Chief: ZHANG Dongqing
Associate Editor: CAI Shuncaai SUN Baiyuan LI Dongguang CHEN Shaochun
Executive Editor: WANG Yilin
Edited&Published by: Editorial Office of Unmanned Systems Technology
Add: P.O. Box 7254-4, Beijing 100074, China
Tel: (8610) 68191488 (Editorial)
(8610) 68375084 (Circulation)
E-mail: chinauas310@163.com
Website: <http://umst.cbpt.cnki.net>
Distributed by: Beijing HIWING Scientific and Technological Information Institute
Printed by: Beijing BOHS Colour Printing Co., Ltd.

本期责任编辑: 籍云方

ISSN 2096-5915

国内定价: 30元/期

CN 10-1565/TJ