

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

空间无人系统
专刊

特约主编 郭继峰



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



2019.3
第2卷 NO.



空间无人系统发展热点论坛 成功召开

2019年5月30日，空间无人系统发展热点论坛在北京顺利召开。本届论坛由哈尔滨工业大学航天学院与《无人系统技术》编辑部联合主办。来自国内从事空间无人系统技术研究的军工集团公司、科研院所、高等院校以及民营企业的专家学者等百余位嘉宾，共同探讨交流未来空间无人系统技术的发展。

论坛邀请到哈尔滨工业大学齐乃明教授、清华大学孙富春教授、哈尔滨工业大学郭继峰教授、西北工业大学符文星教授、中科院沈阳自动化研究所朱枫研究员、航天科技五院501部李伟杰高级工程师、哈尔滨工业大学鞠有伦教授、航天科技五院钱学森实验室侯欣宾工程师等十位专家分享最新学术见解，把握技术发展脉搏。



系统综述

基于不确定性分析的巡视器地形估计方法.....	01
郭继峰, 白成超	
光学遥感影像超分辨率重构研究进展.....	20
赵晓冬, 张洵颖, 程雪梅	

技术研究

基于单目深度估计的视觉里程计算法.....	28
郭爽	
无人行星车自适应协同探测方法.....	37
罗汝斌, 颜鹏	
有限推力空间飞行器自主避障研究.....	43
赵毓	
基于深度学习的空间多目标识别方法研究.....	49
王柳	

前沿动态分析

国外无人在轨服务和模块化可重构航天器发展分析.....	56
贾平, 刘笛	
智能遥感研究现状与展望.....	62
陈昕, 刘昌昊, 陈培永, 华春, 刘廷芳	

《无人系统技术》办刊宗旨是刊载无人系统领域新进展、新成果、新技术, 促进学术交流, 推动成果转化, 提高我国在该领域的科研装备水平。

现诚挚地向无人系统技术研究领域的专家学者、学术带头人以及致力于无人系统理论与技术创新研究的科技工作者约稿。稿件内容以综述、研究论文、技术报告、专题研讨和科技评述等形式为主, 广泛报道无人空中系统、无人地面系统、无人水面水下系统、智能机器人等研究领域的理论研究成果、技术创新、学术见解和经验总结。主要包括无人系统平台技术、自动控制技术、信息技术以及人工智能、通信、传感器等技术在无人系统领域的新应用。同时, 也包括无人系统自主技术、协同技术、跨域同步技术、智能无人系统伦理及其与有人系统的关系等。



Systematic Review

- Patrol Terrain Estimation Method Based on Uncertainty Analysis 01
GUO Jifeng, BAI Chengchao
- Advances in Super Resolution Reconstruction of Optical Remote Sensing Images 20
ZHAO Xiaodong, ZHANG Xunying, CHENG Xuemei

Technical Study

- Visual Odometry Algorithm Based on Monocular Depth Estimation 28
GUO Shuang
- Adaptive Cooperative Detection Method for Unmanned Planetary Vehicle 37
LUO Rubin, YAN Peng
- Research on Autonomous Obstacle Avoidance method of Finite-Thrust Spacecraft 43
ZHAO Yu
- Research on Spatial Multi-objective Recognition Based on Deep Learning 49
WANG Liu

Frontier Dynamic Analysis

- Development Analysis of Unmanned On-Orbit Servicing Spacecraft and Modular Reconfigurable
Spacecraft Abroad 56
JIA Ping, LIU Di
- The State-of-Art and Future of the Intelligent Remote Sensing 62
CHEN Xin, LIU Changhao, CHEN Peiyong, HUA Chun, LIU Yanfang



基于不确定性分析的巡视器 地形估计方法

郭继峰, 白成超

(哈尔滨工业大学, 哈尔滨 150001)

摘要: 对探测地形精确感知是地外天体巡视器自主开展探测任务的前提条件。而基于视觉和激光雷达进行环境测量时易受光照、沙尘等条件制约。在考虑探测过程不确定性影响的情况下, 提出了一种基于多点测距信息的振动/陀螺仪耦合地形估计方法。通过对测量不确定性和运动不确定性的分析, 推导了地形更新模型。为了验证算法的正确性, 基于Unity3D/ROS搭建的月面仿真环境进行了测试分析, 同时在地面环境中结合无人车完成了室内Optitrack辅助环境、室外土壤环境下的地形重构精度测试, 结果表明该算法对于给定尺度地形具有较高的重构能力, 可为实验平台高精度自主路径规划提供支撑。

关键词: 地外天体巡视; 地形感知; 不确定性分析; 耦合地形估计

中图分类号: V11 **文献标识码:** A **文章编号:** 2096-5915 (2019) 03-0447-19

Patrol Terrain Estimation Method Based on Uncertainty Analysis

GUO Jifeng, BAI Chengchao

(Harbin Institute of Technology, Harbin 150001, China)

Abstract: Accurate perception of detected terrain is the prerequisite for autonomous exploration of the extraterrestrial celestial patrol. The environment measurement based on vision and lidar is easily restricted by illumination, dust and other conditions. Considering the uncertainties in the detection process, we proposed a vibration/gyroscope coupled terrain estimation based on multi-point ranging information. Through the analysis of measurement uncertainty and motion uncertainty, the terrain renewal model is deduced. In order to verify the correctness of the algorithm, the lunar simulation environment based on Unity3D/ROS is tested and analyzed. At the same time, the accuracy of Terrain Reconstruction in indoor Optitrack assistant environment and outdoor soil environment is tested in terrestrial environment combined with unmanned vehicle. The results show that the algorithm has a high reconstructed capability at a given scale, which can provide support for high precision autonomous path planning of experimental platform.

Keywords: Extraterrestrial Celestial Inspection; Terrain Perception; Uncertainty Analysis; Coupled Terrain Estimation

收稿日期: 2019-04-22; 修回日期: 2019-05-25

基金项目: 国家自然科学基金 (11472090)

1 引言

巡视器根据任务类型、功能等不同，有着不一样的设计要求和配置标准，作为其若干个子系统中的关键一环，导航系统为巡视器提供了感知环境的能力，通过携带视觉、激光雷达等外部传感模块，可以获取周围环境的结构特征；通过搭载惯性测量单元、里程计等内部传感模块，可以获取与环境的相对位姿关系；通过多种传感模式的融合，可以建立巡视器本体对环境的全局认知。这也在例如勇气号、机遇号这样的实际任务中得到很好的验证和应用。

随着探测任务逐渐复杂，探测时间也越来越长，相应的探测距离也不断延伸，这就要求巡视器本身具备精确的定位和环境重构能力，为规划系统提供准确的输入，从而可以优化巡视路径，规避障碍危险，将巡视价值最大化。其中，如何在地外天体这样一个未知、复杂、动态的环境中获取高精度、大尺度的地形感知信息尤为重要，很大程度上影响了巡视任务的成败，也因此成为了该领域研究的热点之一^[1-3]。

针对地形感知问题的研究，可以从三个方面来分析，即传感器选型，算法和应用^[4]。其中传感器使用从早期的以视觉、激光雷达为主，逐渐向多传感器融合发展；算法从之前的三角测量、滤波优化逐渐向机器学习、生物学启发发展；应用则从一开始的地形估计逐渐向地理环境建模，科学属性探测发展。总的趋势还是更倾向于不依赖外部信息的多传感器融合地形估计。2007年，Olson^[5]基于大量在轨和巡视过程拍摄的图片，通过光束法平差实现巡视器附近区域的高精度帧间匹配，并利用宽基线双目视觉实现了远距离地形重构，给出了火星长距离巡视导航的实现思路。Li R等^[6]基于光束法平差修正，给出了勇气号在Gusev Crater附近的拓扑地形估计，并基于正射映射(Ortho Maps)生成了数字高程地图。2011年多伦多大学Barfoot团队^[7]将SLAM技术应用到地外天体巡视过程，通过激光雷达及里程计补偿实现

了全局一致地形精确估计，其中提出的稀疏特征方法和批量对齐算法有效的解决了特征关联和测量异常值的鲁棒性问题。2013年，由加拿大航天局发起的MRPTA项目^[8]，实现了基于最小传感器配置的地形构建，提出了以巡视器为中心的局部环形网格表示，并通过地图管理器将不同时刻的测距图进行了融合管理，从而得到了全局优化的地形表示。之后来自Surrey大学的Bajpai A等^[9]提出了基于单目的地外天体同步定位与绘图技术(PM-SLAM)，该方法的创新之处在于受生物学语义特征检测的启发，提出了视觉显著性模型，即首先基于点描述子给出了生成混合显著特征的方法，其次将该特征用于地形状态估计，由多个场景的测试结果看出该方法可有效提高视觉感知的鲁棒性。2017年来自MIT的Gonzalez R等^[10]针对地外天体巡视过程可能遇到的滑动问题，在仅依赖内部传感模块状态下，提出了基于机器学习的轮地交互滑动检测方法，一方面由于依旧使用原有的内部传感设备没有增加系统的复杂度，另一方面提高了对光照等条件的适应性，并在实际验证过程中对比分析了有监督和无监督学习方法对该检测的有效性。同时随着深度学习、卷积神经网络的不断发展，越来越多的算法被应用到巡视器任务中^[11]。Carrio J H等^[12]提出了基于视觉里程计、IMU和轮式里程计的融合SLAM地形估计方法，其创新之处在于首先通过多传感器融合进行地形重构，其次基于高斯过程的里程计误差模型预测了由于轮地交互引起的非系统误差，提高了估计的精度。Shaukat A等^[13]也提出了视觉和激光雷达的融合策略，通过实验验证了该种模式在距离、灵活性、精度等方面的优势。最近，随着在地外天体地表构型估计方面取得了突破性成果，逐渐向下一个阶段过度，即具备多属性状态的地形估计，不再仅仅关注于环境地形是否平坦、有障碍，而是更多的去融合硬度、材质等特征属性。哈尔滨工业大学的邓宗全教授团队^[14]，提出了用等效刚度表征地形的压力特性，同时用摩擦角表征剪切特性的新思路，通过证明车轮与土壤之间

受力的交互力学模型与车轮与岩石之间受力的接触模型具有等效性,给出了含有物理特性的数字高程地图。

除此之外,地形重构问题在地面机器人、无人驾驶等领域也是一个高关注度的研究点。早在2002年,卡耐基梅隆大学的Thrun S教授就给出了基于机器人绘图的综述介绍,对比分析了多种不同的基于概率的实现方法,作为领域非常有代表性的著作,为后续的技术发展提供了支撑^[15]。Bresson G等^[16]针对同步定位与绘图技术给出了现状综述,分析了自动驾驶的发展趋势。来自密西根大学的Ye C等^[17]利用2D激光雷达估计了地形的高程图和确定性地图,提出的确定性辅助空间滤波(Certainty Assisted Spatial Filter),在运动连续性和空间连续性上通过物理约束有效区分了高程图中的损坏像素。之后,Wolf D F等^[18]将地形重构及分类进行了结合,基于隐马尔科夫模型给出了三维地形估计,并对可导航区域和不可导航区域进行了区分,这为后续的路径规划提供了更为深入的信息,从某种意义上具备了一定的语义能力。Gingras D等^[19]则利用360°视角的激光雷达进行了非结构化表面重构,通过对表面分析及对可导航空间的提取将安全可通过区域用压缩的不规则三角形网格表示,这样一种紧凑的地形表示形式,一方面简化了计算的复杂程度,另一方面也保证了平台运行的可靠性。

虽然现在基于上述的传感模式和地形重构方法取得了不错的精度,在实际应用中也效果显著,但仍需考虑在多变不确定的地外环境,在发生意外(失效或部分失效)时如何依然具备对地形的感知能力。当然,造成这种意外的因素有很多,可能是因为软着陆过程振动频率过大,也可能是光照、温度等环境变化引起,所以说在已有的地形重构能力上,如何构建鲁棒性更强的地形感知能力是下一个亟待突破的难点。

基于上述分析,本文主要针对受光照变化影响时,视觉传感单元无法正常工作的情况,研究在运动不确定环境下依靠主动测距信息精确重构

地形的可行方法。早在1989年,Hebert M等^[20]首次提出了在球面极坐标空间下利用轨迹算法(Locus Algorithm)构建地形表示,同时基于特征匹配和标记匹配实现了不同探测位置数据的有效配准。Krotkov E等^[21]在前者的基础上,考虑了目标阴影遮挡的问题。随后在2001年,Whitaker R T^[22]基于多个稠密测距地图构建了地形的高度函数表示,通过寻找在测试集和先验数据集上的最大后验概率来给出地形的最优估计,并且验证了多个测距地图实验结果远优于任何单个测距地图,最后还通过激光测距仪验证了其对噪声具有一定的鲁棒性。之后他们利用含有噪声的多视点测距信息估计表面构型,给出了传感器模型构建三维表面的似然表达,通过优化似然得到了无偏差的估计器,该方法相比于之前的高度测量及最近点匹配提出了新的地形估计思路^[23]。来自加州理工的Cremer L B等^[24]提出了一种适合于高速和高度非结构化的室外环境的2.5D数字高程图构建方法,首先给出了完整的测距传感器误差不确定性分析,其次将测量通过不确定模型转化得出测量的概率密度函数,并在概率密度函数中值区域附近选定更新区域,最后通过卡尔曼滤波不断更新地形结果,该方法相比之前在局部地形估计和更新方法,以及在线实现方面都给出了新的观点。Lshigami G等^[25]等则针对测距数据到地形转换过程提出了一种新的扇形参考网格,从而得到了带圆柱坐标的高程图,这种转换方法实现了地形的尺度化表示,即在巡视器附近精细化重构,离巡视器越远则越稀疏表达。基于之前的研究基础,来自ETH的Fankhauser P等^[26]针对四足机器人提出了定位不确定情况下的概率地形估计方法,同时考虑了传感器测量误差及平台运动估计误差的影响,基于运动学及惯性测量实现了高精度地形估计,该方法相比之前给出了地形的三维协方差表示,并推导了地图更新误差传递关系。

本文将在前述研究基础上,结合地外天体巡视环境,重点讨论基于多点测距的振动/陀螺仪耦合高程地形构建方法,从而提升巡视器对环境变

化的鲁棒性，以及为后续运动规划、3D感知语义场构建提供支撑。

2 坐标系定义




图1 坐标系定义

Fig. 1 Coordinate system definition

本文定义了四个坐标系，分别为惯性坐标系 I 、地形坐标系 T ，巡视器本体坐标系 R ，以及传感器坐标系 S 。其中，惯性坐标系固定在惯性空间，巡视器本体坐标系固定在巡视器质心位置，传感器坐标系与传感器本体质心固联，详见图1。坐标系之间的转换关系由变换矩阵来给出，即三维的平移 r 和三维的旋转 ϕ ，其中传感器与巡视器在执行任务时均为固定校准安装，故巡视器本体坐标系与传感器坐标系相互转换关系已知，这里定义为 (r_{RS}, ϕ_{RS}) ，同理，惯性坐标系与巡视器本体坐标系之间的转换为 (r_{IR}, ϕ_{IR}) 。由于巡视器在不同时刻的位姿对于惯性坐标系具有高度不确定性，同步给出每一时刻位姿的协方差矩阵：

$$\sum_{IR}^{6 \times 6} = \text{Cov}(r_{IR}, \phi_{IR}) \quad (1)$$

巡视器在未知地形前进时，可用俯仰、偏航和滚转来描述其三维姿态的变化，本文假定地形相对于惯性坐标系为固定不变的，故可由下式来描述巡视器本体坐标系与惯性坐标系之间的转换：

$$\phi_{IR} = \phi_{IR}(\psi) \cdot \phi_{RR}(\theta, \varphi) \quad (2)$$

其中， $\phi_{IR}(\psi)$ 描述了惯性坐标系绕 z 轴旋转 ψ 角度得到了中间坐标系 \tilde{R} ， $\phi_{RR}(\theta, \varphi)$ 描述了由中间坐标系到巡视器本体系的俯仰和滚转变换。

为了简化后续的推导和计算，这里设定惯性坐标系 z 轴垂直地面向上，地形坐标系 z 轴始终与惯性坐标系 z 轴平行，使得两个坐标系之间的转换

只存在一个自由度，即绕 z 轴的偏航。同时设定 $\psi_{(I \rightarrow T)}$ 由 $\psi_{(I \rightarrow \tilde{R})}$ 给出，即地形坐标系与巡视器本体坐标系的转换只存在俯仰和滚转两个自由度，从而实现了坐标转换之间的降维处理。

3 基于测距信息的地形融合估计

对于每一次测量，根据传感单元的感知能力及任务需要会有不同数量的采样结果，为简化理解，这里取任意一点进行分析，如图1所示，点 P 为测量点，其坐标为 (x_p, y_p, \tilde{h}_p) ，即在地形坐标系下 (x_p, y_p) 点处的高度估计值为 \tilde{h}_p 。针对高度的估计，本文采用高斯概率分布对其近似处理，即 $\tilde{h}_p \sim N(h_p, \sigma_{h_p}^2)$ ，其中 h_p 为该分布的均值， $\sigma_{h_p}^2$ 为分布的方差。由图1可知，点 P 在传感器坐标系下的测量值为 ${}_S r_{SP}$ ，通过传感器坐标系到地形坐标系的转换可得：

$$h_p = H[\Phi_{ST}^{-1}({}_S r_{SP}) - {}_S r_{SM}] \quad (3)$$

其中， $H = [0 \ 0 \ 1]$ ，将点 P 的三维坐标进行高度方向提取。进而可以知道高度估计与转换矩阵和传感器测量值直接相关，与之前分析的误差来源相对应，故对上式求一阶导，得到对应误差的雅克比矩阵，即：

(1) 传感器测量雅克比矩阵：

$$J_S = \frac{\partial h_p}{\partial {}_S r_{SP}} = HC(\Phi_{ST})^T \quad (4)$$

(2) 传感器坐标系旋转雅克比矩阵：

$$J_\phi = \frac{\partial h_p}{\partial \Phi_{ST}} = HC(\Phi_{ST})^T {}_S r_{SP}^x \quad (5)$$

其中， $C(\Phi)$ 定义为对应旋转矩阵的映射，即 $C: SO(3) \rightarrow \mathbb{R}^{3 \times 3}$ ， $\Phi(r) \triangleq C(\Phi)r$ 。将雅克比矩阵带入下式，可得方差 $\sigma_{h_p}^2$ 的误差传递关系：

$$\sigma_{h_p}^2 = J_S \sum_S J_S^T + J_\phi \sum_{\phi_S} J_\phi^T \quad (6)$$

其中，第一项为传感器噪声引起的误差传递，由所使用传感器本身性质决定，其协方差值由噪声模型来求解得到；第二项为由于坐标系之间的转换造成的误差传递，转换由两部分组成，即平移和旋转，

在之前坐标系定义时限定了地形坐标系的指向，故此处可忽略平移的影响。

至此，基于传感器测量的噪声误差估计已经获得，对于每一次测量更新，都会有相应的高度估计，故下一步需要将新获得的高度测量估计与已有的高程地形图进行融合。由于高度的测量估计与每一个测量点没有复杂的动力学关系，状态的传递方程比较直观，其仅仅是针对某个点 (x, y) 测量值的更新，所以地形图中的每一点随着传感器测量都会进行大量的更新，反之，如果没有更新将保持不变。这里给出了基于卡尔曼滤波的融合形式。

首先给出简化的离散卡尔曼滤波方程：

时间更新：

$$x_k = Ax_{k-1} + Bu_{k-1} \quad (7)$$

$$P_k = AP_{k-1}A^T + Q$$

状态更新：

$$K_k = P_{k-1}H^T(HP_{k-1}H^T + R)^{-1} \quad (8)$$

$$x_k = x_{k-1} + K_k(z_k - Hx_{k-1}) \quad (9)$$

$$P_k = (I - K_kH)P_{k-1} \quad (10)$$

针对巡视器地形估计，状态向量实际为每一测量点的高度尺度，故 H 项为 I ，状态 z_k 对应于当前测量点高度估计 h_p ，观测协方差 R 对应于当前测量点高度估计的方差 $\sigma_{h_p}^2$ ，观测值 x_k 对应于已有的高度值 \hat{h} ，误差协方差 P 对应于 σ_h^2 ，代入式 (8) ~ (10) 整理可得：

$$K_k = \sigma_h^2 (\sigma_h^2 + \sigma_{h_p}^2)^{-1} \quad (11)$$

$$^{(k)}\hat{h} = ^{(k-1)}\hat{h} + K_k(h_p - ^{(k-1)}\hat{h}) \quad (12)$$

$$^{(k)}\sigma_h^2 = (I - K_k)^{(k-1)}\sigma_h^2 \quad (13)$$

将式 (11) 代入式 (12) 得：

$$\begin{aligned} ^{(k)}\hat{h} &= ^{(k-1)}\hat{h} + [^{(k-1)}\sigma_h^2 (\sigma_h^2 + \sigma_{h_p}^2)^{-1}] (\hat{h}_p - ^{(k-1)}\hat{h}) \\ &= ^{(k-1)}\hat{h} + \frac{^{(k-1)}\sigma_h^2}{^{(k-1)}\sigma_h^2 + \sigma_{h_p}^2} (h_p - ^{(k-1)}\hat{h}) \\ &= \frac{^{(k-1)}\hat{h}(\sigma_h^2 + \sigma_{h_p}^2) + ^{(k-1)}\sigma_h^2(h_p - ^{(k-1)}\hat{h})}{^{(k-1)}\sigma_h^2 + \sigma_{h_p}^2} \\ &= \frac{^{(k-1)}\hat{h}\sigma_{h_p}^2 + ^{(k-1)}\sigma_h^2 h_p}{^{(k-1)}\sigma_h^2 + \sigma_{h_p}^2} \end{aligned} \quad (14)$$

将式 (11) 代入式 (13) 可得：

$$\begin{aligned} ^{(k)}\sigma_h^2 &= (I - K_k)^{(k-1)}\sigma_h^2 \\ &= [I - ^{(k-1)}\sigma_h^2 (\sigma_h^2 + \sigma_{h_p}^2)^{-1}] ^{(k-1)}\sigma_h^2 \\ &= (I - \frac{^{(k-1)}\sigma_h^2}{^{(k-1)}\sigma_h^2 + \sigma_{h_p}^2}) ^{(k-1)}\sigma_h^2 \\ &= \frac{^{(k-1)}\sigma_h^2 + \sigma_{h_p}^2 - ^{(k-1)}\sigma_h^2}{^{(k-1)}\sigma_h^2 + \sigma_{h_p}^2} ^{(k-1)}\sigma_h^2 \\ &= \frac{\sigma_{h_p}^2 ^{(k-1)}\sigma_h^2}{^{(k-1)}\sigma_h^2 + \sigma_{h_p}^2} \end{aligned} \quad (15)$$

从而给出了新测量到的高度 $(h_p, \sigma_{h_p}^2)$ 与已有高程地图估计 (\hat{h}, σ_h^2) 的融合方法，其中左上方 $(k-1)$ 代表更新前的估计， (k) 代表更新后的估计。

4 基于运动信息的地形融合估计




图2 不同时刻位置关系示意

Fig.2 Positional relationship at different time points

除了传感器本身的噪声影响，巡视器运动也会产生噪声误差，与常规实现地形估计不同的是，本文将地形坐标系与运动本体相关联，而不是基于惯性坐标系来表示，故巡视器只要有运动就会有地形更新产生，由上节可知，一般情况下，每一点的均值和方差都会根据运动的不确定性来更新，但这会带来巨大的计算压力，所以本节提出了利用真实地形上每一点对应的空间协方差矩阵来扩展高程图的方法，这样一来可以获取每一点的三维不确定性信息。根据之前定义，即地形坐标系与当前巡视器位姿相关联，不失一般性，假设网格中的一点 i 有新的测量更新，可以设定其协方差为：

$$\begin{aligned}
\mathbf{J}_\phi &= \frac{\partial_{T_{k+1}} \mathbf{r}_{T_{k+1}P}}{\partial \Phi_{R_k R_{k+1}}} = \frac{\partial[-\Phi_{R_{k+1}T_{k+1}}^{-1}({}_{R_{k+1}} \mathbf{r}_{R_k R_{k+1}}) - ({}_{T_{k+1}} \mathbf{r}_{R_{k+1}T_{k+1}}) + \Phi_{T_k T_{k+1}}^{-1}({}_{T_k} \mathbf{r}_{R_k T_k} + {}_{T_k} \mathbf{r}_{T_k P})]}{\partial \Phi_{R_k R_{k+1}}} \\
&= \frac{\partial[-(\Phi_{R_k T_k}^{-1} \cdot \Phi_{R_k R_{k+1}})({}_{R_{k+1}} \mathbf{r}_{R_k R_{k+1}}) - ({}_{T_{k+1}} \mathbf{r}_{R_{k+1}T_{k+1}}) + ({}_{T_k} \mathbf{r}_{R_k T_k} + {}_{T_k} \mathbf{r}_{T_k P})]}{\partial \Phi_{R_k R_{k+1}}} \\
&= \frac{\partial[-(\Phi_{R_k T_k}^{-1} \cdot \Phi_{R_k R_{k+1}})({}_{R_{k+1}} \mathbf{r}_{R_k R_{k+1}}) + \mathfrak{N}]}{\partial \Phi_{R_k R_{k+1}}} = \frac{\partial[-(\Phi_{R_k T_k}^{-1} \cdot \Phi_{R_k R_{k+1}})(\Phi_{R_k R_{k+1}}({}_{R_k} \mathbf{r}_{R_k P}) + ({}_{R_{k+1}} \mathbf{r}_{R_{k+1}P})) + \mathfrak{N}]}{\partial \Phi_{R_k R_{k+1}}} \\
&= -C(\Phi_{R_k T_k})^T ({}_{T_k} \mathbf{r}_{R_k P})^\times = -C(\Phi_{R_k T_k})^T ({}_{T_k} \mathbf{r}_{R_k T_k} + {}_{T_k} \mathbf{r}_{T_k P})^\times
\end{aligned} \tag{32}$$

其中, $\mathfrak{N} = -({}_{T_{k+1}} \mathbf{r}_{R_{k+1}T_{k+1}}) + ({}_{T_k} \mathbf{r}_{R_k T_k} + {}_{T_k} \mathbf{r}_{T_k P})$ 。到目前为止, 不足以求解 $k+1$ 时刻的协方差, 还需要知道 k 到 $k+1$ 时刻运动估计误差造成的不确定性影响, 即对 Σ_r , Σ_ϕ 的求解, 其表示如下:

$$\mathbf{r}_{R_k R_{k+1}} \sim N(\tilde{\mathbf{r}}_{R_k R_{k+1}}, \Sigma_{P,k}^r) \tag{33}$$

$$\Phi_{R_k R_{k+1}} \sim N(\tilde{\Phi}_{R_k R_{k+1}}, \Sigma_{P,k}^\phi) \tag{34}$$

如之前定义的坐标系关系, 将巡视器本体坐标系 z 轴与惯性坐标系 z 轴对准处理, 可以得到处理后的姿态不确定性仅与偏航角相关, 故可以通过降维处理重新给出在 k 时刻巡视器位姿的协方差矩阵表示, 即:

$$\mathbf{x}_{IR} = (\mathbf{r}_{IR}, \Phi_{IR}) \rightarrow \mathbf{x}_{\bar{IR}} = (\mathbf{r}_{\bar{IR}}, \psi) \tag{35}$$

其中, \bar{R} 为对准后的巡视器本体坐标系, 同时满足 $\mathbf{r}_{IR} = \mathbf{r}_{\bar{IR}}$, $\psi = \psi_{IR} = \psi_{IR}$ 。

5 基于振动/陀螺仪耦合的地形协方差求解

用高斯随机模型来近似运动过程, 同时研究不基于外部传感单元来实现巡视器定位, 给出了采用三轴振动触觉传感单元及单轴陀螺仪的定位模式, 下面将基于此模式给出 $\Sigma_{P,k}^r$, $\Sigma_{P,k}^\phi$ 的求解方法。

5.1 基于传感器信息位置求解

本文采用的是三轴振动触觉传感器输出值为测量点的振幅和频率值, 可将其转换为加速度信号, 即输入为 $a_{\bar{R}}$; 单轴的陀螺仪输出为绕 z 轴的角加速度, 记为 $\beta_{\bar{R}}$ 。为减小因非线性而造成的误差, 以传感器固连点为坐标原点, 取前后测量时间

隔为 Δt , 故有:

$$\Delta \mathbf{v} = \hat{\mathbf{a}} \Delta t \tag{36}$$

其中, $\hat{\mathbf{a}} = C_{IR}(\psi) a_{\bar{R}}$ 。且由于巡视器在行进过程相对平稳且较缓, 其从 k 时刻到 $k+1$ 时刻位移变化由下式可得:

$$\begin{aligned}
\Delta \mathbf{x} &= \Delta \mathbf{v} \Delta t + \frac{1}{2} \hat{\mathbf{a}} \Delta t^2 \\
&= \hat{\mathbf{a}} \Delta t^2 + \frac{1}{2} a \Delta t^2 \approx \frac{3}{2} C_{IR}(\psi) ({}_{\bar{R}} a_{\bar{R}}) \Delta t^2
\end{aligned} \tag{37}$$

同理, 基于陀螺仪输入可以求得从 k 时刻到 $k+1$ 时刻偏航角变化, 即:

$$\Delta \omega = C_{IR}(\psi) \beta_{\bar{R}} \Delta t \tag{38}$$

$$\begin{aligned}
\Delta \psi &= \Delta \omega \Delta t + \frac{1}{2} C_{IR}({}_{\bar{R}} \beta_{\bar{R}}) \Delta t^2 \\
&= C_{IR}(\psi) ({}_{\bar{R}} \beta_{\bar{R}}) \Delta t + \frac{1}{2} C_{IR}(\psi) ({}_{\bar{R}} \beta_{\bar{R}}) \Delta t^2 \\
&\approx \frac{3}{2} C_{IR}(\psi) ({}_{\bar{R}} \beta_{\bar{R}}) \Delta t^2
\end{aligned} \tag{39}$$

5.2 地形协方差估计

在实际采样过程, 存在着不确定性, 这里假设其高斯噪声矢量为 $\mathbf{n} = (n_a, n_\beta)^T$, 可得:

$$\mathbf{x}_{\bar{IR}}^{k+1} = \mathbf{x}_{\bar{IR}}^k + [\Delta \mathbf{x} \quad \Delta \psi]^T \tag{40}$$

将式 (37) 和 (39) 带入 (40) 可得:

$$\begin{bmatrix} {}_I \mathbf{r}_{\bar{IR}}^{k+1} \\ \psi_{k+1} \end{bmatrix} = \begin{bmatrix} {}_I \mathbf{r}_{\bar{IR}}^k \\ \psi_k \end{bmatrix} + \begin{bmatrix} \frac{3}{2} C_{IR}(\psi) & 0 \\ 0 & \frac{3}{2} C_{IR}(\psi) \end{bmatrix} \begin{bmatrix} a_k + n_a^k \\ \beta_k + n_\beta^k \end{bmatrix} \Delta t^2 \tag{41}$$

对上式求一阶导, 可得关于状态及噪声的雅克比矩阵:

$$\begin{aligned} \mathbf{J}_x &= \frac{\partial x_{IR}^{k+1}}{\partial x_{IR}^k} = \begin{bmatrix} \frac{\partial r_{IR}^{k+1}}{\partial r_{IR}^k} & \frac{\partial r_{IR}^{k+1}}{\partial \psi_{IR}^k} \\ \frac{\partial \psi_{IR}^{k+1}}{\partial r_{IR}^k} & \frac{\partial \psi_{IR}^{k+1}}{\partial \psi_{IR}^k} \end{bmatrix} \\ &= \begin{bmatrix} \mathbf{I}^{3 \times 3} & \frac{3}{2} C_{IR}(\psi)(a_k + n_a^k) \Delta t^2 \\ \mathbf{0}^{1 \times 3} & \frac{3}{2} C_{IR}(\psi)(\beta_k + n_\beta^k) \Delta t^2 \end{bmatrix} \end{aligned} \quad (42)$$

$$\begin{aligned} \mathbf{J}_n &= \frac{\partial x_{IR}^{k+1}}{\partial \mathbf{n}} = \begin{bmatrix} \frac{\partial r_{IR}^{k+1}}{\partial n_a^k} & \frac{\partial r_{IR}^{k+1}}{\partial n_\beta^k} \\ \frac{\partial \psi_{IR}^{k+1}}{\partial n_a^k} & \frac{\partial \psi_{IR}^{k+1}}{\partial n_\beta^k} \end{bmatrix} \\ &= \begin{bmatrix} \frac{3}{2} C_{IR}(\psi) \Delta t^2 & \mathbf{0}^{3 \times 1} \\ \mathbf{0}^{1 \times 3} & \frac{3}{2} C_{IR}(\psi) \Delta t^2 \end{bmatrix} \end{aligned} \quad (43)$$

则其协方差传递关系可以写成:

$$\Sigma_{IR}^{k+1} = \mathbf{J}_x \Sigma_{IR}^k \mathbf{J}_x^T + \mathbf{J}_n \Omega \mathbf{J}_n^T \quad (44)$$

进而可以得到巡视器从 k 时刻到 $k+1$ 时刻的变换关系, 即:

$$x_{\bar{R}_k \bar{R}_{k+1}} = \begin{bmatrix} \bar{R}_{k+1} r_{\bar{R}_k \bar{R}_{k+1}} \\ \bar{R}_k \psi_{\bar{R}_k \bar{R}_{k+1}} \end{bmatrix} \quad (45)$$

同时将位移及转角值分解可知:

$$\bar{R}_{k+1} r_{\bar{R}_k \bar{R}_{k+1}} = C_{IR}(\psi)(r_{IR}^{k+1} - r_{IR}^k) \quad (46)$$

$$\bar{R}_k \psi_{\bar{R}_k \bar{R}_{k+1}} = C_{IR}(\psi)(\psi_{IR}^{k+1} - \psi_{IR}^k) \quad (47)$$

带入式 (45), 可得:

$$\begin{aligned} x_{\bar{R}_k \bar{R}_{k+1}} &= \begin{bmatrix} C_{IR}(\psi)(r_{IR}^{k+1} - r_{IR}^k) \\ C_{IR}(\psi)(\psi_{IR}^{k+1} - \psi_{IR}^k) \end{bmatrix} \\ &= \frac{3}{2} \begin{bmatrix} a_k + n_a^k \\ \beta_k + n_\beta^k \end{bmatrix} \Delta t^2 \end{aligned} \quad (48)$$

则可以求出 $x_{\bar{R}_k \bar{R}_{k+1}}$ 的协方差 $\Sigma_{\bar{R}_k \bar{R}_{k+1}}$:

$$\Sigma_{\bar{R}_k \bar{R}_{k+1}} = Cov(x_{\bar{R}_k \bar{R}_{k+1}}) = \Omega \left(\frac{3}{2} \Delta t^2 \right)^2 \quad (49)$$

由式 (44) 可知:

$$\Omega = \mathbf{J}_n^{-1} (\Sigma_{IR}^{k+1} - \mathbf{J}_x \Sigma_{IR}^k \mathbf{J}_x^T) (\mathbf{J}_n^T)^{-1} \quad (50)$$

带入式 (49) 得:

$$\Sigma_{\bar{R}_k \bar{R}_{k+1}} = \tilde{\mathbf{J}}_n (\Sigma_{IR}^{k+1} - \tilde{\mathbf{J}}_x \Sigma_{IR}^k \tilde{\mathbf{J}}_x^T) \tilde{\mathbf{J}}_n^T \left(\frac{3}{2} \Delta t^2 \right)^2 \quad (51)$$

其中,

$$\tilde{\mathbf{J}}_n = \mathbf{J}_n^{-1} = \begin{bmatrix} \frac{3}{2} C_{IR}(\psi) \Delta t^2 & \mathbf{0}^{3 \times 1} \\ \mathbf{0}^{1 \times 3} & \frac{3}{2} C_{IR}(\psi) \Delta t^2 \end{bmatrix}^{-1} \quad (52)$$

$$\tilde{\mathbf{J}}_x \approx \begin{bmatrix} \mathbf{I}^{3 \times 3} & C_{IR}(\psi)(r_{IR}^{k+1} - r_{IR}^k) \\ \mathbf{0}^{1 \times 3} & C_{IR}(\psi)(\psi_{IR}^{k+1} - \psi_{IR}^k) \end{bmatrix} \quad (53)$$

而巡视器从 k 时刻到 $k+1$ 时刻的变换由平移和旋转确定, 故其协方差可由下式给出

$$\Sigma_{\bar{R}_k \bar{R}_{k+1}} = \begin{bmatrix} \Sigma_{P,k} & \mathbf{0} \\ \mathbf{0} & \sigma_{\psi_{\bar{R}_k \bar{R}_{k+1}}}^2 \end{bmatrix} \quad (54)$$

所以结合式 (51) 和 (54) 可以求出 Σ_r 的取值。

最后一个需要求解的是 $\Sigma_{P,k}$, 由于本文通过坐标系定义, 只有方位是变化的, 其一阶导也只存在 z 轴方向的值, 故可得:

$$\Sigma_{P,k}^\phi = \mathbf{J}_\psi \sigma_{\psi_{\bar{R}_k \bar{R}_{k+1}}}^2 \mathbf{J}_\psi^T \quad (55)$$

其中, $\mathbf{J}_\psi = \frac{\partial \Phi(\phi, \theta, \psi)}{\partial \psi} = [0 \ 0 \ 1]^T$ 。

综上, 结合式 (14) (15) (16) (28) 给出了从 k 时刻到 $k+1$ 时刻, 测量点 P 对应于地形中每一点 i 的不确定性地形更新。

6 实验测试

6.1 实验设计

本文将从三个方面来测试所提算法的正确性, (1) 基于 Unity3D/ROS 月面仿真环境的地形估计实验; (2) 基于 Optitrack 辅助室内地形测试; (3) 室外土壤环境测试。为了增加从仿真到实物验证的对比, 除了环境不同之外, 传感器均为相同配置, 即仿真环境为实物的高精度模拟。其中, 仿真环境将基于 Unity3D/ROS 系统搭建模拟月球地形, 实物测试将分别在室内 Optitrack 辅助环境及室外土

壤环境进行。无人运行平台采用加拿大Clearpath公司的Jackal无人车,搭载ROS运行环境,传感器选型为Microsoft Kinect V1.0深度相机, AFT601D三轴振动触觉传感器,以及单轴陀螺仪。除此之外,本文地形重构可视化将基于通用网格地图库(Universal Grid Map Library)实现。

6.2 基于Unity3D/ROS月面仿真环境地形测试

本节基于Unity3D/ROS搭建的模拟月面仿真环境如图3所示,其中大图为Unity3D环境运行示意,小图为ROS环境地形重构结果示意。由前述可知,通过对每一个检测点的高度及协方差估计更新来提高地形的重构精度,这里在估计值的基础上,同步给出 3σ 分布估计,来更好的判断地形估计的合理性。




图3 基于Unity3D/ROS月面模拟环境示意

Fig.3 Unity 3D/ROS based lunar simulation environment

图4给出了探测过程地形的估计结果,其中蓝色曲面和黄色曲面为地形估计的 3σ 上下边界,红色曲面为估计地形结果,绿色曲面为地形的实际

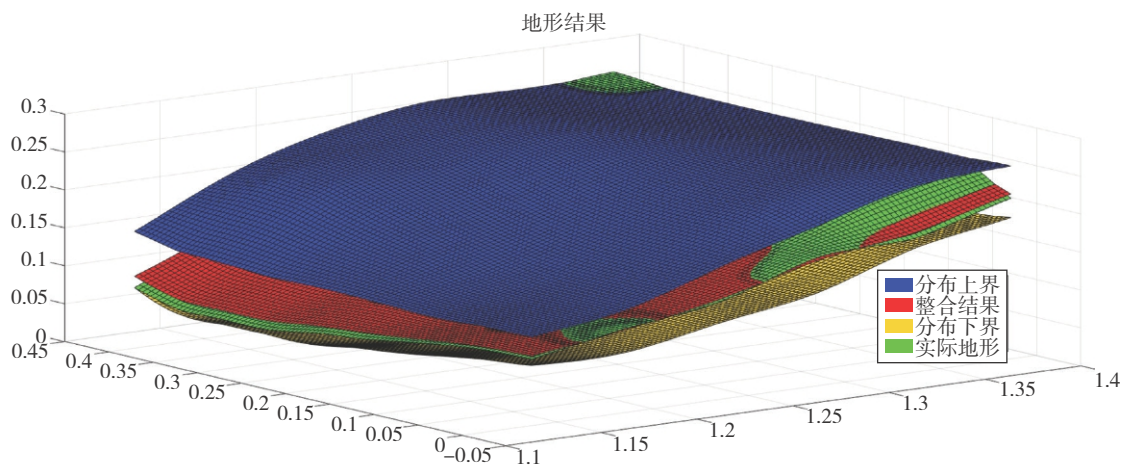


图4 地形重构结果示意

Fig.4 Terrain mapping results

值,大部分区域均满足估计值与真实值在合理边界区域内。同时结合图5,可以清楚的看到估计值与真实值几乎重合,由于测试区域为上坡趋势,后期的估计边界值明显缩小,可见在平坦区域估计精度要高于有坡度的区域。

为了对比算法的估计值与实际地形值的误差,由图6所示,给出红蓝两个区域的细节对比,从红色椭圆形区域可知,在 x 和 y 值相同时,最大高度估计误差在 0.44cm ;从蓝色椭圆形区域可知,在 x 和 y 值相同时,最大高度估计误差在 1.363cm 。相比于移动平台车轮的直径,该误差满足在实际运行中的精度要求。

接下来,基于上述地形曲面的结果,从高度估计剖面来分析算法对不规则地形的估计精度。由图7可知,红色曲线代表的估计值与黄色曲线代表的真实值在运行过程几乎重合,且完全处于合理的上下边界内,同时从局部放大示意图可知高度偏差在 0.52cm ,都说明了算法对于不规则地形估计的合理性。而且对地形的 3σ 估计分布区域可以看出,在初始和结束相对平缓的部分,分布边界相对于起伏的部分要窄,这也符合平坦地形估计精度高,起伏地形估计偏差大的特点,同时结合图8,从其点云图的分布也可以验证上述观点。总体来说,从仿真环境算法的重构结果来看,精度还是比较理想,但是毕竟与真实环境相比,在环境噪声,运行偏差,轮地交互不确定性等方面还

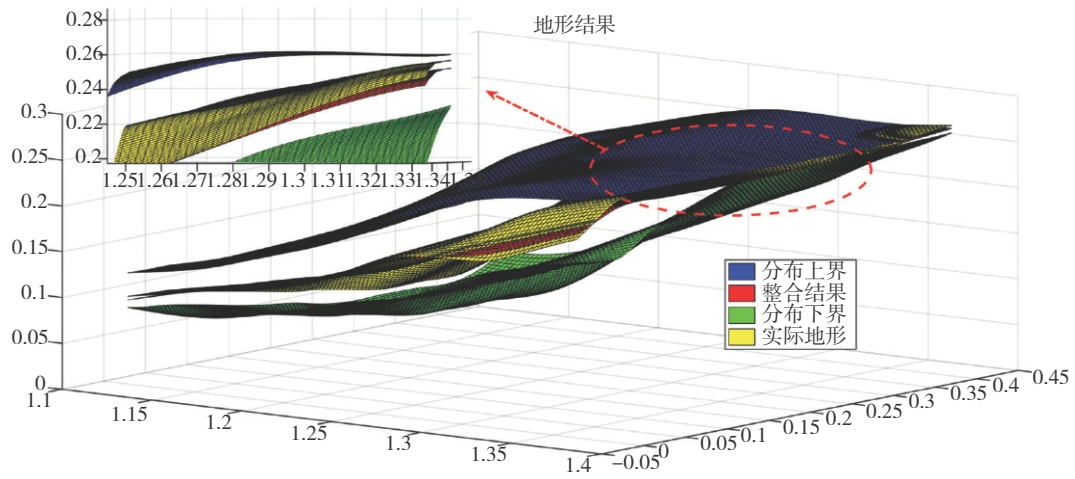


图5 地形交叉部分细节示意
Fig.5 The details of the intersection of the terrain

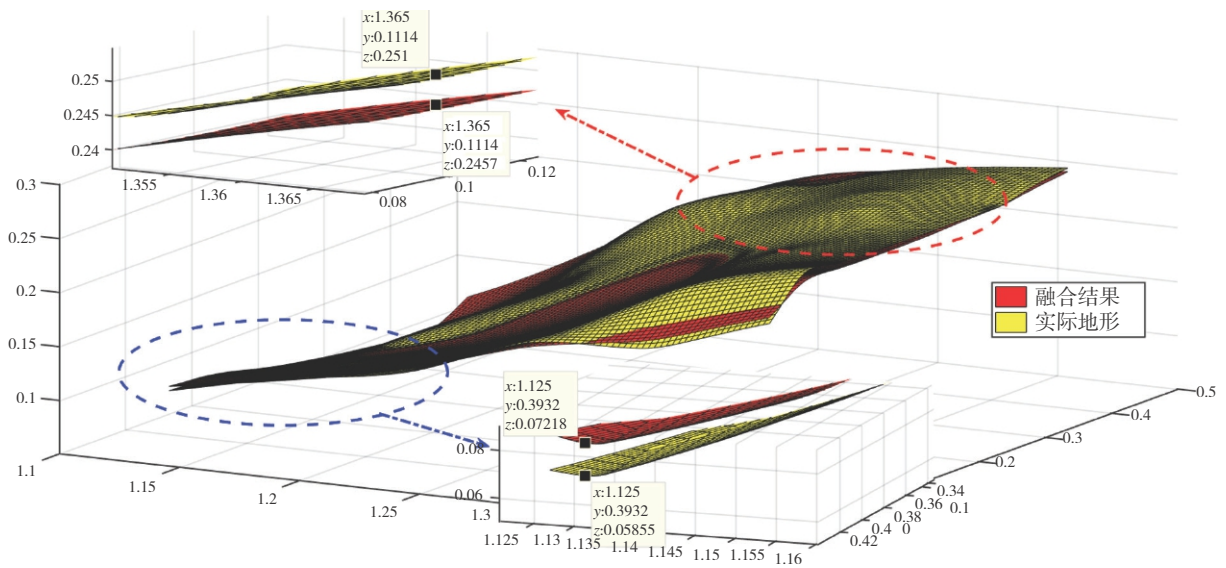


图6 估计值与真实值对比分析
Fig.6 Comparative analysis of estimated values and real values




图7 地形估计剖面结果
Fig.7 Terrain estimation profile results

有差距,故下一节将在此基础上,基于无人车平台和传感单元在实际环境中进行性能对比测试。




图8 地形估计剖面点云结果示意

Fig.8 Point cloud results for terrain estimation profiles

除此之外,基于上述地形重构值,将会对平台定位提供支持,同步给出在仿真环境下的定位精度对比分析,本实验在仿真环境中进行了四组测试,运行轨迹分别为半径为20m和30m的圆,以及两次随机测试。由结果可以看出定位的误差精度基本在厘米级,平均的定位误差在4cm左右,具有较高的定位能力。

(1) 半径20m路径测试




图9 半径20米路径定位误差对比

Fig.9 Positioning error comparison with radius of 20 meters

(2) 半径40m路径测试




图10 半径40米路径定位误差对比

Fig.10 Positioning error comparison with radius of 40 meters

(3) 随机路径测试1




图11 随机路径1定位误差对比

Fig.11 Positioning error comparison with random path 1

(4) 随机路径测试2




图12 随机路径2定位误差对比

Fig.12 Positioning error comparison with random path 2

6.3 基于Optitrack辅助的室内地形测试

本节在Optitrack实验环境下,搭建了模拟地形,如图13所示,场地内含有障碍物及模拟起伏地形。同时在无人车平台及传感器上布置了捕获点,从而在Optitrack环境下构建跟踪刚体,如图14所示,给出了实验平台捕获示意。

实验进程如图15所示,展示了不同时刻行进过程。图16给出了在上述地形的重构结果,为了提高计算效率限制了视觉传感器的采样范围,从结果可以看出地形起伏趋势与所设置地形基本一致,在位置1处,对应实际地形坡度变化较大的地方,由于车体在向上倾斜的趋势运行过程中,传感器对于斜坡处于盲区,无法有效检测到,故这里地形处会出现缺失的现象,在后续分析中,通过采样点间的变化趋势拟合实现地形的全连接估计;在位置2处,实际地形为绿色地毯,由于地毯末尾处将其弯成一定曲率,从实验结果可以清楚的看出来对这种细节的有效检测。




图13 室内验证环境示意

Fig.13 The indoor verification environment




图14 实验平台示意及捕获刚体构建示意

Fig.14 Experimental platform and rigid body construction

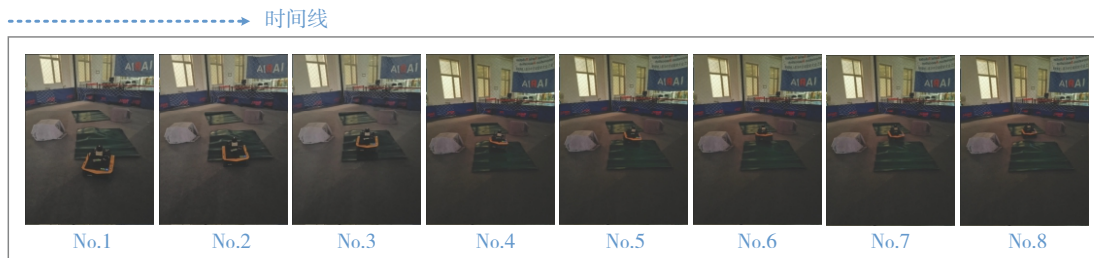


图15 不同时刻实验示意

Fig.15 Experiment at different times




图16 地形重构结果示意

Fig.16 Terrain mapping results

图17给出了测试地形的实验结果，其中红色曲面为地形的估计值，蓝色曲面和绿色曲面分别代表了地形估计值的 3σ 分布上下边界，黄色曲面为实际地形值，根据传感器测量范围的限制，在图中用黄色点画线给出了有效估计区域的范围，

同时给出了偏差较大部分的细节展示图，从小图可以看到地形的估计值与实际值均处于上下边界范围内，上下边界范围偏差小于5cm。

同时结合图18，可以对比出算法对于地形的估计值与真实值之间的误差，针对有效识别区域

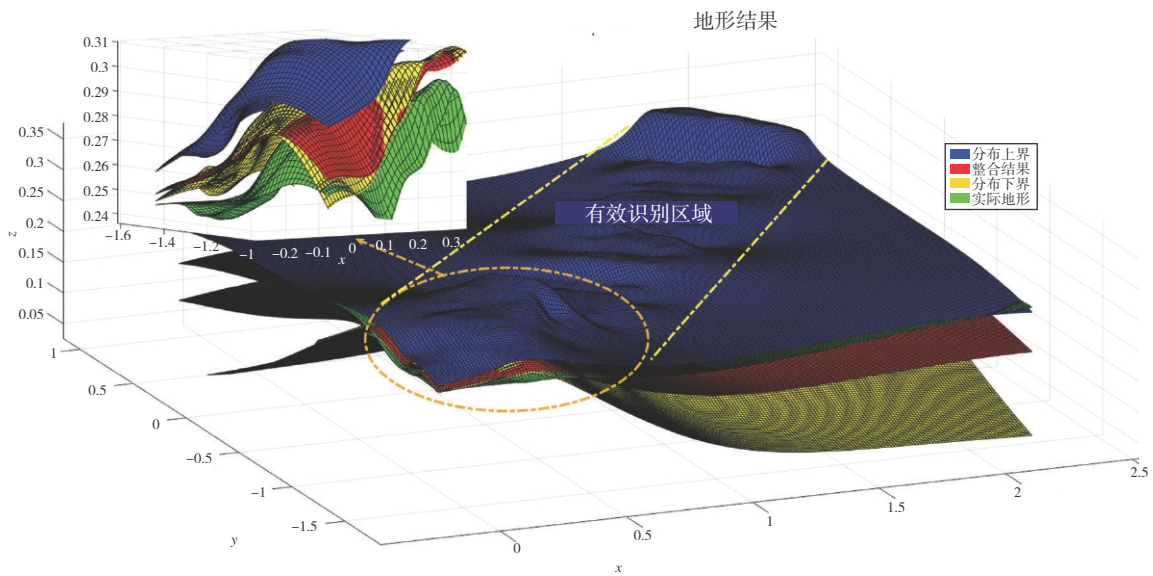


图17 地形重构结果对比分析

Fig.17 Comparative analysis of terrain mapping results

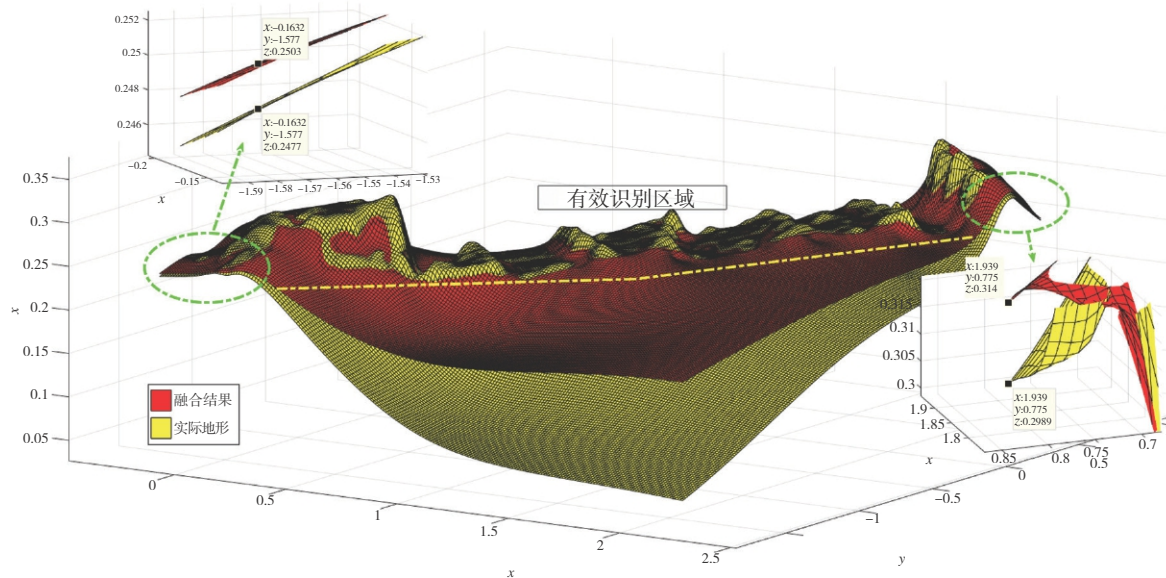


图18 地形估计值与真实值对比分析

Fig.18 Comparative analysis of terrain estimates and real values

的地形起伏，给出了地形对比的细节图，并选择相同的 x 和 y 点进行高度值的对比，由左图所示，在相对平坦的地形误差在0.26cm，由右图所示，末端高度偏差在1.51cm。其过程偏差也基本处于2cm的偏差之内。

图19则针对地形剖面进行了分析，因为本实验不是基于固定直线行走，完全遵循三维实际运

动过程，故选择中间测量值所对应的地形剖面进行分析，从大图中可见估计值与真实值偏差最大的部分处于蓝色虚线框范围，从细节图可以看到，相同 x 值对应的高度偏差处于0.8cm范围内，因为所选参考切面为相机采样较为集中和平均的地方，其测量精度相对较高，同时从曲线变化趋势可以看出，在地形变化的地方比平坦区域 3σ 分布范围




图19 地形重构结果剖面示意
Fig.19 Terrain reconstruction result profile




图20 地形重构三维点云示意
Fig.20 3D point cloud representation of terrain reconstruction

相对较宽，这也符合平坦地形估计精度高，起伏地形估计偏差大的特点。结合图 20 所示的全局点云信息，可以分析出地形的整体估计效果与实际接近，相比于平台车轮的直径大小，误差量级完全符合实际运行过程的需要。

下面给出在 Optitrack 环境下定位精度测试结果，在室内环境中做了两组测试，分别是圆形路径和直线型路径，其中加入了基于视觉的定位对比。

(1) 圆形路径

由图 21 可知，在室内环境下做圆形运动，本文方法在定位精度上要优于基于视觉的定位结果，在运行过程中，本文算法的定位误差在 4cm 以内，而基于视觉的定位误差在 20cm 左右，可以说明所提算法在圆形路径应用中其定位精度有了一定的提升。

(2) 直线路径


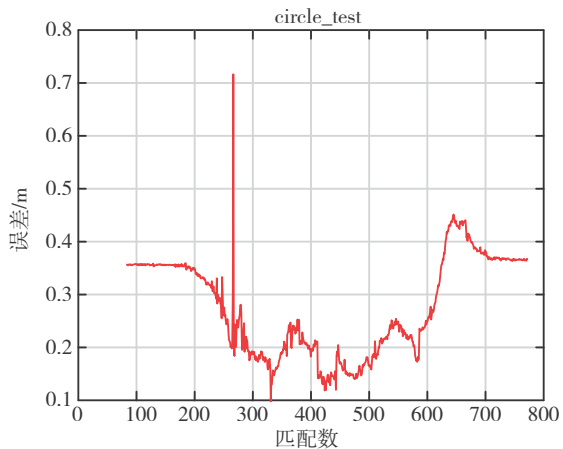
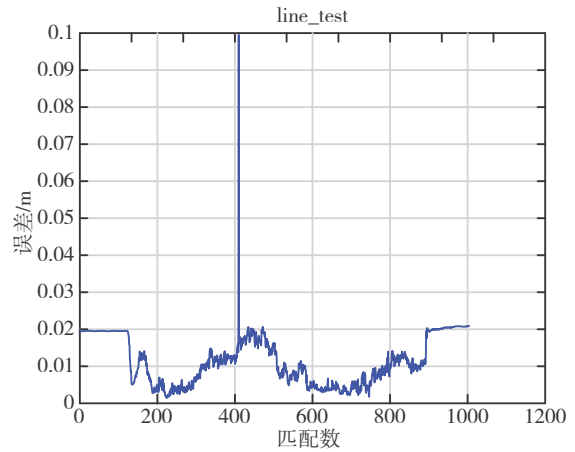
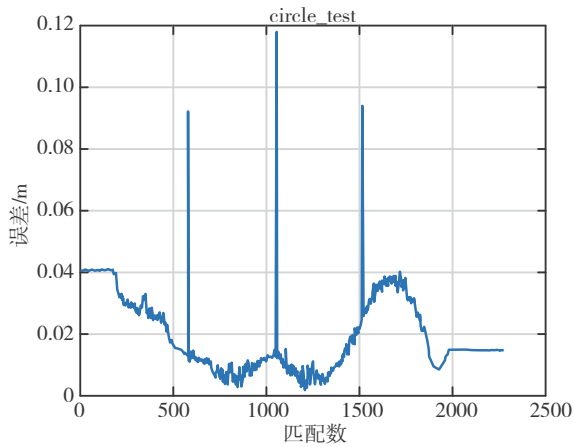
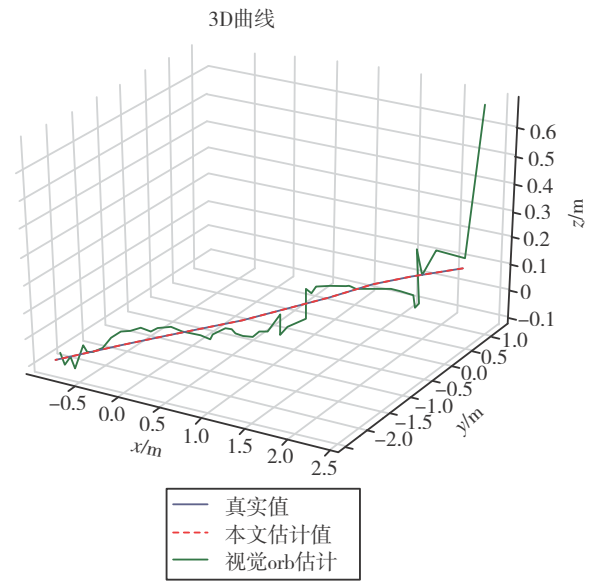



图21 圆形路径定位误差对比

Fig.21 Circular path positioning error comparison

图22 直线路径定位误差对比

Fig.22 Linear path positioning error comparison

由图22可知，在室内环境下做直线运动，本文方法在定位精度上同样要优于基于视觉的定位，在运行过程中，本文算法的定位误差在2cm以内，

而基于视觉的定位误差在9cm以内，同样说明，本文提出的算法在直线路径中其定位精度有了可观的提升。

6.4 室外土壤环境地形测试

在完成上述测试之后，对算法的估计精度有了定量的认识，但毕竟相对于实际运行环境，无论是地形的起伏还是环境的影响都较为理想，故本节将基于模拟月面土地环境进行测试，来类比在地外天体运行时的实际环境状况。图23给出了实验环境及重构出来的地形结果，由图可知实际运行环境错综复杂，除了土壤还有杂草，这给实际的估计带来了不小的干扰，从结果对比可看出地形的感知趋势大致与行进趋势相一致。




图23 室外测试环境示意及地形重构结果

Fig.23 Outdoor test environment and terrain reconstruction results

图24给出了室外土壤环境下的测试结果，由于无法准确测量地形的起伏，同时实验距离相对较近，这里用里程计测量值近似看做真值。地形重构结果如图25所示，从中间部分的有效检测区

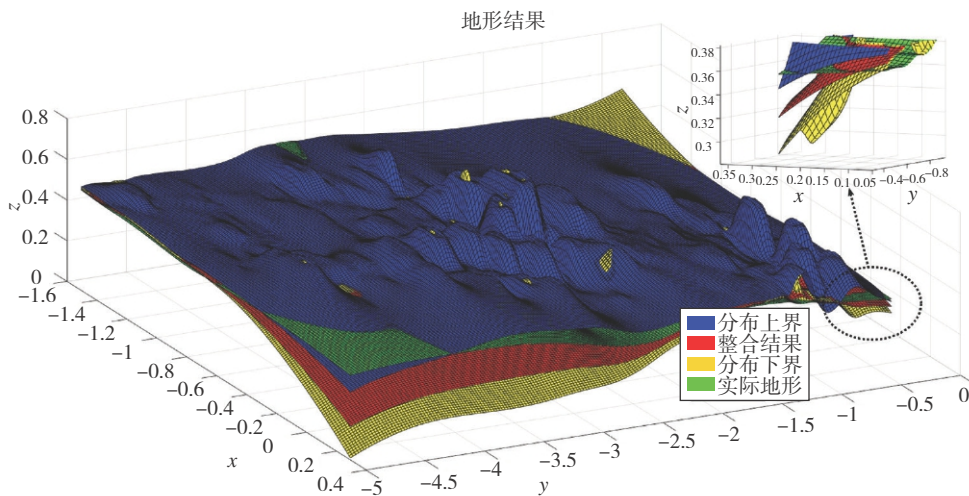


图24 地形重构结果对比分析

Fig.24 Comparative analysis of terrain mapping results

可以看出地形起伏偏差较大，细节处区间范围接近9cm，同时出现了分布曲面交叉的情况，这说明了室外运行环境干扰较大，算法估计值受传感器测量、平台运动，以及传感器与平台固联偏差的影响很容易出现偏差。由图26可以得出两者在高度方向个别位置的最大偏差接近8cm，但大多数还是处于3cm偏差以内，这与环境的不确定性有一定的关系，同时近似真实地形与实际地形也有一定的差异，从后续的路径规划结果可以看出在实际应用中地形重构精度可以满足实际需求，故这里可以给出地形估计偏差在6.5cm以内。

图27则给出了运行过程地形剖面的结果示意，相较之前两种测试 3σ 分布区间明显较大，在运行停止的时候由于平台惯性作用，加上地形的凹凸不平，以及传感器与平台连接处在平台运动环境下不可避免的微小颤振影响，都会导致估计的不确定性，从而出现曲面之间的交叉，说明了实际运行过程受外界影响较大。

除此之外，在室外环境下，还进行了大范围的移动测试，同时与激光雷达定位精度值进行对比，其结果如图28所示，可以看到在精度上有一定的不同，从实际的路线测量可以得出精度值要优于激光雷达，在后续的研究中将给出对比测试真值，深入分析精度的提升大小。

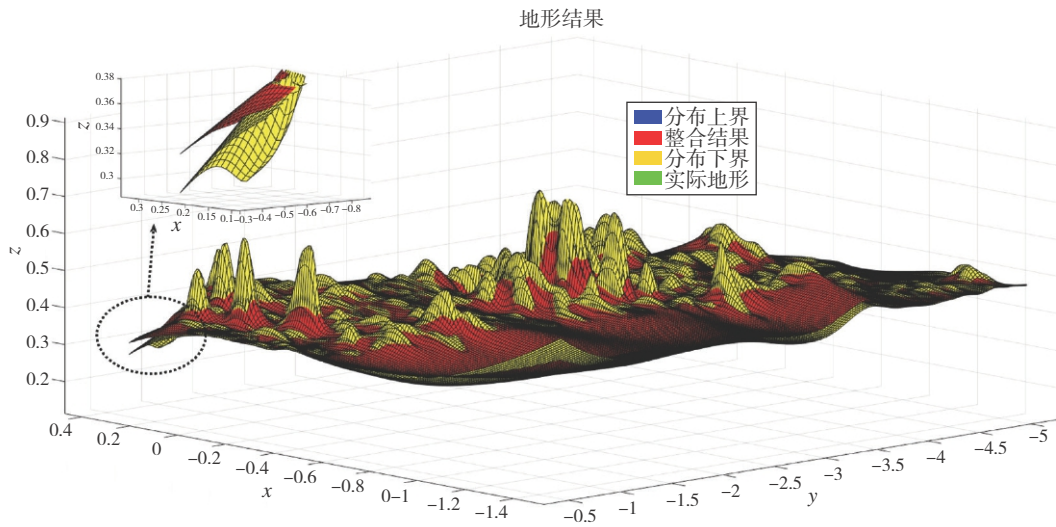


图25 地形估计值与真实值对比分析

Fig.25 Comparative analysis of terrain estimates and real values




图26 地形估计值与真实值点云示意图

Fig.26 Point clouds of terrain estimates and real values




图27 地形估计结果剖面对比分析

Fig.27 Comparative analysis of profile values of terrain estimation results




图28 室外测试定位精度对比

Fig.28 Outdoor test positioning accuracy comparison

7 结论

本文针对图像信息不可用情况下，巡视器依然具备地形感知能力的需求，提出了考虑不确定性影响的振动/陀螺仪耦合地形估计方法，兼顾了传感器测量不确定性及平台运动不确定性的影响。并基于Unity3D/ROS的月面仿真环境、室内Optitrack辅助环境、室外土壤环境进行了综合测试，结果表明本文所提出的地形估计算法在仿真环境及室内环境下具有较好的估计精度，其中仿真环境精度在1cm以内，室内环境下估计精度在2cm以内，但是受表面杂质干扰，以及传感器测量、平台运动、传感器与平台固联偏差等影响，在凹凸不平的室外土壤环境中估计偏差较大，虽然实际地形不可精确获得，但从所用无人平台载体在室外的运行情况可以得出估计误差应小于平台的底盘高度，即小于6cm，与其20cm的轮毂直径相比，也具有一定的实际应用价值。综合本文研究结果，提出的传感器配置及重构算法具有厘米级的重构能力，但后续仍需要在大尺度环境下，对全局高精度估计优化以及语义地形构建方面进行深入研究，为地外天体巡视提供可靠的地形感知保障。

参考文献

[1] Beaty D, Hipkin V, Caudill C, et al. Geological evaluation

of the MSRAD field site by a human field party: implications for rover-based exploration operations and for the future human exploration of Mars [J]. *Planetary and Space Science*, 2019.

[2] Lawrence S J, Neal C R, LEAG Executive Committee. The open gateway: lunar exploration in 2050 [C]. *Planetary Science Vision 2050 Workshop*, Washington, 2017.

[3] Brady A L, Nawotniak S E, Hughes S, et al. Strategic planning insights for future science-driven extravehicular activity on Mars [J]. *Astrobiology*, 2019, 19 (3): 347-368.

[4] Pradel D L, Gao Y. A survey on terrain assessment techniques for autonomous operation of planetary robots [J]. *Journal of the British Interplanetary Society*, 2010, 63: 206-217.

[5] Olson C F, Matthies L H, Wright J R, et al. Visual terrain mapping for Mars exploration [J]. *Computer Vision & Image Understanding*, 2007, 105 (1): 73-85.

[6] Li R, Archinal B A, Arvidson R E, et al. Spirit rover localization and topographic mapping at the landing site of Gusev crater, Mars [J]. *Journal of Geophysical Research*, 2006.

[7] Tong C H, Barfoot T D. Three-dimensional SLAM for mapping planetary work site environments [J]. *Journal of Field Robotics*, 2012, 29 (3): 381-412.

[8] Polotski V, Ballotta F J, James J. Autonomous navigation and mapping system for MRPTA rover [C]. *30th International Symposium on Automation and Robotics in Construction and Mining*, 2013.

[9] Bajpai A, Burroughes G, Shaikat A, et al. Planetary monocular simultaneous localization and mapping [J]. *Journal of Field Robotics*, 2016, 33 (2): 229-242.

[10] Gonzalez R, Apostolopoulos D, Iagnemma K. Slippage and immobilization detection for planetary exploration rovers via machine learning and proprioceptive sensing [J]. *Journal of Field Robotics*, 2018, 35: 231-247.

[11] Wong C, Yang E, Yan X, et al. Adaptive and intelligent navigation of autonomous planetary rovers—a survey [C]. *NASA/ESA Conference on Adaptive Hardware and Systems*, Pasadena, 2017.

[12] Carrio J H, Poulakis P, Kirchner F. Adaptive localization and mapping with application to planetary rovers [J].

- Journal of Field Robotics, 2017, 35: 961–987.
- [13] Shaukat A, Blacker P C, Spiteri C, et al. Towards camera–LIDAR fusion–based terrain modelling for planetary surfaces: review and analysis [J] . Sensors, 2016.
- [14] Yang H, Ding L, Gao H, et al. Dynamic simulation of planetary rovers with terrain property mapping [C] . IEEE International Conference on Robotics and Automation, Brisbane, 2018.
- [15] Thrun S. Robotic mapping: a survey [R] . Carnegie Mellon University, 2002.
- [16] Bresson G, Alsayed Z, Yu L, et al. Simultaneous localization and mapping: a survey of current trends in autonomous driving [J] . IEEE Transactions on Intelligent Vehicles, 2017.
- [17] Ye C, Borenstein J. A new terrain mapping method for mobile robots obstacle negotiation [J] . Proceedings of SPIE–The International Society for Optical Engineering, 2003.
- [18] Wolf D F, Sukhatme G S, Fox D, et al. Autonomous terrain mapping and classification using hidden markov models [C] . IEEE International Conference on Robotics and Automation, Barcelona, 2005.
- [19] Gingras D, Lamarche T, Dupuis E, et al. Rough terrain reconstruction for rover motion planning [C] . IEEE Canadian Conference on Computer and Robot Vision, Ottawa, 2010.
- [20] Hebert M, Caillas C, Krotkov E, et al. Terrain mapping for a roving planetary explorer [C] . IEEE International Conference on Robotics and Automation, Arizona, 1989.
- [21] Krotkov E, Hoffman R. Terrain mapping for a walking planetary rover [J] . IEEE Transactions on Robotics and Automation, 1994, 10 (6): 728–739.
- [22] Whitaker R T. Reconstructing terrain maps from dense range data [C] . International Conference on Image Processing, Thessaloniki, 2001.
- [23] Whitaker R T, Gregor J. A maximum–likelihood surface estimator for dense range data [J] . IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24 (10): 1372–1387.
- [24] Cremean L B, Murray R M. Uncertainty–based sensor fusion of range data for real time digital elevation mapping [C] . IEEE International Conference on Robotics and Automation, Barcelona, 2005.
- [25] Ishigami G, Otsuki M, Kubota T. Range–dependent terrain mapping and multipath planning using cylindrical coordinates for a planetary exploration rover [J] . Journal of Field Robotics, 2013, 30 (4): 536–551.
- [26] Fankhauser P, Bloesch M, Hutter M. Probabilistic terrain mapping for mobile robots with uncertain localization [J] . IEEE Robotics and Automation, 2018, 3 (5): 3019–3026.

作者简介:

郭继峰(1977–), 男, 博士, 教授, 主要研究方向为空间机器人智能感知与自主规划技术。

白成超(1990–), 男, 博士研究生, 主要研究方向为空间机器人智能感知技术、SLAM。

光学遥感影像超分辨率重构研究进展

赵晓冬¹, 张洵颖¹, 程雪梅²

(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365研究所, 西安 710072)

摘要: 对光学遥感影像超分辨率重构领域的相关研究进行综合论述, 并进行展望。首先分别介绍了基于多帧和单帧遥感影像的降质模型, 分析了针对超分辨率重构这类病态问题的解决方法, 指出对其求解需要施加先验约束将其转化为适定问题; 随后概括了超分辨率重构技术发展史上的经典算法及其在光学遥感影像中的应用; 最后对现有研究状态下亟待解决的问题进行概括。综述表明, 从最大后验估计、迭代反投影、凸集投影、确定性正则化、稀疏表示、偏微分方程到深度学习, 基于光学遥感领域的超分辨率重构算法及应用已经步入智能时代。

关键词: 光学遥感影像; 超分辨率重构; 稀疏表示; 偏微分方程; 深度学习

中图分类号: TP751 **文献标识码:** A **文章编号:** 2096-5915 (2019) 03-0466-08

Advances in Super Resolution Reconstruction of Optical Remote Sensing Images

ZHAO Xiaodong¹, ZHANG Xunying¹, CHENG Xuemei²

(1. Northwestern Polytechnical University, Unmanned System Research Institute, Xi'an 710072, China,

2. Northwestern Polytechnical University, Institute of 365, Xi'an 710072, China)

Abstract: The related research in the field of super-resolution reconstruction of optical remote sensing images is comprehensively discussed and prospected. Firstly, the degradation models based on multi-frame and single-frame remote sensing images are introduced, and the solutions to ill-posed problems such as super-resolution reconstruction are analyzed. It is pointed out that prior constraints should be applied to the solution of these ill-posed problems. Then, the classical algorithms in the history of super-resolution reconstruction technology and their applications in optical remote sensing images are summarized. Finally, the existing research problems that need to be solved urgently are summarized. The review shows that super-resolution reconstruction algorithms and applications based on optical remote sensing have entered the era of intelligence, going through the research of maximum posteriori estimation, iterative back-projection, convex set projection, deterministic regularization, sparse representation, partial differential equation and deep learning.

Keywords: Optical Remote Sensing Image; Super-Resolution Reconstruction; Sparse Representation; Partial Differential Equation; Deep Learning

收稿日期: 2019-04-01; 修回日期: 2019-05-08

1 引言

随着航空航天遥感技术的发展, 遥感影像的数据量大幅增加, 高分辨率光学遥感影像具有丰富的纹理、空间和语义信息。在军事领域可以检测特定军事目标如舰船、飞机等, 获得情报进行精确制导, 在民用领域可以感知城市状态, 监测海洋漏油、病虫害、灾后搜救、土地调查等。然而在获得影像的过程中, 遥感系统会受到如气流扰动、成像衍射、传输干扰、相对姿态变化、下采样、附加噪声等多种因素的影响, 导致影像的像质下降。利用硬件途径提高影像分辨率的方法被众多因素所限制。

超分辨率(Super Resolution, SR)重构^[1]指在观测系统不改变的前提下, 利用算法恢复影像获取过程中所丢失的成像截止频率以上的高频信息, 分为单帧影像重构和多帧序列影像重构。单帧影像重构是典型的数学反问题, 充分利用先验知识进行影像重构, 非常适用于不能直接获取序列影像的应用场景。多帧影像充分利用影像之间的冗余互补信息, 结合先验知识, 可以获得更好的重构应用效果。多帧重构算法通过时间分辨率的牺牲提高空间分辨率, 算法更为复杂。

随着遥感领域的不断发展, 如何通过各类理论来有效进行超分辨率重构, 是目前光学遥感影像恢复领域非常有前途的研究热点。遥感领域的

研究人员应当充分运用遥感技术和信号分析技术, 获得更多的地物特征信息, 为光学遥感影像的后续分析奠定基础。

2 光学遥感影像降质模型

在光学遥感影像重构当中, 降质模型对于求解非常重要, 反映了高分辨率目标遥感影像与低分辨率观测遥感影像间的映射关系, 可以体现退化因素。在光学遥感影像成像过程当中, 假设 $X(x, y)$ 代表不失真连续信号物影像, 退化得到序列低分辨率观测影像 $Y_i(k, l) (i=1, 2, \dots, p)$ 为离散影像。当满足采样定理时, $X(x, y)$ 可以被不失真地转换为离散影像 $X(k, l)$, 即原始数字影像。光学遥感影像的降质模型框图如图1所示。

基于多帧光学遥感影像的降质模型表述为:

$$Y_k = DB_k M_k X + n_k \quad k=1, 2, \dots, p \quad (1)$$

该降质模型表示基于多帧光学遥感影像的重构模型, 假设高分辨率影像大小为 $L_1 N_1 \times L_2 N_2$, 参数 L_1 和 L_2 表示水平和竖直方向的降采样因子, X 代表需要计算重构的高分辨率遥感影像, Y_k 表示第 k 帧观测到的低分辨率影像, M_k 表示第 k 帧影像对应的运动矩阵, B_k 表示第 k 帧影像对应的模糊矩阵, D 表示降采样矩阵, n_k 表示第 k 帧的加性噪声。

基于单帧光学遥感影像的降质模型表示为:

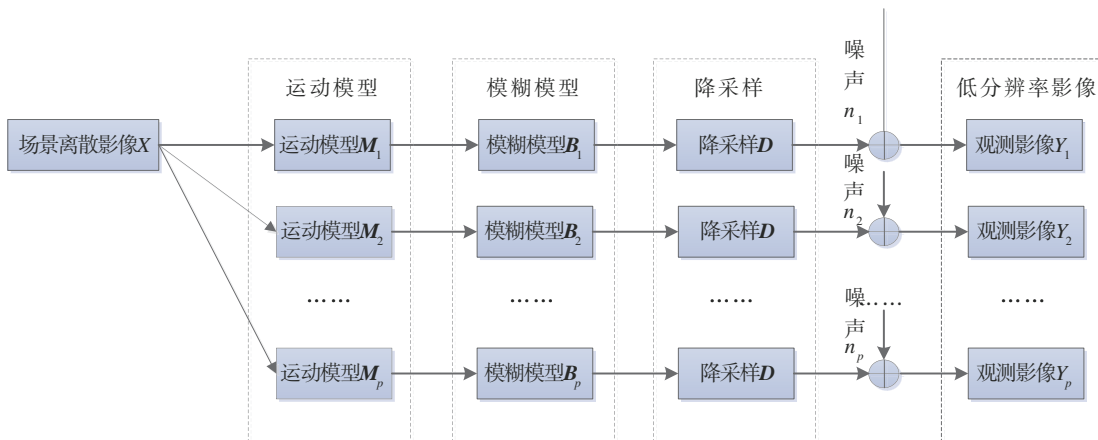


图1 光学遥感影像降质模型原理图

Fig.1 Principle diagram of optical remote sensing image degradation model

$$Y = DHX + n \quad (2)$$

其中, X 表示需要计算重构的高分辨率遥感影像, Y 表示观测到的低分辨率遥感影像, H 表示模糊矩阵, D 表示降采样矩阵, n 表示噪声矩阵。

3 病态性问题解决方法

遥感影像的成像过程受到光学衍射、噪声、欠采样等多种因素影响, 造成影像降质的过程是一个数学正问题, 从降晰且离散的遥感影像中估计连续信号, 是非常经典的数学反问题。对于遥感成像系统来说, 在逆滤波时, 噪声非常可能会被放大继而淹没真实信号; 卷积函数精确表达形式未知, 对其求逆向反卷积从本质上讲不可行; 即使噪声和核函数已经精确已知, 逆滤波也不能获得有意义可解释的解, 所有这些因素都会导致重构变成非常严重的不适定问题。

针对这类不适定问题, 对其进行求解的过程中, 需要施加一定程度的先验条件及限制, 从而将其转为适定问题求解, 实现这一转化的思路称之为正则化 (Regularization)。正则化算法的主要解决思路是利用各类先验知识修改原问题, 将其变为最小化问题, 或将求解过程变为投影迭代问题, 并在此过程中对数据范围加以限制, 抑制不合理的解; 对解建立相应的统计模型, 并将其作为先验知识, 从而使求解问题变成参数的估计和优化问题。

4 超分辨率重构算法

4.1 最大后验估计

最大后验估计 (Maximum A Posteriori, MAP) 算法进行重构的主要思想是在已知低分辨率观测序列的前提下, 使高分辨率出现的后验概率最大。假设有 k 幅低分辨率观测图像, 表示为 $g = \{g_1, g_2, \dots, g_k\}$, 则超分辨率重构问题表述为:

$$\hat{f}(m, n) = \arg \max_f \{P(f(m, n) | g_k(x, y))\} \quad (3)$$

依据贝叶斯定理, 有条件概率:

$$P(f(m, n) | g_k(x, y)) = \frac{P(f(m, n))P(g_k(x, y) | f(m, n))}{P(g_k(x, y))} \quad (4)$$

将式 (4) 代入式 (3), 并取对数可得:

$$\hat{f}(m, n) = \arg \min_f \left\{ \begin{array}{l} -\log P(f(m, n)) \\ -\log P(g_k(x, y) | f(m, n)) \end{array} \right\} \quad (5)$$

其中, 第二项代表高分辨率影像存在时低分辨率影像的概率密度函数, 代表噪声模型类型, 第一项代表影像先验模型, 不同噪声模型及先验模型均会产生相应最小化函数, 可以选择 Huber-MRF、Gaussian-MRF 等先验模型进行描述。MAP 的超分辨率重构应用非常早, 研究人员针对火星探测器 Viking 获取的多幅低分辨率影像, 运用 MAP 技术恢复并进行了三维高分辨率影像重构。Shen H F 等^[2]在扩展 MAP 框架的基础上, 将运动估计、分割与超分辨率重构过程建立在统一的框架当中, 使 MAP 可以应用在针对多个运动目标以及场景剧烈变化情况下的重构过程之中。

4.2 迭代反投影

迭代反投影 (Iterative Back Projection, IBP) 算法采用待求高分辨率影像初始估计作为当前计算结果, 将此结果通过观测模型投影得到低分辨率模拟影像, 随后采用迭代方式逐步减少模拟降质过程所得影像与实际低分辨率影像之间的误差, 根据该误差不断更新当前估计, 从而迭代循环获得最终的重构影像。Friden B R^[3]将代数层析相关滤波理论引入投影算法中, 并将其推广到彩色视频重构领域, IBP 方法很容易理解, 其缺点是解不具备唯一性, 迭代过程存在不收敛的可能性, 难以引入先验知识。

4.3 确定性正则化

确定性正则化算法利用先验知识增加约束, 使解可以连续依赖于观测数据并且具备物理意义,

基于正则化变分理论的重构技术，根据影像的降质模型建立代价函数，进行最小化求解，获得最优重构影像，该类算法计算复杂度较小，并且可以达到较好的重构效果，其框架表示为变分模型：

$$\hat{f} = \arg \min_z \left[\sum_{k=1}^p \|g_k - W_k f\|_2^2 + \lambda U(f) \right] \quad (6)$$

其中，第一项代表数据约束项，用于衡量观测数据 g_k 和理想数据 z 之间相一致的程度；第二项代表正则化项，用于约束光滑性和有界变差等图像先验信息； λ 代表均衡二者的正则化参数，控制求解过程中的贡献量。该类型影像重构框架围绕三个问题展开： $U(f)$ 的具体设计、 λ 的参数选取以及变分模型求解。较为经典的正则化算子包括 Tikhonov 模型、TV 模型、双边全变分模型和自适应双边全变分模型。

式 (6) 可以视为非约束最优化问题，利用变分法将求解最优问题转化为求解欧拉-拉格朗日方程问题。变分 PDE 可以更好地处理曲率、梯度、水平集和切线等敏感信息，可以采用较为成熟的优化方法和计算算法，具备稳定性，可以获得较高的影像质量。针对式 (6) 的能量函数，欧拉-拉格朗日方程可以描述为：

$$\sum_{k=1}^p W_k^T \cdot ((W_k \hat{f} - g_k) + \lambda Q^T Q \hat{f}) = 0 \quad (7)$$

可以使用最速下降法进行超分辨率重构问题的求解，利用最速下降法进行运算的迭代公式描述为：

$$\hat{f}^{n+1} = \hat{f}^n - \beta \left[\sum_{k=1}^p (W_k^T \cdot W_k \hat{f}^n - W_k^T \cdot g_k) + \lambda Q^T Q \hat{f}^n \right] \quad (8)$$

4.4 凸集投影

凸集投影 (Projection Onto Convex Sets, POCS) 算法^[4]认为，高分辨率影像约束条件可以定义为向量空间的凸集合，只要求取集合交集，便可获得超分辨率影像的解。该算法在可行解的空间内定义一系列约束条件，包括观测数据的正定性、一致性、光滑性、能量有界性等，将限制条件定

义为完备内积空间的紧凸集，通过求解交集获取重构的最终解。假设影像的 n 个约束集定义为相应的投影算子，分别表示为 P_1, P_2, \dots, P_n ，则高分辨率影像通过迭代方程进行求解。

$$f_{k+1} = P_n \cdot P_{n-1} \cdot \dots \cdot P_2 \cdot P_1 \cdot f_k \quad (9)$$

POCS 算法决定于每个投影算子的选择，其中，数据一致性约束最为重要，描述了高低分辨率影像间的关系，IBP 算法为 POCS 算法只考虑数据一致性时的特殊情况。POCS 中可以引入像素取值范围约束、幅度约束、参考图像约束、能量约束等条件，并且可以将噪声模型、采样格网及运动模糊、改进 PFS 系数、分割图、时空联合自适应^[5]等概念引入约束中进行凸集求解。缺点是解不唯一，收敛速度慢，依赖初始条件。有学者提出将 POCS 和 MAP 结合起来^[6-7]进行重构，给出了输出解的收敛证明和唯一性证明。

4.5 稀疏表示

压缩感知理论^[8]突破奈奎斯特定理，以远低于奈奎斯特的频率，对信号进行压缩采样，通过与稀疏基不相关的测量矩阵，将信号从高维投影至低维，通过求解最优化问题，从少量观测值中，以较高或完全概率重构原始信号。字典稀疏表示原理如图 2 所示。




图2 字典稀疏表示原理图

Fig.2 Principle diagram of dictionary sparse representation

离散数字信号，即影像 $x \in R^N$ 可以由基向量 $\{\psi_i\} i=1, \dots, k$ ， $\psi_i \in R^N$ 的线性组合形式表示为

$x = \sum_{i=1}^k \alpha_i \psi_i$, 其中, α_i 为表示系数。当 $\|\psi_i\|_2 = 1$ 时, 称 ψ_i 为原子, 将 $\Psi = \{\psi_i\}_{i=1, \dots, k}, \Psi \in R^{N \times K}$ 称为字典。根据 N 与 K 的大小关系分为三种情况: $N > K$ 时, 字典欠完备; $N = K$ 时, 字典完备; $N < K$ 时, 字典过完备。

矩阵形式表示为式(10), α 为 x 关于 Ψ 的稀疏系数。

$$x = \Psi\alpha \quad (10)$$

假设光学遥感影像的重构模型描述为:

$$y = \mathbf{D}\mathbf{B}x + n \quad (11)$$

其中, y 代表降质图像, x 代表重构目标图像, \mathbf{B} 代表模糊因子, \mathbf{D} 代表降采样因子, 假设影像 x 在过完备字典中足够稀疏, $x = \Psi\alpha$, 则 x 可由低维观测值 y 求解:

$$\alpha_0 = \min_{x=\Psi\alpha} \left\{ \|y - \mathbf{D}\mathbf{B}\Psi\alpha\|_2^2 + \lambda \|\alpha\|_1 \right\} \quad (12)$$

$\hat{x} = \Psi\alpha_0$ 为重构获得的超分辨率影像。大批学者针对稀疏表示进行了算法研究, 刘志州^[9]提出了基于多任务的字典学习算法, 将结构相似性局部约束引入其中, 基于K-SVD字典学习实现影像的超分辨率重构。首照宇^[10]提出不借助额外数据库进行学习的算法, 采用PCA迭代训练K-均值聚类过的低分辨率影像, 生成具有自适应能力的子字典, 利用非局部自相似性和IBP对重构影像进行后处理。申世闻^[11]提出了针对单帧影像的基于多尺度相似性的超分辨率重构算法, 以及基于结构相似性学习和IBP结合的重构算法。基于稀疏表示的算法思想曾主导了相应领域的研究方向。

4.6 偏微分方程

基于偏微分方程(Partial Differential Equation, PDE)的模型^[12-13]根据像素点局部邻域信息, 判断该点的区域特征, 在不同的区域进行各向异性扩散, 在平滑噪声的同时, 保持或增强边缘。偏微分方程的发展经历了由线性到非线性, 由各向同性扩散到各向异性扩散的过程, 可以归结为求解初始值为输入影像的非线性扩散问题。

PDE最早协助建立了图像的多尺度表达理论,

从Perona-Malik(P-M)方程、MCM及其改进模型、张量扩散模型到高阶模型, PDE理论开创了一个新的领域。文献[12]在综合考虑平滑区域、边缘区域、角点和交叉点区域三类不同维度特征的基础上结合高阶张量进行分析, 提出了基于偏微分方程统一架构的单帧重构模型。邵文泽^[13]进行了结构张量图像建模方法的研究, 设计了统一正则化的PDE模型, 更好地刻画角形、平坦、边缘结构的滤波性能, 并分别进行了图像修补、图像插值、超分辨率重构等实验的验证。

4.7 深度学习

目前已涌现很多成熟的基于深度学习的超分辨率重构研究成果, 其中, 基于端到端的超分辨率算法是主流研究方向, 可高效运行于GPU平台。卷积神经网络(Convolutional Neural Networks, CNN)通过训练学习颜色、边缘、纹理、形状以及图像拓扑结构等特征, 对结构进行准确描述, 已被证明是深度学习中最好了的结构。

SRCNN^[14-15]算法于2014年开启了CNN算法在超分辨率重构领域当中的探索之门, 利用深度学习网络训练适合LR图像重建的模型, 直接学习输入图像和输出图像的关系, 合理优化网络参数。FSRCNN^[16]采用无预处理的图像作为输入, 将SRCNN中的非线性映射部分替换为压缩、映射和扩展。VDSR^[17]引入残差网络的思想, 仅仅学习高低分辨率图像的残差, 并将网络结构扩展到20层。

ESPCN^[18]是基于多帧图像的SR重构网络, 图像尺寸放大过程的插值函数被隐含地包含在前面的卷积层中, 可以自动学习到。SRGAN^[19]在生成模型的基础上增加对抗模型, 生成网络生成高分辨率图像, 对抗网络判断拿到的图像是由生成网络生成的, 还是数据库中的原图, 从而相互促进完成SR重构的过程。LapSRN^[20]实现多级结构, 每一级完成一次两倍上采样操作, 每一级先通过级联卷积层提取特征, 并通过反卷积层将提取出的特征尺寸上采样两倍。通过逐步上采样, 一级

一级预测残差,对每一级的结果进行监督。

DRCN^[21]第一次将递归神经网络结构应用在SR重构问题的求解中,利用残差学习的方法加深网络结构,增加网络感受野,提升性能。DRRN^[22]对ResNet等结构进行相应的调整,采取了更深的网络结构,最佳网络深度是52层,是一种多路径模式的局部残差学习、全局残差学习合并多权重递归学习的网络模型。

SRDenseNet^[23]在稠密块中将每一层的特征都输入给后续所有层,将所有层的特征并置,减少参数数量。EDSR^[24]去掉了ResNet中的批规范化操作,使网络可以堆叠更多层数或在每层提取更多特征,获得更好的性能表现。

5 光学遥感影像重构应用

在基于超分辨率算法的遥感应用中,学者们基于各类重构理论进行了广泛的研究,陆续将以上超分辨率重构相关理论应用于光学遥感影像的处理中,应用传统方法对遥感影像进行重构的研究成果较为成熟,基于深度学习的应用还在不断探索。有学者尝试将深度学习框架下的超分辨率重构算法应用到卫星影像重构过程中^[25],获得了较好的重构效果。此外,也有其他学者在基于深度学习的超分辨率重构领域获得了研究成果^[26-28]。

一些学者利用基于小波域的重构算法^[29]对SPOT遥感影像进行算法应用,通过三线阵相机获取到同一场景在邻近时相和不同角度的三张前影像、中影像和后视影像,进行多帧影像的重构。也有研究人员将重构技术应用在三线阵影像中,研究光流配准、正射影像重构算法和一级影像盲超分辨重构算法^[30]。有学者开展了空域自适应滤波算法^[31]研究,将其应用于斜模式遥感影像复原系统中,进行斜模式下基于软硬件结合的影像复原算法及其应用研究,其提出的复原框架,对于重构领域具有重要启发性。也有研究人员分别分析了基于频域和空域的多种重构算法^[32],将其应用于光学遥感图像的复原过程当中,对两帧图像

频域解混叠,引入下采样、正则项、位移算子及参数设置,提出新的更加鲁棒的算法。

文献[33]提出频率混叠单帧重构算法,将之应用于卫星影像重构过程中,影像的分辨率和清晰度获得了大幅增强。中科院西安光机所团队将重构技术应用与传感器制造过程中,利用棱镜分光技术实现基于面阵的亚像元成像。文献[34]对利用多种传统重构算法对我国的资源三号卫星影像以及异源数据分别进行超分辨率实验验证。

有学者将随机分形和小波变换相结合,提出小波分形插值算法^[35],并在单帧光学遥感影像中进行应用。研究人员基于压缩感知、字典学习以及图像自相似性,实现了光学遥感影像的字典学习和超分辨率重构^[36-37],并且提出新的指标用于衡量重构效果。文献[38]对基于小波变换的边缘检测进行研究,针对遥感影像边界和噪声不清楚的问题,通过共轭梯度追踪技术实现重构精度以及效率的同步提升。一直以来,超分辨率重构技术如何能够更好地应用于光学遥感影像处理过程当中,一直是专业人员的热点研究课题。

6 结论

目前对于光学遥感影像超分辨率重构技术的研究,已经从能够获得改善影像质量发展为对算法鲁棒性、时效性、效率和应用性等众多方面的需求。如何提出通用、鲁棒、高效的重构算法,如何确定可以重构的理论极限,对于约束参数如何进行自学习,如何在保证精度的前提下对性能进行加速,如何建立可解释的重构卷积网络,如何建立更附合实际情况的退化模型,如何能够将理论研究应用于具体的实践中,都是光学遥感影像超分辨率重构领域值得关注的研究热点和发展方向。

此外,随着器件的不断升级,如何能将深度学习网络应用到嵌入式设备中进行实时计算,也是当前研究下亟待解决的重要问题之一。目前已出现多种类型的智能计算平台,包括ARM+GPU、

ARM+FPGA、单纯FPGA、TPU、NPU等各类平台，其各有特点，在一定程度上可以互补。随着国家在航空航天遥感领域的重大专项推进，随着机器学习、数据挖掘及人工智能技术、智能芯片技术的大力发展，超分辨率重构技术在遥感应用领域必将获得新的理论进展。

参 考 文 献

- [1] 杨欣. 图像超分辨率技术原理及应用 [M]. 北京: 国防工业出版社, 2013.
- [2] Shen H F, Zhang L P, Huang B, et al. A map approach for joint motion estimation, segmentation, and super resolution [J]. IEEE Transactions on Image Processing, 2007, 16 (2): 479-490.
- [3] Frieden B R, Aumann H G. Image reconstruction from multiple 1-D scans using filtered localized projection [J]. Applied Optics, 1987, 26 (17), 3615-3621.
- [4] 肖创柏, 段娟, 禹晶. 序列图像的POCSSR重建方法 [J]. 北京工业大学学报, 2009, 35 (1): 109-204.
- [5] 田敬北, 候天峰, 李梦和. 自适应视频SR重建算法 [J]. 计算机应用研究, 2011, 28 (7): 2778-2781.
- [6] 陈光盛, 李树涛. MAP和POCS算法实现SR图像的重建 [J]. 科学技术与工程, 2006, 6 (4): 396-399.
- [7] 张剑. 图像超分辨率重建问题研究 [D]. 长沙: 中南大学, 2010.
- [8] 甘伟, 许录平, 苏哲. 一种压缩感知重构算法 [J]. 电子与信息学报, 2010, 32 (9): 2151-2155.
- [9] 刘志州. 基于字典学习的超分辨率图像重构 [D]. 西安: 西安电子科技大学, 2011.
- [10] 首照宇. 基于PCA字典学习的图像超分辨率重建 [J]. 计算机工程与设计, 2015, 36 (11): 3025-3029.
- [11] 申世闻. 基于多尺度相似结构学习的单幅图像超分辨率重建 [D]. 南京: 南京理工大学, 2014.
- [12] Zhao X D, Cao J Z, Zhou Z F, et al. A novel pde-based single image super-resolution reconstruction method [J]. Journal of Pattern Recognition and Artificial Intelligence, 2017, 31 (6): 1-21.
- [13] 邵文泽. 基于图像建模理论的多幅图像正则化超分辨率重建算法研究 [D]. 南京: 南京理工大学, 2008.
- [14] Dong C, Loy C C, He K M, et al. Image super-resolution using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38 (2): 295-307.
- [15] Dong C, Loy C C, He K M, et al. Learning a deep convolutional network for image super-resolution [C]. European Conference on Computer Vision, Zurich, Switzerland, September 6-12, 2014.
- [16] Dong C, Loy C C, Tang X O. Accelerating the super-resolution convolutional neural network [C]. European Conference on Computer Vision, Amsterdam, The Netherlands, October 11-14, 2016.
- [17] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks [C]. IEEE Conference on Computer Vision and Pattern Recognition, Seattle, June 27-30, 2016.
- [18] Shi W Z, Caballero J, Huszár F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, June 27-30, 2016.
- [19] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C]. IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, July 21-26, 2017.
- [20] Lai W S, Huang J B, Ahuja N. Deep laplacian pyramid networks for fast and accurate super-resolution [C]. IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, July 21-26, 2017.
- [21] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution [C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, June 27-30, 2016.
- [22] Tai Y, Yang J, Liu X M. Image super-resolution via deep recursive residual network [C]. IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, July 21-26, 2017.
- [23] Tong T, Li G, Liu X J. Image super-resolution using dense skip connections [C]. IEEE International Conference on Computer Vision, Venice, Italy, Oct. 22-29, 2017.
- [24] Lim B, Son S H, Kim H, et al. Enhanced deep residual networks for single image super-resolution [C]. IEEE Conference on Computer Vision and Pattern Recognition

- Workshops, Honolulu, HI, USA, July 21–26, 2017.
- [25] Luo Y M, Zhou L G, Wang S, et al. Video satellite imagery super resolution via convolutional neural networks [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14 (12):2398–2402.
- [26] Cheng J Y, Park I K. Deep CNN-based super-resolution using external and internal examples [J]. IEEE Signal Processing Letters, 2017, 24 (8):1252–1256.
- [27] Wang Z Y, Yang Y Z, Wang Z W, et al. Learning super-resolution jointly from external and internal examples [J]. IEEE Transactions on Image Processing, 2015, 24 (11):4359–4371.
- [28] Kappeler A, Yoo S, Dai Q Q, et al. Video super-resolution with convolutional neural networks [J]. IEEE Transactions on Computational Imaging, 2016, 2(2):109–122.
- [29] 谭兵, 徐青, 邢帅, 等. 小波超分辨率重建算法及其在 SPOT 影像中的应用 [J]. 测绘学报, 2004, 33 (3):233–238.
- [30] 范冲. 三线阵影像超分辨率重建 [D]. 长沙: 中南大学, 2007.
- [31] 郑钰辉. 空域自适应滤波方法及其在斜模式遥感图像复原中的应用 [D]. 南京: 南京理工大学, 2009.
- [32] 杨学峰. 遥感图像频域和空域超分辨重建技术研究 [D]. 哈尔滨: 哈尔滨工业大学, 2011.
- [33] 李金宗, 李宁宁, 朱兵, 等. 遥感图像复原与超分辨理论及实现 [M]. 北京: 科学出版社, 2016.
- [34] 余新宇. 遥感图像的超分辨率重建技术研究 [D]. 成都: 电子科技大学, 2013.
- [35] 陈向欣. 遥感图像的超分辨率图像重建技术频域方法的研究 [D]. 北京: 中国地质大学, 2008.
- [36] 潘宗序, 黄慧娟, 禹晶, 等. 基于压缩感知与结构自相似性的遥感图像超分辨率方法 [J]. 信号处理, 2012, 28 (6):859–872.
- [37] 潘宗序, 禹晶, 胡少兴, 等. 基于多尺度结构自相似性的单幅图像超分辨率算法 [J]. 自动化学报, 2014, 40 (4):597–603.
- [38] 杨志远. 面向遥感图像的压缩感知重构条件及算法研究 [D]. 长沙: 国防科学技术大学, 2011.

作者简介:

赵晓冬(1986-), 女, 博士, 助理研究员, 主要研究方向为嵌入式机器视觉、遥感影像超分辨率重构。

张洵颖(1981-), 男, 博士, 研究员, 主要研究方向为星上遥感信息实时处理技术、高性能容错计算。

程雪梅(1972-), 女, 博士, 研究员, 主要研究方向为智能飞行控制与智能决策。

基于单目深度估计的视觉里程计算法

郭 爽

(哈尔滨工业大学航天学院, 哈尔滨 150001)

摘 要: 在各类视觉里程计算法所使用的传感器中, 单目相机由于成本小、质量轻、功耗低的优势, 更加适应小型移动平台的应用场景。但由于单目相机无法获取场景的深度信息, 因此各类单目视觉里程计或SLAM算法都不可避免地存在尺度不确定性的缺陷。针对这个问题, 提出了一种基于单目深度估计的视觉里程计算法, 将单目深度估计模块加入了半直接法单目视觉里程计中, 为其建图线程中的深度滤波器提供良好的初值, 克服了尺度不确定问题, 提高了视觉里程计算法的精度与鲁棒性。

关键词: 单目深度估计; 视觉里程计; 尺度不确定性; 深度学习; 导航与定位

中图分类号: V19 **文献标识码:** A **文章编号:** 2096-5915 (2019) 03-0474-09

Visual Odometry Algorithm Based on Monocular Depth Estimation

GUO Shuang

(School of Astronautics, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Among the visual sensors used in various visual odometry methods, monocular camera is more suitable for the application scenarios of small mobile platforms due to its low cost, light weight and low power consumption. However, monocular cameras cannot obtain the depth information of the scene, so all kinds of monocular visual odometry or SLAM algorithms inevitably have the defect of scale ambiguity, which greatly limits their application in actual navigation scenarios. To solve the above problems, a semi-direct visual odometry algorithm based on monocular depth estimation is proposed in this paper, added a monocular depth estimation module into the semi-direct visual odometry, which provides a good initial value to the depth filter. In this way, the inherent defect of scale ambiguity is overcome, and the accuracy and robustness of monocular visual odometry are improved.

Keywords: Monocular Depth Estimation; Visual Odometry; Scale Ambiguity; Deep Learning; Navigation and Localization

1 引 言

视觉导航凭借其导航信息丰富、应用领域广泛等优点受到了人们的广泛关注, 近年来在移动机器人及无人飞行器上的应用越来越多。视觉里程计(Visual Odometry, VO)和即时定位与地图构建(Simultaneous Localization And Mapping, SLAM)

是当今视觉导航领域中的重要组成部分, 也是当下最受关注的研究热点。

导航中常用的视觉传感器有单目相机、双目相机和RGB-D相机。其中, RGB-D相机由于其自身测量原理的限制, 深度测量范围较小, 难以在室外场景中使用; 双目相机的深度测量范围与基线长度有关, 在室外大尺度场景下进行导航所需

收稿日期: 2019-04-09; 修回日期: 2019-05-10

基金项目: 黑龙江省博士后面上资助(LBH-Z16082)

的相机基线长度过长,导致相机体积与质量显著增加,难以在无人机等小型移动平台上应用。除此之外,这两种相机模型较复杂,在标定、矫正过程中也会带来一些麻烦。

相比之下,单目相机在成本、功耗、质量、标定复杂度等方面都具有非常明显的优势,可以克服以上传感器在无人机等移动平台应用方面的缺点,因此基于单目相机的VO和SLAM算法吸引了更多研究者的目光。然而在传统几何视觉理论中,很难建立较为通用的数学模型实现用单张图像提取出场景的深度信息,这就导致了即使近年来人们的研究工作使单目VO和SLAM算法在精度和鲁棒性上都有了很大的提升,但尺度不确定性的问题仍然没有得到解决,即通过估计出的轨迹及建立的地图只能得知运动及环境的大致形状而实际大小无法确定,这极大的限制了单目VO与SLAM算法在无人机等移动平台导航中的应用。针对这个问题,现有的解决方法多采用在系统中引入其他传感器进行补充,最具代表性的是在系统中加入惯性传感器,得到视觉惯性里程计(Visual Inertial Odometry, VIO),但这类方法不仅增加了系统复杂度,而且为传感器标定带来了更多的麻烦。

近年来深度学习在计算机视觉领域表现出了强大的解析与表达能力,使从单张图像中估计深度成为可能,单目深度估计问题也成为了近年来研究者们关注的热点之一。将单目深度估计加入到单目VO中,作为对缺失尺度的良好补充,在系统不增加额外传感器的前提下,提升系统的性能,在未来有望扩展单目VO的应用范围。本文将单目深度估计加入到半直接法单目VO中,得到了一种可以恢复运动真实尺度的单目视觉里程计算法。

2 研究现状

2.1 单目深度估计

Eigen D等^[1-2]首次提出用卷积神经网络(Convolutional Neural Networks, CNN)解决单目深

度估计问题,采用带有真实深度图的数据集进行有监督训练,从而直接拟合出从单目图像到其对应深度图的映射函数,但此文中所使用的真实深度图实际中很难获取,即使用激光雷达在室外大尺度场景下也难以保证获取完整的深度图。Zhou T等^[3]提出了利用一段由单目相机拍摄的图片序列作为训练集,采用无监督学习的方式进行单目深度估计,但由于单目图像数据集并不包含场景的真实深度信息,因此这种方法只能计算出相对深度,与真实深度仍然相差一个倍数,尺度不确定性问题依然没有得到解决。Godard C等^[4]采用双目相机的图片序列作为数据集,利用左右图像重建损失对网络进行无监督训练,之后由神经网络输出视差图,再利用预测出的视差图计算出深度图。与Zhou T等^[3]的方法不同,本文所采用的双目相机的数据集包含了场景的三维信息,由此训练出的网络输出的视差图进而计算出的深度图为绝对深度,可以用来恢复场景的真实尺度。

2.2 VO/SLAM与单目深度估计的结合

Laina I等^[5]提出了一种包含残差学习网络的全卷积网络结构对单目图像和深度图之间的模糊映射进行建模的方法。该方法经作者改进后融合到单目SLAM技术当中^[6],得到了一种将CNN预测的密集深度图与直接法单目SLAM的深度测量相结合的方法。这种融合方法可以在传统单目SLAM方法容易失效的位置(如缺少纹理特征的区域)进行深度预测,并利用深度预测估计地图重建的绝对尺度,克服了单目SLAM缺少尺度信息的局限性。Li R等^[7]提出了UnDeepVO,一种基于无监督深度学习的单目VO,利用双目图像训练UnDeepVO恢复绝对尺度,用连续的单目图像进行测试,实现了用深度神经网络对单目图像同时进行姿态估计和稠密深度图估计,但这种基于深度学习的方法不可能完全替代基于几何的传统方法,在对未经训练的陌生环境或运动的扩展能力上也会受到限制。

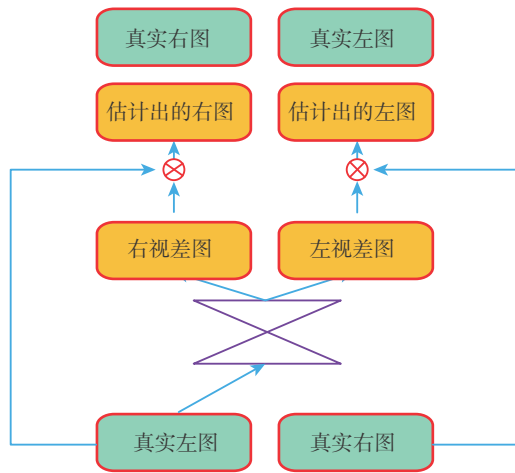


图1 左右图像重建损失

Fig.1 Reconstruction loss between left and right images

(3) 左右一致性损失

在实际情况下，双目相机从左到右的视差与从右到左的视差是完全等价的，CNN 仅接受左图像作为输入并同时预测出左右两幅视差图，为了保证协调，在损失函数中加入对左右视差不一致的惩罚，强迫左视差图等于投影后的右视差图，加入这项较强先验的监督可以有效提高网络对于视差图的预测精度。

$$C_{lr}^l = \frac{1}{N} \sum_{i,j} |d_{ij}^l - d_{ij+d_{ij}^l}^r| \quad (6)$$

3.2 网络结构

考虑到半直接法单目视觉里程计系统的需求，单目深度估计模块的作用是为半直接法 VO 中的深度滤波器提供良好的深度滤波初值，并非将其输出作为最终结果直接用于匹配，因此没必要也不应该盲目追求深度图具有精细的轮廓（部分较难预测的像素点深度误差足够小，如边缘处等），而应该使整张图像上多数像素点的深度预测误差处于合理的范围内，这些点所对应特征点的深度就都可以通过滤波快速收敛到真值，即使存在个别误差较大而不能收敛的异常点，也会在滤波阶段被剔除，不会影响系统的整体性能。

改进后的网络结构如图2所示。在网络的前两层仍然保留了较大的卷积核保持足够大的感受野，保证可以提取到足够丰富的信息支撑后期的深度

预测。随着网络层数逐渐加深，很多细节上的特征被提取出来，但其中很多细节特征对于深度预测的帮助微乎其微，并且提取它们需要大量的计算，对于系统的需求而言，过多地关注它们会造成很大的计算资源浪费。相反，本文把更多的注意力放在较为宏观的特征上，从而保证将整张深度图像每个像素点的预测误差控制在一定范围内。为此，本文对原有的卷积模块进行了修改，引入 1×1 的卷积核，主要目的是降维，其次是将不同的经过卷积处理后得到的特征之间进行融合以形成更加宏观的特征。本文灵感来源于 ResNet^[8] 的降维 Inception 模块，并为改进后的卷积模块取名为 “Inception Conv Block”，同样，在解码器中采取相同技巧改进的模块叫做 “Inception Upconv Block”。改进后的模块被应用在了图中绿色和蓝色所示的位置，通过这种操作实现了用较少的参数提取宏

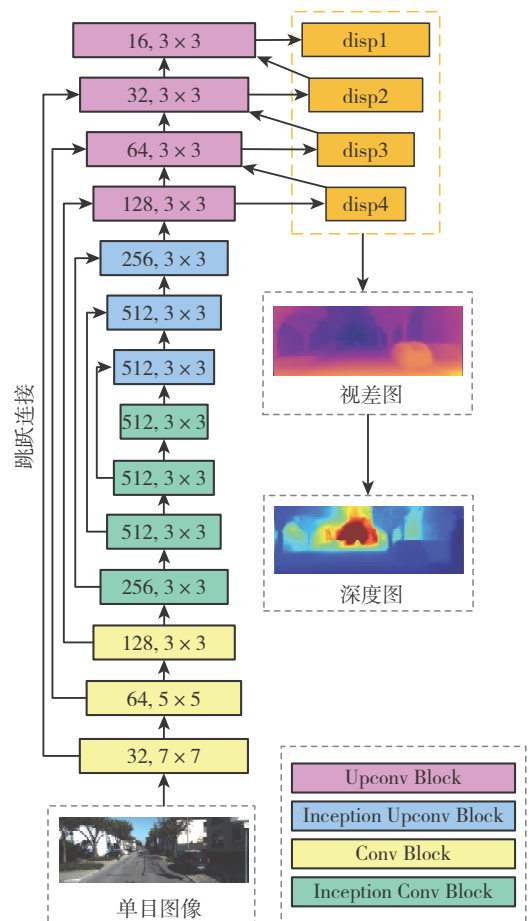


图2 深度估计网络结构

Fig.2 Architecture of depth estimation network

观特征，降低了模型参数量，同时减轻了模型的过拟合程度。

在Inception Conv Block和Inception Upconv Block的具体实现过程中，两次使用了 1×1 的卷积核，目的截然不同。第一次在计算成本较高的 3×3 卷积核之前使用了 1×1 的卷积核实现降维，将中间层特征图的数量减少到输出层特征图数量的 $1/4$ ，同时对不同的特征图实现了信息整合，在经过降维的张量上进行计算量较大的 3×3 卷积操作，有效减少了 3×3 卷积核的数量；第二次使用 1×1 卷积核的目的是对张量进行线性变换将维数调整至与原网络相同。改进后的网络模型包含大约1600万可训练参数，相比原始模型^[4]的3100万减少了一半，在占用内存和运行速度上都有一定优势。

4 VO算法框架

4.1 系统概述

如图3所示，本文的算法框架由两部分组成：一部分是单目深度估计模块，另一部分是半直接法单目VO模块。本文的算法框架建立在开源方案半直接法VO (Semi-direct Visual Odometry, SVO) 的基础上，在建图线程加入了单目深度估计模块，故称为CNN-P-SVO。在运动估计线程中，分别通过最小化光度误差，重投影误差实时优化相机位姿，地图中3D点位置三个步骤来达到恢复相机运动与场景结构的目的。在建图线程中，通过概率贝叶斯滤波的方式估计2D特征点的深度。先对关键帧提取点特征，点特征通过FAST角点^[9]提取；再对被选中的点特征初始化深度滤波器，其中深度初值由单目深度估计模块提供。如果是非关键帧则提供对这些特征点的观测，以贝叶斯滤波的方式更新深度分布模型，当深度滤波器的不确定度足够小时，视为收敛到真实的深度值，则将该点插入地图中，立即用于后续的跟踪线程。

4.2 运动估计线程

运动估计共分为三个步骤：

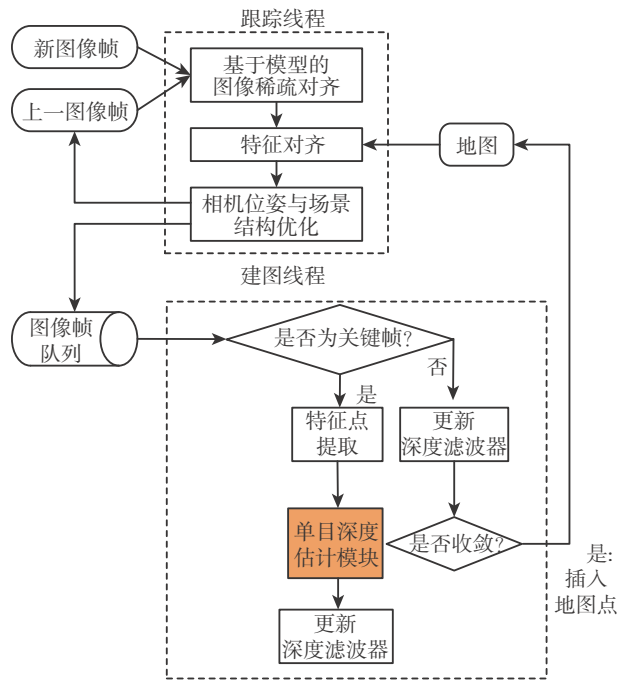


图3 VO算法框架

Fig.3 Framework of VO algorithm

第一步，将当前帧与相邻的上一帧进行基于模型的图像稀疏对齐，首先将上一帧中的像素点根据其位姿以及深度反投影到当前帧中，将投影点的像素值 v 与上一帧反投影前的像素值做比较得到像素光度误差，如式(7)所示，这是一个典型的非线性最小二乘问题，可以通过高斯牛顿等迭代方法求得其最小化时所对应的 $T_{k,k-1}$ ，得到对当前帧位姿的粗略估计，见图4。

$$T_{k,k-1} = \arg \min_{T_{k,k-1}} \frac{1}{2} \sum \|\delta I(T_{k,k-1}, u_i)\|^2 \quad (7)$$

其中， $\delta I(T_{k,k-1}, u_i)$ 为在 $T_{k,k-1}$ 下的像素光度误差。




图4 第一步：基于模型的图像稀疏对齐

Fig.4 First step: sparse model-based image alignment

第二步，先利用上一步估计的位姿变换 $T_{k,k-1}$ 将地图中的特征点投影到当前帧，之后利用光流跟踪进行特征对齐，在光度不变假设下，如式 (8) 所示，同样是通过最小化光度误差的方式优化它们在当前帧上投影的像素位置 (见图 5)。注意此处不是对上一帧中的像素进行操作，而是将关键帧中存储的地图点与当前帧进行特征对齐，可以理解为是在求取地图中的 3D 点在当前帧投影位置的观测值，为下一步构造重投影误差做准备。

$$u'_i = \arg \min \frac{1}{2} \|I_k(u'_i) - A_i \cdot I_r(u_i)\|^2 \quad (8)$$




图5 第二步：特征对齐

Fig.5 Second step: relaxation through feature alignment

前面两步完成后，实现了对特征点快速准确的跟踪，且通过与前面关键帧的匹配关联减小了轨迹的漂移。最后一步，将地图中的点按照第一步估计出的位姿投影到当前帧中，得到一个可视为预测值的像素位置，与上一步中求出的此像素位置的观测值共同构造点线特征的重投影误差，如式 (9) 所示。此处重投影误差的含义是指二者像素位置的差异，并非前两步中像素值的差异，同样通过非线性优化的手段使其达到最小，从而优化当前帧位姿以及对应的地图中的 3D 点坐标，最后引入局部集束约束调整，再次对相机位姿和 3D 点位置进行联合优化，见图 6。

$$T_{k,w} = \arg \min_{T_{k,w}} \frac{1}{2} \sum_i \|u_i - \pi(T_{k,w}, w p_i)\|^2 \quad (9)$$

$$w p_i = \arg \min_{w p_i} \frac{1}{2} \sum_i \|u_i - \pi(T_{k,w}, w p_i)\|^2$$




图6 第三步：相机位姿与场景结构优化

Fig.6 Third step: pose and structure refinement

通过以上三步便可对相机位姿进行比较可靠的估计。

4.3 建图线程

在建图线程中，首先对当前帧的属性进行判断。如果当前帧是关键帧则提取新的特征点，并将其作为种子点放入队列中，再用单目深度估计模块提供的深度值初始化特征点的深度分布。如果当前帧不是关键帧，则利用当前帧 2D 特征与地图中 3D 点的对应关系更新种子点的深度分布。当深度分布的不确定度降低到足够小时，则认为该种子点的深度分布已经收敛，将其插入地图，供跟踪线程使用。

种子点的深度分布以“高斯分布+均匀分布”的叠加进行建模^[10]，使用贝叶斯滤波更新深度。即深度滤波器。在 SVO 的原始算法中，滤波初值被初始化为场景的平均深度，由于该深度初值并不准确，同时赋给深度滤波器一个比较大的不确定度。这会导致三个问题，一是滤波器收敛慢；二是搜索匹配点时耗时；三是由于图像的强非凸性增加误匹配的概率。

为了解决上述问题，将当前关键帧输入单目深度估计模块得到对应的深度图，为深度滤波器提供深度均值的初值，由于该初值相对准确，因此本文赋予其较小的深度不确定度，显著缩小了搜索空间。基于以上情况，加入深度预测模块不

但可以恢复运动的真实尺度，还可以大大加快滤波器的收敛速度，提高深度估计精度。

5 实验

本文用不同数据集的多个场景来测试 CNN-P-SVO 的性能，同时将本文的方法与目前最先进的单目 VO 方法对比，包括 SVO^[11]、DSO^[12]、去掉回环检测的单目 ORB-SLAM^[13]。其中，SVO 在这些场景中均失效，因这两种方法的深度滤波器都是用当前场景深度均值初始化，不适用于深度变化比较大的室外场景，故在后面的结果对比中不再展示。轨迹精度采用常见的绝对轨迹误差 (Absolute Trajectory Error, ATE) 进行度量，即计算估计位姿与真实位姿之间的欧氏距离的均方根误差 (Root Mean Square Error, RMSE)。由于参与对比评价的算法都是单目 VO 方法，需要先进行相似变换对齐轨迹才能计算误差。

整个实验中使用的计算平台配置如下：Intel Core i7-6820 CPU 2.70GHz；16GB RAM；NVIDIA Quadro M2000M GPU。所有视觉里程计算法均在此平台下运行。选取数据集双目图像对中的左图像作为输入，由于所有参与比较的算法都存在一些不确定性，因此每个实验都重复做 5 次并且记录其中位数作为最终结果。

5.1 轨迹精度评估

本文提出的算法首先在常用的数据集 KITTI 上进行了评估，这个数据集包含了城市、乡村、高速公路等多种场景。由于制作数据集时相机的帧率较低 (10FPS)，相机载体运动速度较快以及图像中出现了较多运动的汽车与行人，使这个数据集对于单目 VO 来说是一个很大的挑战。

表 1 比较了不同算法测试所得的性能，结果表明，加入单目深度估计模块后，本文提出的 CNN-P-SVO 算法在精度指标上明显优于其他算法。表 1 还展示了不同算法在 KITTI sequence 00 和 05 上运行

后得到的轨迹以及真实轨迹之间的对比。所有的算法在 sequence 01 上都运行失败，这是由于场景中存在的大量自相似特征进而产生了大量坏点。

表1 KITTI数据集上不同算法的平均绝对轨迹误差对比

Table 1 Comparison of localization accuracy on KITTI dataset

序列编号	CNN-P-SVO	ORB-SLAM	DSO
00	11.617	79.047	106.589
01	—	—	—
02	19.851	28.284	122.173
03	2.546	1.067	11.837
04	0.738	0.844	1.603
05	6.236	41.372	45.456
06	7.113	56.888	114.159
07	3.650	17.967	35.049
08	10.541	50.528	97.305
09	10.311	39.930	68.126
10	3.021	9.237	13.624

注：表中所有数据单位均为m。

从图 7 中可以看出，结合单目深度估计的 CNN-P-SVO 算法对真实轨迹跟踪效果好。而去掉回环检测的 ORB-SLAM 算法及 DSO 算法在轨迹对齐后出现了明显的漂移。

5.2 尺度精度评估

本文的主要工作是解决长久以来单目 VO 的尺度不确定问题，之前的研究从理论的角度解释了引入单目深度估计模块克服尺度缺失的可行性，实验结果证明所提出的算法可以解决此问题。本文将参与比较的每组 VO 的运行结果通过相似变换与真实轨迹对齐，这一过程中计算出的运行轨迹与真实轨迹间的尺度差距展示在表 2 中，CNN-P-SVO 算法尺度非常接近 1，即非常接近真实轨迹，这表明它具有理想的尺度，这是由单目深度估计模块提供的强先验信息带来的结果，因此本文提出的算法很好地解决了传统单目 VO 尺度不确定问题。

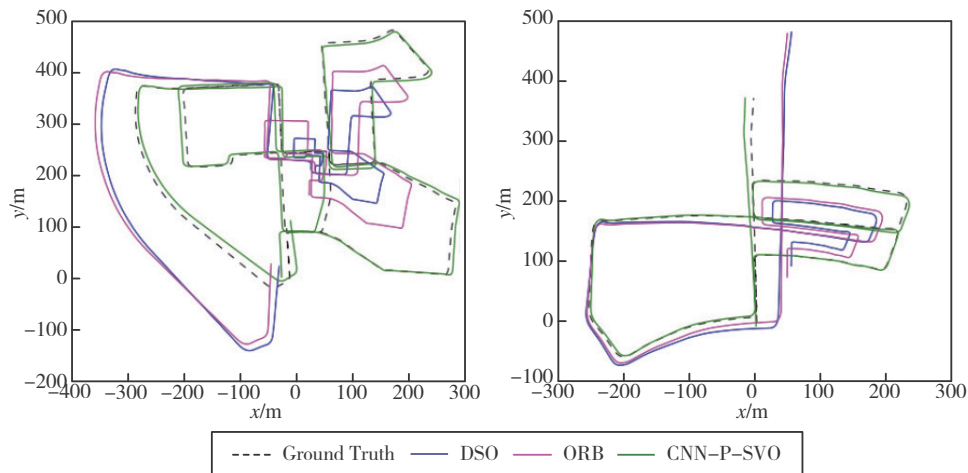


图7 不同方法在KITTI sequence 00和05上运行得到的轨迹与真实轨迹之间的对比
Fig.7 The estimated trajectories using different VO algorithms on KITTI Sequence 00, 05

表2 不同方法在KITTI数据集上运行得到轨迹与真实轨迹之间尺度差异对比

Table 2 Comparison of scale estimation on KITTI dataset

序列编号	CNN-P-SVO	ORB-SLAM	DSO
00	1.067	5.392	3.224
01	—	—	—
02	1.053	17.345	13.499
03	1.053	10.328	21.680
04	1.111	26.758	38.419
05	1.052	10.073	8.997
06	1.082	10.634	10.512
07	1.036	6.102	14.535
08	1.034	9.572	7.267
09	1.041	15.995	9.818
10	1.055	15.270	21.658

注：表中所有数据单位均为m。

6 结论

本文对单目深度估计以及半直接法VO进行了研究，并将二者有机结合，提出了一种基于单目深度估计的VO算法，主要完成了以下研究工作：

(1) 使用基于图像重建的无监督学习算法从单张图像中提取深度信息，将难以显式建模的单张图像与其深度图之间的映射函数用神经网络学习

来近似。训练过程中使用双目图像，包含场景三维信息，因此在使用模型时，仅输入单张图像就可以获取场景的绝对深度，克服了传统深度传感器在成本、质量和功耗上的限制。之后针对本文VO系统的需求，对深度估计算法进行调整，使其更好地融入到系统之中。

(2) 针对现有单目VO算法尺度不确定性的缺点，结合半直接法VO建图线程中的深度滤波器模块，用单目深度估计模块输出像素深度为深度滤波器提供滤波初值，再根据观测更新滤波器直到收敛，从而补偿深度估计的误差，一方面解决了单目VO尺度不确定的固有缺点，另一方面加快滤波器收敛，提高了系统的鲁棒性。

(3) 将提出的算法在公开的数据集上进行了测试，并与目前最先进的单目VO算法在轨迹误差、尺度等指标上分别进行了对比，证明了所提出的算法对于解决尺度缺失问题是有效的，并且在精度上也远远优于其他单目算法。

参考文献

- [1] Eigen D, Puhrsch C, Fergus R. Depth map prediction from a single image using a multi-scale deep net-work [C]. International Conference on Neural Information Processing Systems. 2014.

- [2] Eigen D, Fergus R. Predicting depth, surface normals and semantic labels with a common multi-scale convolutional architecture [C] . The 15th International Conference on Computer Vision, Santiago, Chile, 2015.
- [3] Zhou T, Brown M, Snavely N, et al. Unsupervised learning of depth and ego-motion from video [C] . The 30th IEEE Conference on Computer Vision and Pattern Recognition, Hawaii, USA, July 22–25, 2017.
- [4] Godard C, Mac A O, Brostow G J. Unsupervised monocular depth estimation with left-right consistency [C] . The 29th IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, June 19–21, 2016.
- [5] Laina I, Rupprecht C, Belagiannis V, et al. Deeper depth prediction with fully convolutional residual networks [C] . The 4th International Conference on 3D Vision, CA, USA, October 25–28, 2016.
- [6] Tateno K, Tombari F, Laina I, et al. CNN-SLAM: Real-time dense monocular SLAM with learned depth prediction [C] . The 30th IEEE Conference on Computer Vision and Pattern Recognition, Hawaii, USA, July 22–25, 2017.
- [7] Li R, Wang S, Long Z, et al. Undeepvo: Monocular visual odometry through unsupervised deep learning [C] . 2018 IEEE International Conference on Robotics and Automation, Brisbane, Australia, May 21–26, 2018.
- [8] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions [C] . The 28th IEEE Conference on Computer Vision and Pattern Recognition, Boston, USA, June 8–10, 2015.
- [9] Forster C, Pizzoli M, Scaramuzza D. SVO: Fast semi-direct monocular visual odometry [C] . 2014 IEEE international conference on robotics and automation, Hong Kong, China, May 31–June 5, 2014.
- [10] Vogiatzis G, Hernández C. Video-based, real-time multi-view stereo [J] . Image and Vision Computing, 2011, 29 (7): 434–441.
- [11] Rosten E, Porter R, Drummond T. Faster and better: A machine learning approach to corner detection [J] . IEEE transactions on pattern analysis and machine intelligence, 2008, 32 (1) : 105–119.
- [12] Vogiatzis G, Hernández C. Video-based, real-time multi-view stereo [J] . Image and Vision Computing, 2011, 29 (7): 434–441.
- [13] Engel J, Koltun V, Cremers D. Direct sparse odometry [J] . IEEE transactions on pattern analysis and machine intelligence, 2017, 40 (3) : 611–625.
- [14] Mur-Artal R, Montiel J M M, Tardos J D. ORB-SLAM: a versatile and accurate monocular SLAM system [J] . IEEE transactions on robotics, 2015, 31 (5) : 1147–1163.

作者简介:

郭爽(1997-), 男, 硕士研究生, 主要研究方向为视觉感知、单目深度估计。

无人行星车自适应协同探测方法

罗汝斌¹, 颜 鹏²

(1. 北京宇航系统工程研究所, 北京 100076; 2. 哈尔滨工业大学, 哈尔滨 150001)

摘要: 无人行星车通过对地外天体的探测, 对人类开发利用空间资源具有重要的意义。提出一种无人行星车自适应协同探测方法, 赋予行星车自学习能力。首先将探测环境进行栅格化处理; 然后使用卷积神经网络处理探测环境信息以及激光雷达数据, 提取环境特征; 接着使用强化学习方法学习探测环境的策略, 在学习过程中, 对奖励函数进行了详细设计, 使行星车可以快速无碰撞的探测给定区域, 同时, 行星车之间可以共享探测信息, 加速学习的过程; 最后在Gazebo软件中进行了仿真实验, 由实验结果可知, 行星车具有一定的协同能力, 可以快速有效的探测给定的区域。

关键词: 行星车; 协同探测方法; 自学习; 深度强化学习; Gazebo仿真环境; 卷积神经网络

中图分类号: V11 **文献标识码:** A **文章编号:** 2096-5915 (2019) 03-0483-06

Adaptive Cooperative Detection Method for Unmanned Planetary Vehicle

LUO Rubin¹, YAN Peng²

(1. Institute of Aerospace Systems Engineering, Beijing 100076, China;

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

Abstract: Unmanned planetary vehicle have important significance for human development and utilization of space resources through the detection of extraterrestrial objects. This paper proposes an adaptive cooperative detection method for unmanned planetary vehicles, which endows the planet vehicles with self-learning ability. First, the detection environment is rasterized; then, the convolutional neural network is used to process the detection environment information and the lidar data to extract the environmental features; the reinforcement learning method is used to learn the strategy of detecting the environment. During the learning process, the reward function was designed in detail so that the planetary vehicle can detect a given area quickly and without collision. At the same time, the detection information can be shared between planetary vehicles to accelerate the learning process. Finally, simulation experiments were carried out in Gazebo. The experimental results show that the planetary vehicle has a certain synergistic ability and can detect the given area quickly and effectively.

Keywords: Planetary Vehicle; Cooperative Detection Method; Self-Learning; Deep Reinforcement Learning; Gazebo Simulation Environment; Convolutional Neural Network

收稿日期: 2019-04-29; 修回日期: 2019-05-21

基金项目: 国家自然科学基金 (51705109)

1 引言

随着科技的进步，人类对未知空间的探索逐步增加，目前已经发射了大量的星际探测器，对太阳系内的行星进行了探索。行星车通过对地外天体的直接探测，探索气候及地质特征，搜索生命信号，对人类研究行星生命演化、开发和利用空间资源具有重要的科学意义^[1]。在探测复杂未知的行星环境过程中，行星车需要具备自主感知行星环境、规划路径的能力，以保障成功执行任务。作为行星车自主能力中的一项关键技术，行星车自主导航方法已有广泛的研究^[2-3]。在大量的研究基础上，单个行星车已经可以执行一些简单的任务，但由于行星环境的复杂性，单个行星车所能执行的任务有限，在极端情况下很有可能由于意外故障而导致任务执行失败。多行星车协同工作可以共享探测信息，迅速提升对未知非结构化行星表面环境的认知，扩大行星车的探测范围、探测速度以及探测能力，提高执行任务的成功率。现有的多车协同方法，如Leader-Follower^[4]、虚拟结构体法^[5]、基于行为的方法^[6]等不具备自学习能力，不能在未知环境中动态调整自身的策略，从而不适用于行星探测这种不确定性极高的任务。本文提出基于深度强化学习方法^[7]的行星车协同探测方法，使行星车具备自学习的能力，可以根据不同的环境调整自身的策略；同时，通过行星车之间的信息共享，加速学习过程。

2 问题

本文研究两个行星车协同探测未知环境的问题。给定一片未知区域 E ，两个行星车 $c_i(i=1,2)$ ，要求在最短的时间 t 内探测完未知区域 E 。行星车配备激光雷达和视觉相机两种探测传感器，对行星环境进行探测。环境中具有不确定的障碍 $O_i(i=1,2,\dots,n)$ ，行星车通过激光雷达感知障碍，避免与障碍物相碰，通过视觉相机拍摄照片进行探测。同时，两个行星车之间为了保持通信，其

间距 d 必须在一定通信范围 d_{\max} 内。小车的探测范围可简化为一个扇形区域，由探测半径 r_{det} 和角度 θ_{det} 表示。该问题可由下式表示：

$$\begin{aligned} \min \quad & t \\ \text{s.t.} \quad & (E_i^1 \cup E_i^2) \geq E \\ & P_i \notin O_j (i=1,2; j=1,2,\dots,n) \\ & d < d_{\max} \end{aligned} \quad (1)$$

其中， E_i^1 和 E_i^2 分别表示两个小车在时间 t 内已经探测的区域， P_i 表示第 i 个小车的位置。

两个行星车协同探测未知环境的问题如图1所示：




图1 两个行星车探测未知环境

Fig.1 Two planetary vehicles detect unknown environment

其中，蓝色区域为待探测区域，红色区域为随机分布的障碍，绿色扇形区域为小车的探测能力范围。

3 自学习协同探测方法

本文使用Deep Q-network (DQN)^[8]使两个行星车具备协同探测未知环境的能力。DQN结合强化学习方法的自学习能力和深度神经网络的特征提取能力，在很多任务上具有和人类相当的能力，相比于其他深度强化学习算法，DQN可以在线学习，根据环境实时调整自身策略，适用于行星车探测未知环境的任务。

3.1 探测区域的表示方法

我们将行星车探测的区域进行栅格化处理，如图2所示：

车需要探测的区域为一个 $10\text{m} \times 10\text{m}$ 的矩形区域，其中随机分布着障碍物。行星车通过激光雷达感知障碍物，使用视觉相机获取环境信息，完成探测任务。




图6 仿真环境

Fig.6 Simulation environment

4.2 训练过程

在上述仿真环境中对行星车所使用的深度神经网络进行训练。在训练过程中，相关参数取值见表1。

表1 仿真参数

Table 1 Simulation parameters

参数	取值	单位
最大通信距离 d_{\max}	5	m
探测半径 r_{det}	3	m
探测角度 θ_{det}	60	(°)
栅格个数 K	100	个

训练过程进行了5000个训练周期，每一个训练周期开始之前将障碍物和两个行星车的位置随机重置，一个周期最大的训练步数为500步。一个训练周期的停止条件为达到最大训练步数或探测覆盖率超过0.85。图7为训练过程中的奖励函数变化情况，其中显示曲线是每50个相邻训练周期奖励值的平均值与方差。由奖励变化曲线可以看出，在训练1000次之后，奖励值基本稳定，表明网络已经收敛。

4.3 结果分析

对4.2节中训练好的深度神经网络进行10次随

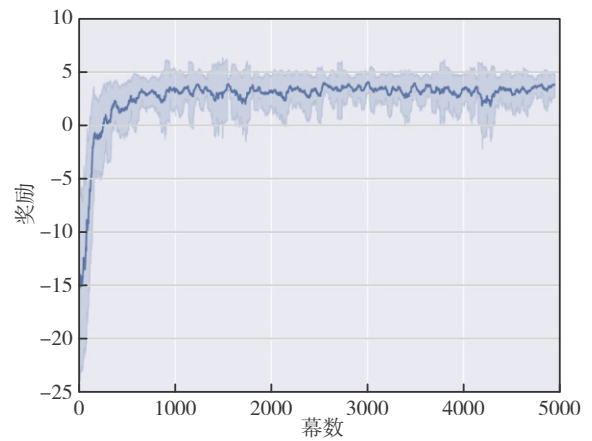


图7 训练过程奖励变化曲线

Fig.7 Training process reward curve

机测试，结果如表2所示。

表2 仿真结果

Table 2 Simulation results

实验编号	探测时间 /s	探测覆盖率	累计奖励
1	44.1	0.86	4.3
2	50.3	0.87	3.8
3	60.1	0.86	3.2
4	35.6	0.87	5.1
5	47.8	0.86	4.0
6	44.9	0.87	4.2
7	55.1	0.87	3.6
8	45.2	0.87	4.1
9	48.1	0.88	3.9
10	39.7	0.87	4.8
平均值	47.1	0.87	4.1

由表2可知，在10次随机测试中，行星车都可以完成探测任务，因行星车的初始位置和障碍物的位置都是随机设置，所以探测时间随环境而异。仿真实验测试设定探测率超过0.85就算完成探测任务，因此10次随机测试中的探测率都在0.85以上。同样可得，探测时间越长，奖励值越小，这与设定的奖励函数一致。10次测试中的某次探测过程如图8所示。

图8为行星车利用训练好的深度神经网络进行一次区域探测的结果，绿色为已探测区域，红色区域为障碍物，蓝色和黑色实线为行星车轨迹。由图8可知，两个行星车在探测过程中，各自所探测的区域交集不大，大部分区域都是各自独立探

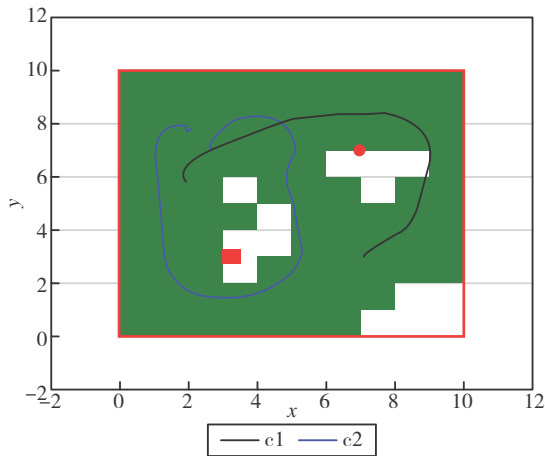


图8 区域覆盖结果

Fig.8 Regional coverage result

测的，这体现了行星车探测过程的协同行为，这种协同行为可以增加区域探测的效率。

5 结论

本文针对行星车探测未知区域问题，提出了一种基于深度强化学习方法的自适应协同探测方法。其中，行星车搭载激光雷达与视觉相机对未知区域进行探测，激光雷达传感器感知环境中的障碍物，实现自主避障；视觉传感器进行图片采集，实现区域探测。在协同探测过程中，将探测区域进行栅格化处理，方便探测区域的表示以及探测覆盖率的计算。为了提取环境特征，采用卷积神经网络处理激光雷达数据与探测区域地图信息。为了保持行星车之间的有效协同以及信息共享，行星车之间的距离被限制在一定的范围内。在Gazebo软件中搭建了仿真环境，进行了深度神经网络的训练与测试，由仿真结果表明，该算法可使行星车快速的探测完给定的区域并避开环境中的障碍物。

参考文献

[1] 郭延宁, 冯振, 马广富, 等. 行星车视觉导航与自主控制进展与展望 [J]. 宇航学报. 2018, 39(11): 1185-

1196.
 [2] Zhang J, Xia Y, Shen G. A novel learning-based global path planning algorithm for planetary rovers [J]. arXiv preprint arXiv:1811.10437. 2018.
 [3] Wong C, Yang E, Yan X, et al. Adaptive and intelligent navigation of autonomous planetary rovers—A survey [C]. NASA/ESA Conference on Adaptive Hardware and Systems (AHS), 2017.
 [4] Consolini L, Morbidi F, Prattichizzo D, et al. Leader-follower formation control of nonholonomic mobile robots with input constraints [J]. Automatica. 2008, 44 (5) : 1343-1349.
 [5] Roy D, Chowdhury A, Maitra M, et al. Multi-robot virtual structure switching and formation changing strategy in an unknown occluded environment [C]. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2018.
 [6] Lee G, Chwa D. Decentralized behavior-based formation control of multiple robots considering obstacle avoidance [J]. Intelligent Service Robotics. 2018, 11 (1) : 127-138.
 [7] Tai L, Zhang J, Liu M, et al. A Survey of deep network solutions for learning control in robotics: from reinforcement to imitation [J]. arXiv preprint arXiv:1612.07139. 2016.
 [8] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning [J]. Nature. 2015, 518 (7540) : 529.
 [9] Razavian A S, Azizpour H, Sullivan J, et al. CNN features off-the-shelf: an astounding baseline for recognition [C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2014.
 [10] Hinton G E. Rectified linear units improve restricted boltzmann machines vinod nair [C]. International Conference on International Conference on Machine Learning, 2010.

作者简介:

罗汝斌(1981-), 男, 硕士, 高级工程师, 主要研究方向为飞行器制导控制技术。

颜鹏(1996-), 男, 博士研究生, 主要研究方向为空间机器人自主决策技术。

有限推力空间飞行器自主避障研究

赵 毓

(哈尔滨工业大学航天学院, 哈尔滨 150001)

摘 要: 基于对飞行器小范围快速变轨机动方法的分析, 针对有限推力飞行器在轨自主避障过程中机动时机决策和推力方向控制问题进行研究, 提出了一种在线自主决策有限推力避障规划方法。其中, 基于强化学习理论, 揭示了轨道飞行器避障过程中机动时机与运动状态的变化规律, 建立了“线下学习, 线上决策”的空间飞行器自主避障决策训练模型。对影响轨道机动的典型参数进行研究, 构建了以时间为奖励函数参量的强化学习评价机制, 实现了能量最优的小范围轨道机动规划。与传统高斯伪谱法有限推力轨迹规划对比分析表明, 提出的自主避障机动决策方法在求解速度和运算性能上更优。

关键词: 空间飞行器; 有限推力; 自主避障; 强化学习; 自主决策; 能量最优

中图分类号: V474.2 **文献标识码:** A **文章编号:** 2096-5915 (2019) 03-0489-06

Research on Autonomous Obstacle Avoidance method of Finite-Thrust Spacecraft

ZHAO Yu

(School of Astronautics, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Based on the analysis of the maneuvering method of rapid orbit maneuver in small range for spacecraft, the maneuvering timing decision and thrust direction control of a limited thrust vehicle during autonomous obstacle avoidance in orbit are studied. An on-line autonomous decision-making method for obstacle avoidance planning with limited thrust is proposed. Based on reinforcement learning theory, the change rule of maneuvering opportunity and motion state of orbiting vehicle during obstacle avoidance is revealed. An autonomous obstacle avoidance decision-making training model of space vehicle is established, which is based on ‘offline learning and online decision-making’ frame. Study on typical parameters of orbital maneuver, the evaluation mechanism of reinforcement learning based on time as reward function parameter is constructed. Small range orbital maneuver planning with optimal energy method is founded. Comparison and analysis the finite thrust trajectory planning with traditional Gauss pseudospectral method, the method of autonomous obstacle avoidance maneuvering decision-making presented in this paper is better in solving speed and operation performance.

Keywords: Spacecraft; Finite-Thrust; Autonomous Obstacle Avoidance; Reinforcement Learning; Autonomous Decision-Making; Energy Optimization

收稿日期: 2019-04-12; 修回日期: 2019-05-17

基金项目: 上海航天科技创新基金 (SAST2016039)

1 引言

随着人类对空间环境的探索和开发,空间碎片的数量快速增长,对在轨运行的空间飞行器危害日益增长^[1]。轨道机动避障技术是空间在轨服务等关键技术开展的基础^[2],以美国为首的各航天大国均已进行了多项研究^[3-5],相关研究计划包括美国国家航空航天局(NASA)的LEGEND^[6]、法国的MEDEE^[7]等。国内钱宇等^[8-9]对轨道规避进行了研究,构造了规避体系和基础框架,但并未给出详细的控制决策算法。晋小伟给出了基于轨道根数的有限推力轨道动力学模型,并结合空间飞行器姿态控制对有限推力轨道机动进行仿真分析,利用高斯伪谱法对有限推力轨道规划问题离散化获得能量最优解^[10]。苏飞等^[11]对轨道面内规避机动进行了最优脉冲分析。上述学者的研究分别在空间避障和有限推力轨道转移方向取得了一定成果,但传统高斯伪谱法求解速度无法满足飞行器在轨实时避障决策需求,工程上也很难为空间飞行器提供瞬时大推力,所以有必要对有限推力空间飞行器在轨实时避障机动决策进行研究。

本文针对有限推力避障场景建立了J2000地心惯性坐标系下轨道动力学模型,在此基础上将新兴自学习神经网络技术与有限推力轨道快速机动技术相结合^[12-13],使空间飞行器在轨运行期间具备自主避障能力。区别于传统离线轨道机动规划技术^[14-15],本文应用强化学习理论设计了一种针对空间飞行器避障机动问题的自学习仿真架构,通过离线神经网络训练实现航天器有限推力变轨时机在线自主决策能力,轨迹规划结果相近情况下,规划时间比传统高斯伪谱法更优。该自学习仿真架构中以地心惯性系有限推力轨道转移动力学为基础,建立了以轨道转移时间为训练回报函数参数的评价机制。通过仿真给出特定约束条件下空间飞行器能量最优有限推力轨道转移避障机动方法,仿真结果与传统高斯伪谱法离线轨迹优化所得结果进行对比,可得本文所述算法得到的轨迹规划时间更短,轨道转移机动耗时、耗能较优。

2 地惯系轨道动力学模型建立

传统的空间飞行器轨道问题研究,动力学方程通常是在发射系或轨道系中给出。此类动力学方程参数可以方便地与空间飞行器本体坐标系转换,从而便于对制导控制系统进行简化。本文所研究空间避障问题的障碍物可以是非合作目标,其相关参数需要通过遥测等方法给出,不宜使用上述坐标系对其进行描述。针对空间交会问题的C-W方程既未考虑摄动影响,又存在运算资源消耗大的问题,亦不适于本文对在轨实时决策的研究。所以,本文建立了基于J2000地心惯性坐标系的空间飞行器、障碍物轨道动力学方程,该方法可以直接使用空间位置和速度来描述空间物体在轨状态,可以更为直观和简便的在自学习系统中进行运算,进而提高系统的解算速度。

在地球引力与发动机推力,以及地球引力摄动、日月引力摄动和大气阻力摄动作用下,航天器对地心的相对运动方程一般矢量形式为:

$$\ddot{\mathbf{r}} = -\frac{\mu}{r^3}\mathbf{r} + \frac{T}{m}\mathbf{u} + \mathbf{f}_p \quad (1)$$

其中, \mathbf{r} 是航天器空间位置矢量; μ 为地球引力常数,其值为 $3.986 \times 10^5 \text{ km}^3/\text{s}^2$; T 为发动机推力大小; m 是航天器瞬时质量; \mathbf{u} 为发动机推力方向单位矢量; \mathbf{f}_p 是作用在航天器上的摄动加速度矢量。由此航天器在地心惯性坐标系中的运动可以描述为:

$$\begin{cases} \dot{v}_x = \frac{\mu x}{(x^2 + y^2 + z^2)^{\frac{3}{2}}} + \frac{T}{m}u_x + f_{px} \\ \dot{v}_y = \frac{\mu y}{(x^2 + y^2 + z^2)^{\frac{3}{2}}} + \frac{T}{m}u_y + f_{py} \\ \dot{v}_z = \frac{\mu z}{(x^2 + y^2 + z^2)^{\frac{3}{2}}} + \frac{T}{m}u_z + f_{pz} \end{cases} \quad (2)$$

其中, x, y, z 分别为航天器位置矢量沿J2000坐标系坐标轴的分量; v_x, v_y, v_z 分别为航天器速度矢量沿三维坐标轴的分量; u_x, u_y, u_z 分别为推力方向单位矢量沿J2000坐标轴的分量; T 在前文中已给出; f_{px}, f_{py}, f_{pz} 为摄动加速度沿三维坐标轴的分量,为本文轨道机动控制方法主要控制量。

本文所用推力模型为 $0.01 \leq T/m_0 < 2$ 。该模型为空间飞行器推力模型中普适性最高的模型，发动机推力较小且作用时间较长。对于常值比冲发动机，其质量变化率表示为：

$$\dot{m} = -\frac{T}{V_e} = -\frac{T}{I_{sp} g_0} \quad (3)$$

其中， T 与前文定义相同； V_e 为发动机排气速度； I_{sp} 为发动机比冲； g_0 为海平面处地球重力加速度，本文所采用发动机均为常比冲发动机。

3 自学习架构设计

3.1 自学习机理分析

如前文所述，诸多学者对空间飞行器有限推力轨迹规划问题进行了详细的研究，但其研究方法多是基于数值分析和力学推演等形式。此类方法如果更换问题条件或初始状态变化过大，就需重新进行数学推导和设计，对实际工程问题的适应性较差。本文采用基于神经网络的强化学习架构对自主避障决策训练系统进行设计，可以很大程度上弥补传统方法适应性不足的问题。

考虑到空间环境中飞行器和障碍物可移动范围较大导致变量连续取值范围过大的情况，传统强化学习方法是基于环境交互试错的形式，容易产生运算量指数极限上升。且传统强化学习方法泛化性能差，实际工程应用中不能仅使用有限离散求解问题，易产生组合爆炸。所以本文对自主避障问题的强化学习框架进行了修改和优化，使其具备解决空间有限推力决策问题的泛化能力。

自学习系统的目标是通过模拟训练和学习初始参数与避障参数之间的变化关系，对有限推力避障参数进行Q值评价，从而取得优化的避障机动能力。在空间有限推力轨迹规划问题中可供分析使用的参量较多，避障场景又引入障碍物相关参数，不利于在线实时运算。为了决策系统具备泛化能力，本文选取飞行器和空间障碍物在惯性系下各三自由度位置、速度参数做为强化学习神经网络系统的输入参数，共计12个输入节点，并在

运算过程中采取参数归一化的方法。

神经网络针对非线性问题有强大的逼近功能，本文使用多层误差反向传播神经网络对避障决策问题进行研究。设计了一种包含两个隐层的神经网络结构，输入变量是十二维的，输出变量是三维的，输出变量分别对应于机动起始时刻、总机动时间和飞行器与障碍物间最短距离。利用神经网络的泛化功能，可以使强化学习环境状态和动作取得连续值。

3.2 Q值与案例结合的强化学习方法

本文采用了Q学习与案例学习相结合的方法实现航天器对避障环境进行变轨机动学习。学习系统结构如图1所示。




图1 学习系统的结构

Fig.1 The structure of self-learning system

航天器决策系统学习的结果以案例形式保存在案例库中，使得航天器与环境交互时的经验能够有效利用；同时相关案例反过来指导航天器对新场景继续学习。案例库随着学习的进行得到动态更新，确保学习是以增量的方式进行。通过预置先验案例（非最优）也可以避免航天器在与环境交互时产生错误行为。

神经网络的学习和Q值学习是同步进行的，且存在交互。首先使用评价函数算法更新Q值，使神经网络能够逼近最优的Q函数。同时用神经网络算法更新网络权值以逼近问题最优解。只要Q函数没达到阈值范围，两个学习过程就会不断更新网络权值达到学习的目的。Q学习提供神经网络所需的参考值，神经网络学习过程不断逼近Q函数，使Q函数提供的参考值更加接近最优。

结合案例库进行Q值强化学习，强化学习过程中部分使用当前的生成案例，部分基于过去的案

例。一旦算法探索到最优目标状态奖励空间，案例库中就会形成一致性很好的学习案例集。案例库更新原理如图2所示。




图2 案例库更新规则示意图
Fig.2 Diagram of case base updating rules

3.3 自学习仿真系统设计

前文中已简要给出自学习系统中神经网络结构参数，下面将对仿真系统中其他环节进行分析设计。仿真系统流程示意图如图3所示。

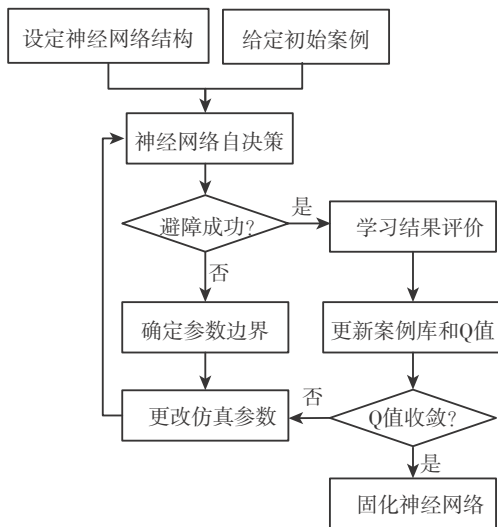


图3 自学习系统的运行流程示意图
Fig.3 Diagram of self-learning system operation process

本文采用误差反馈神经网络做有限推力避障自决策网络。该网络有四层节点，输入层为12个节点，第一隐层为15个节点，第二隐层为6个节点，输出层为3个节点。输入层和输出层参数物理

意义已在前文给出。

学习结果评价Q值函数如下：

$$Q = t_{off} + \frac{1}{T_{st}} + \frac{1}{P_{dt}} \quad (4)$$

其中， T_{st} 为初始有限推力机动时刻， t_{off} 为机动总耗时， P_{dt} 为机动过程中飞行器与障碍物距离评价价值。仿真开始时，可根据飞行器集合外形设定 P_{dt} 参数的评价区间，飞行器与障碍物的距离过近或过远都将影响该值。因此，所得评价Q值越小的方案性能越优。

为了提高系统的训练速度，设定在一系列案例学习过程中，当Q值满足特定阈值范围时即终止学习过程，此时认为神经网络决策系统已经训练成型。随后将训练成型的神经网络进行固化操作，使用其对特定场景进行有限推力避障决策，并与传统有限推力规划方法进行比较分析。

在自学习系统训练过程中，更改仿真参数是以增量规则进行的。同一组输入参数可以被多次训练，但不应超过限定次数，否则会过多占用学习资源。本文将同一输入最大出现次数设定为1000次，该次数可根据飞行器与障碍物交会时间近似确定。自学习系统对某一组参数训练达到Q值阈值或最大次数时，将不再对此组参数进行学习，改变输入条件将会进行新的仿真学习。

4 仿真及结果分析

利用文中所述自学习系统对特定场景空间飞行器有限推力自主避障问题进行仿真研究。空间飞行器初始时刻的质量为450kg，其中主推进剂质量为50kg，发动机推力为400N。为了简化计算，设定理想化空间飞行器和障碍物的初始轨道参数参见表1。

表1 飞行器和障碍物初始轨道参数表

Table 1 Initial orbital parameters table for aircraft and obstacles

	半长轴 / km	偏心率	轨道倾角 / °	近地点幅角 / °	升交点赤经 / °
飞行器	6878.14	0.02	20.0	0	60.0
碎片	6878.14	0.02	160.0	0	240.0

初始时刻飞行器和障碍物的位置、速度参数参见表2。

表2 飞行器和障碍物初始位置速度参数

Table 2 Initial position and velocity parameters of aircraft and obstacles

	x /km	y /km	z /km	V_x / ($\text{km} \cdot \text{s}^{-1}$)	V_y / ($\text{km} \cdot \text{s}^{-1}$)	V_z / ($\text{km} \cdot \text{s}^{-1}$)
飞行器	-5333.62	3633.75	2342.48	-4.35	-6.25	0.23
碎片	-5813.73	2802.17	2342.48	3.24	6.89	0.23

有限推力避障机动时间取值范围为初始时刻到无机动飞行器与障碍物碰撞时刻之间，本算例中近似 100 s。在轨迹动力学推演过程中，取仿真步长为 0.1 s。

自学习系统相关参数已在 3.3 节中给出。

应用本文所述方法对上述空间飞行器避障机动方法进行轨迹设计。神经网络训练状态如图 4 所示。




图4 神经网络训练状态

Fig.4 Training state of neural network

得到飞行器轨迹仿真结果如图 5 和图 6 所示。




图5 有限推力轨道机动图

Fig.5 Diagram of orbital maneuver with finite-thrust




图6 飞行器与障碍物距离图

Fig.6 Distance between spacecraft and obstacles

由图 5、图 6 可知，应用本文所述方法可以有效地解决有限推力空间飞行器避障问题。为了对比分析，又使用传统高斯伪谱法对本仿真算例进行推导计算。通过高斯伪谱法规划所得转移轨迹中施加推力所耗时间为 63.244 s，规划过程计算耗时约为 4.4 s；通过本文所述强化学习神经网络决策系统进行转移轨迹规划，所得轨迹中施加推力时间为 63.2 s，决策过程耗时约为 0.42 s。由此可见本文所述方法相比高斯伪谱法所得转移时间更短，轨迹规划计算过程耗时更短，且占用较少计算资源。可用于飞行器在线自主避障机动，能够得到较优结果。

5 结论

本文针对有限推力空间飞行器自主避障问题，根据自学习框架需求，推导了地心惯性坐标系下空间飞行器动力学方程。然后设计了基于 Q 值与案例学习的强化学习仿真框架，并根据给定案例进行了数值仿真，通过与传统方法的对比分析，证实了本决策仿真系统的正确性和有效性。得出了以下主要结论：

(1) 本文在传统轨迹规划方法的基础上，为有限推力空间飞行器的避障机动问题提供了新的求

解方法;

(2)应用本文方法可以快速对有限推力避障轨迹进行规划和处理,相比传统高斯伪谱法规划耗时更短,求得能耗与高斯伪谱法近似;

(3)本方法计算量更小,通过训练形成的神经网络可以提供实时轨迹规划能力。

参 考 文 献

- [1] 张海涛,张占月,吴帅,等.地球静止轨道卫星碰撞碎片短期演化风险分析[J].上海航天,2019,36(1):67-78.
- [2] 王平,郭继峰,史晓宁,等.服务航天器近距离操作四维运动规划方法研究[J].控制与决策,2010,25(10):1519-1522.
- [3] Chai R, Savvaris A, Tsourdos A, et al. Optimal fuel consumption finite-thrust orbital hopping of aeroassisted spacecraft [J]. Aerospace Science and Technology, 2018, 75:172-182.
- [4] Shen H X, Casalino L. High-accuracy optimal finite-thrust trajectories for Moon escape [J]. Acta Astronautica, 2017, 131:102-109.
- [5] Kharytonov O M, Kiforenko B M. Finite-thrust optimization of interplanetary transfers of space vehicle with bimodal nuclear thermal propulsion [J]. Acta Astronautica, 2011, 69(3-4):223-233.
- [6] Hall D T, Opiela J N, Krisko P H, et al. Legend-a three-dimensional leo-to-geo debris evolutionary model original research article [J]. Advances in Space Research, 2004, 34(5):981-986.
- [7] Dolado J C, Perez R, Costanzo D, et al. Introducing MEDEE: a new orbital debris evolutionary model [C]. 6th European Conference on Space Debris, 2013.
- [8] 钱宇,徐敏,郭东,等.在轨航天器轨道规避体系研究[J].西北工业大学学报,2010,28(1):13-17.
- [9] 姚党甯,王振国.航天器在轨防碰撞自主规避策略[J].国防科技大学学报,2012,34(6):100-103+110.
- [10] 晋小伟.有限推力下卫星轨道机动控制研究[D].哈尔滨:哈尔滨工业大学,2012.
- [11] 苏飞,刘静,张耀,等.航天器面内机动规避最优脉冲分析[J].系统工程与电子技术,2018,40(12):2782-2789.
- [12] 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.
- [13] 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.
- [14] 陈功,傅瑜,郭继峰.飞行器轨迹优化方法综述[J].飞行力学,2011,29(4):1-5.
- [15] 王常虹,曲耀斌,陆智俊,等.航天器有限推力轨道转移的轨迹优化方法[J].西南交通大学学报,2013,48(2):390-394.

作者简介

赵 毓(1992-),男,博士研究生,主要研究方向为空间无人系统任务规划与自主决策。

基于深度学习的空间多目标识别方法研究

王 柳

(哈尔滨工业大学智能感知与自主规划实验室, 哈尔滨 150001)

摘 要: 随着智能感知技术、目标识别技术的快速发展, 以卫星为主要代表的太空飞行器已成为各国太空攻防出奇制胜的重要军事资源。精确识别卫星的类型, 并精确定位卫星的帆板、喷管、星敏感器等部件是实施太空攻防和在轨维护的重要前提及保障技术。利用基于深度学习的卷积神经网络YOLO模型对空间卫星及其部件进行识别, 对两种卫星模型的三维模型及实物模型图片集进行训练, 对近距离正视、远距离、遮挡、运动模糊等不同条件下的卫星及卫星部件进行识别, 几种情况下卫星及卫星部件的识别准确率均达到了90%以上, 对在轨服务、太空攻防对抗等领域有重要意义。

关键词: 深度学习; 空间多目标; YOLO模型; 目标识别; 卫星部件

中图分类号: V19 **文献标识码:** A **文章编号:** 2096-5915 (2019) 03-0495-07

Research on Spatial Multi-objective Recognition Based on Deep Learning

WANG Liu

(Intelligent Sensing and Autonomous Planning, Harbin Institute of Technology, Harbin 150001, China)

Abstract: With the rapid development of intelligent perception technology and target recognition technology, spacecraft which is mainly represented by satellites, has become an important military resource for the extraordinary success of space attack and defense in various countries. Accurately identifying the type of satellite and pinpointing the components of the satellite's windsurfing, nozzles, and star sensors are important prerequisites and safeguards for space attack and on-orbit maintenance. In this paper, the deep learning-based convolutional neural network YOLO model is used to identify the space satellite and its components, and three-dimensional model and physical model image set of the two satellite models are trained for close-range front view, long distance, occlusion, and motion blur. Satellites and satellite components are identified under different conditions. In some cases, the accuracy of satellite and satellite components is more than 90%, it is of great significance in the field of on-orbit services, space attack and defense confrontation.

Keywords: Deep Learning; Spatial Multi-Objective; YOLO Model; Target Recognition; Satellite Component

1 引 言

随着太空领域的不断发展与竞争, 空间态势感知已成为太空安全防护与太空控制的重要基础。

空间目标识别是空间态势感知的重要组成部分, 与其他多个重要领域相互交叉, 具有重大的军事价值^[1]。空间目标识别主要利用空间目标特性数据, 对其身份、姿态、状态等属性进行有效判断

收稿日期: 2019-04-02; 修回日期: 2019-05-09

基金项目: 国家自然科学基金 (11672093)

和识别。当前，目标特性数据的来源主要为地基探测，包括光学和雷达等设备。然而，地基设备的探测数据与观测角度、目标特征、太阳角度和大气层等多种因素相关，使探测结果具有极大的不确定性，给空间目标识别带来诸多挑战^[2]。首先，空间目标的固有特征会对特性数据造成不同影响，如姿态、形状、表面材料等；其次，虽然不同目标在基本特征上具有一定差别，但由于目标数量多、范围广、空间环境复杂等因素，特性数据区分度并不明显，使目标不易分类和识别^[3]。

对非合作卫星进行自主识别与检测的手段主要有两种，一种是传统的目标识别方法，主要基于目标特性数据进行反演获得部分目标特征^[4-6]，对非合作目标选定的区域进行特征提取，提取的特征通常包括直线、多边形、椭圆等。但传统方法通常具有较高的算法复杂度，难以应对空间目标识别的新挑战。另一种是基于深度学习的方法，利用卷积神经网络(Convolutional Neural Networks, CNN)对已标记的图像进行训练，使损失函数值不断减小，从而得到各卷积层的权值。

本文基于CNN，以航天任务模拟工具(Satellite Tool Kit, STK)中两颗卫星和卫星实物模型为样本集，对两颗卫星及卫星的部件进行识别和检测。并搭建实物验证系统，检测在不同方位、不同光照条件、运动模糊等条件下卫星及部件的识别效果。

2 空间目标特性

典型卫星的局部构件主要包括卫星本体、天线、太阳帆板以及卫星搭载的有效载荷等。对于可观测局部构件，几何构形具备多样化的特点。

卫星本体一般都为规则形状，轮廓清晰可分辨，这有利于在视觉图像中相对容易地提取本体形状^[7]。

太阳帆板也被称为太阳电池板或太阳电池阵。卫星上安装的太阳帆板大致可分为体装式及展开式。对于体装式帆板，其轮廓与卫星主体轮廓重合较多，不能仅依靠形貌特征进行判断，还需要

用到太阳帆板的光学反射特性等作为识别判据；对于展开式太阳翼，其展开时大多为规则的矩形组合体，且安装位置与卫星主体存在一定距离，因此其轮廓提取与判断也相对容易。

卫星携带的通信天线包括全球波束、半球波束、区域波束、点波束、多波束、可变波束等类别，卫星依照其执行任务的不同会携带不同的天线，且数量往往不止一个。其中反射面天线的轮廓较明显，但其紧靠的发射器与接收器易干扰识别过程^[8]；喇叭天线相对卫星的几何尺寸较小，一般通过支架安装并与卫星表面保持一定距离；相控阵天线与螺旋天线也均用支架安装但一般相对贴近卫星表面。因此，可利用卫星的部分先验知识辅助构件的有效识别。

一般卫星搭载的有效载荷的种类与卫星功能相关，各功能卫星及其携带的载荷主要可分为以下几类：(1)科学探测和实验类卫星携带载荷：电离层探针、粒子探测器、磁强计、质谱计、红外天文望远镜等；(2)信息获取类卫星携带载荷：光学相机、多谱段扫描仪、微波辐射计、合成孔径雷达、无线电侦察接收机等；(3)信息传输类卫星携带载荷：通信转发器和通信天线；(4)信息基准类卫星携带载荷：无线电信标机、激光反射器等^[10]。

3 智能识别体系架构

3.1 空间多目标识别流程

在对CNN进行训练前要先利用小波阈值滤波方法对训练的图片进行去噪等预处理，再用CNN模型对预处理后空间环境中的卫星图片进行识别与检测^[11-12]。技术流程如图1所示。

建立卫星部件的样本库，对卫星及其部件进行标定。之后利用训练集对改进后的CNN进行训练，不断迭代更新各层CNN的权值，直到达到终止条件。利用验证集进行精度验证，修改学习率、激活函数、训练集样本数等再次进行训练直到达

到精度要求。

3.2 网络模型设计

CNN YOLO结构模型如图2所示，模型共含24个卷积层、4个池化层和2个全连接层^[9]。模型将原图划分为 $S \times S$ 的网格。如果一个目标的中心落入格子，该格子就负责检测该目标。每一个格子预测边界框和该边界框的置信值。置信值代表此边界框里包含一个目标的置信度，用 $P(\text{Object}) * IOU_{pred}^{truth}$ 表示，其中 $P(\text{Object})$ 表示当前位置是一个卫星的概率，如果没有目标，置信值为零。另外，希望预测的置信值和真值预测的重叠概率(Intersection Over Union, IOU)相同。记

录的5个元素具体为 $(x, y, w, h, P(\text{Object}) * IOU)$ ， (x,y) 代表当前格子预测得到的卫星或卫星部件边界框的中心坐标， (w,h) 为卫星或卫星部件边界框的宽和高。网络最后的输出为 $S \times S \times (B \times 5 + C)$ 维度的张量。其中B指边界框的个数，C指网络要预测的类别数。

3.3 误差函数设计

采用求和平方误差最小为目标函数来优化，增加边界框损失权重，减小置信度权重。训练阶段的总损失函数LOSS如式(1)所示。总LOSS函数分为三个部分：坐标损失(前两项)，类别损失(中间两项)，置信损失(最后一项)。

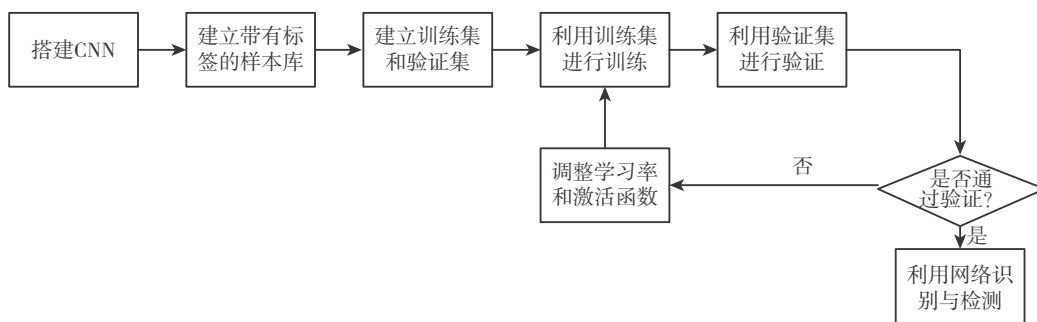


图1 空间多目标识别流程图

Fig.1 Spatial multi-objective identification flow chart




图2 CNN模型结构

Fig.2 CNN model structure

$$\begin{aligned} \text{LOSS} = & \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{\text{obj}} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{\text{obj}} [(\sqrt{\omega_i} - \sqrt{\hat{\omega}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] \\ & + \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{\text{obj}} (C_i - \hat{C}_i)^2 + \lambda_{\text{noobj}} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{\text{noobj}} (C_i - C_i)^2 + \sum_{i=0}^{S^2} I_i^{\text{obj}} \sum_{c \in \text{classes}} (p_i(c) - \hat{p}_i(c))^2 \end{aligned} \quad (1)$$

损失函数的设计目标是让坐标 (x, y, w, h) 、置信值、类别这三个方面达到很好的平衡。此函数避免了以下不足^[9]：(1)坐标损失和类别损失同等重要显然不合理；(2)如果一个网格中没有卫星本体或部件（一幅图中这种网格很多），那么就会将这些网格中边界框的置信值减小到0，相比于较少的有卫星部件的网格，这种做法会导致网络不稳定甚至发散。

式(1)的创新点有：(1)更重视坐标预测，在坐标损失前赋予了更大的权值，记作 λ_{coord} ，在本网络中取值为5；(2)对于不同大小的边界框预测，相比于大边界框偏一点，小边界框预测偏一点更不能忍受。为缓解这个问题，将边界框的宽和高取平方根代替原来的宽和高；(3)对没有卫星本体或部件的边界框的置信损失赋予小的权值，记为 λ_{noobj} ，在本网络中取值为0.5。

对卫星部件的识别与检测与对卫星的识别与检测相比，种类更多且要识别的部件像素区域更小，识别的难度更大。这部分利用的CNN做了如下修改：

(1)对卫星部件进行识别，更强调是否有过拟合。在每一个卷积层后添加批量标准化 (Batch Normalization)，极大的改善了收敛速度，同时减少了对其它正则化方法的依赖。

(2)对卫星部件进行检测，检测的像素区域更小，需要图片的分辨率更高。目前的目标检测算法中，一般会使用ImageNet预训练过的模型提取特征，如果用AlexNet网络输入的图片，则分辨率会被缩放到不足 256×256 ，导致分辨率不够，给检测带来困难。改进后的网络通过修改预训练分类网络的分辨率为 448×448 ，并在ImageNet数据集上训练10轮。这个过程让网络有足够的时间去适应高分辨率的输入。

(3)在识别与检测种类增多时，为提高运算效率，借鉴Faster R-CNN^[13]中的Anchor思想：在卷积特征图上进行滑窗采样，每个中心预测9种不同大小和比例的建议框，基于此，对每个窗口位置都可以根据9个不同长宽比例、不同面积的Anchor逆向推导出它对应的原始图片中的一个区域。由于都是卷积不需要重塑，很好的保留空间信息，最终特征图的每个特征点和原图的每个网格一一对应。用预测相对偏移取代直接预测坐标，方便网络学习，即移除全连接层，使用Anchor框去预测边界框。

4 实验测试与结果

4.1 网络模型参数设置

Batch=1, Subdivisions=1;

初始学习率: Learning Rate=0.0005;

衰减正则项: Decay=0.0005;

旋转角度: Angle=5 (通过随机旋转角度 $-5^\circ \sim 5^\circ$ 生成更多样本);

饱和度: Saturation=1.5 (通过调整饱和度 1~1.5倍来生成更多样本);

曝光量: Exposure=1.5 (通过调整曝光量 1~1.5倍来生成更多样本);

色调: Hue=0.1 (通过调整色调 1~1.1倍来生成更多样本)。

经过60000次的循环迭代，网络的各参数如下：

平均IOU: Region Avg IOU=0.8996 (代表边界框和真值的交集和并集的比，期望该值趋近于1);

类别: Class=0.9032 (标注物体类型的概率，期望该值趋近于1);

标注物体的概率: Obj=0.8887 (期望该值趋

近于1);

平均召回率: Avg Recall=0.8530 (期望该值趋近于1);

平均损失: Avg Loss=2.9641 (期望该值趋近于0)。

4.2 目标数据集

本文的目标数据集由三部分构成,分别是STK软件中北斗卫星模型、Cartosat-2卫星模型的图片;SolidWorks绘制的北斗卫星模型、Cartosat-2卫星模型的图片;北斗卫星模型、Cartosat-2卫星模型的实物模型图片。分别标记了这些图片中的星本体、帆板、天线、喷管、相机、星敏感器。

4.3 目标训练

训练网络用的深度学习工作站配有4个GPU, GPU由大量的运算单元组成,计算效率是CPU的几十倍,并行计算能力远高于CPU。通常来说, GPU拥有普通内存位宽更大、频率更高的专用显存,适合处理大规模数据的并行计算。深度学习工作站实现了“CPU+GPU”协同计算加速,能合理分配计算资源,充分释放计算能力,具有高效、可靠、稳定的性能,它利用GNU编译器包括C/C++/Fortran、MKL库以及OPENMPI、MPICH的并行消息环境,采用Caffe、Tensorflow、Theano、BIDMach、Torch等深度学习框架,通过编译Caffe的Python和Matla等接口,基于B/S架构实现且可视化的进行深度神经网络的训练、测试等。

深度学习工作站如图3所示。



图3 深度学习工作站外形图
Fig.3 Deep learning workstation

4.4 识别结果

(1) 仿真图片识别结果

详见图4-7。




图4 Cartosat-2的STK图片识别结果
Fig.4 Cartosat-2 STK picture recognition results




图5 北斗的STK图片识别结果
Fig.5 Beidou STK picture recognition results

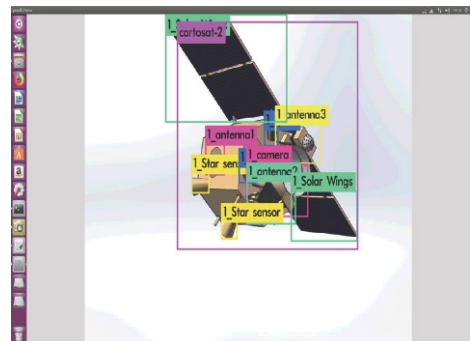


图6 Cartosat-2 3D建模图识别结果
Fig.6 Cartosat-2 3D picture recognition results




图7 北斗3D建模图识别结果
Fig.7 Beidou 3D picture recognition results

两类卫星模型识别的准确率约为95%，召回率约为92%。

(2) 实物模型识别结果

本文在近距离正视、侧视及遮挡、弱光照条件下对两组不同的实物卫星模型进行检测，检测的结果如下：




图8 近距离正视条件下北斗模型识别结果

Fig. 8 Beidou model recognition results under close-range conditions




图9 近距离正视条件下Cartosat-2卫星模型识别结果

Fig.9 Cartosat-2 recognition results under close-range conditions

近距离正视条件下卫星模型识别准确率为96.6%，召回率为97.3%。




图10 侧视及遮挡条件下北斗模型识别结果

Fig.10 Beidou recognition results under side and occlusion conditions




图11 侧视及遮挡条件下Cartosat-2卫星模型识别结果

Fig.11 Cartosat-2 recognition results under side and occlusion conditions

侧视及遮挡条件下卫星模型识别准确率为90.2%，召回率为87.25%。




图12 弱光照条件下北斗卫星模型识别结果

Fig.12 Beidou model identification results under weak lighting conditions

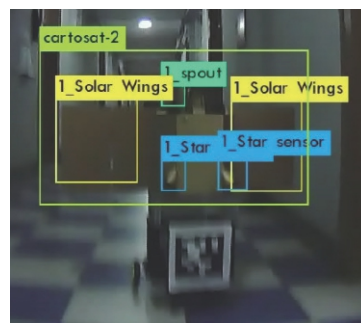


图13 弱光照条件下Cartosat-2卫星模型识别结果

Fig.13 Cartosat-2 model identification results under weak lighting conditions

弱光照条件下卫星模型识别准确率为90.09%，召回率为77.52%。

在近距离正视方位情况下对卫星模型的识别检测的准确率较高，能达到96.6%。而在遮挡、运动模糊、暗光照环境等极端环境下准确率稍低，达到90.1%左右。可以通过加大训练特殊情况下的样本提高准确率。

5 结束语

本文基于CNN YOLO模型对两类空间卫星(Cartosat-2、北斗)及其部件(帆板、星敏感器、天线、喷管、相机等)在近距离正视、远距离、遮挡、运动模糊等不同条件下进行识别测试,识别准确率均达到了90%以上。本文的研究对空间在轨服务、态势感知中的目标识别有重要参考价值,创新点在于将星本体、帆板、天线等部件的形状信息作为CNN的权重先验值;结合星本体及部件的特殊性,对误差损失函数和网络结构进行修改。但本文仅是在地面环境下对按一定缩比的卫星模型进行识别,尽管考虑了不同运动、不同光照、不同方位情况,但是对于更加复杂的太空光照环境、复杂的章动、进动等运动规律下卫星模型的识别仍未全面考虑,后期可用仿真的太空光照环境图片或者真实拍摄的卫星图片进行训练、检测,进一步验证在复杂太空环境下此卫星识别算法的准确性。

参 考 文 献

- [1] 曾德贤,李智.太空态势感知前沿问题研究[J].装备学院学报,2015,26(4):71-76.
- [2] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J]. Computer Science, 2014.
- [3] Furfaro R, Linares R, Jah M K, et al. Mapping sensors measurement to the resident space objects behavior energy and state parameters space via extreme learning machines [C]. The 67th International Astronautical Congress, Guadalajara, Mexico, 2016.
- [4] Linares R, Leve F A, Jan M K, et al. Space object mass-specific inertia matrix estimation from photometric data [J]. Advances in the Astronautical Sciences, 2012, 144: 41-54.
- [5] Hinks J C, Crassidis J L. Angular velocity bounds via light curve glint duration [C]. AIAA Guidance, Navigation and Control Conference, 2016.
- [6] 王阳,杜小平,范椿林.地基光度曲线反演空间目标特征技术研究进展[J].科学通报,2017,62(15):1578-1590.
- [7] Payne T, Gregory S, Luu K. SSA analysis of geosynchronous photometric signature classifications and solar panel offsets [C]. The Advanced Maui Optical and Space Surveillance Technologies Conference, 2006.
- [8] Vrba F J, Divittorio M E, Hindsley R B, et al. A Survey of Geosynchronous Satellite Glints [C]. Proceedings of the Advanced Maui Optical and Space Surveillance Technologies Conference, 2009.
- [9] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [J]. Image Processing, 2015.
- [10] Walker G K, Taylor J K. Satellite identification and antenna alignment [J]. Molecular Ecology Notes, 1994, 6(3):882-885.
- [11] 刘礼城,周如好,张丽敏,等.基于视觉的航天器的特征识别算法[C].第二届中国空天安全会议,2017.
- [12] 高琳,宋伟东,谭海,等.多尺度膨胀卷积神经网络资源三号卫星影像云识别[J].光学学报,2019,39(1):299-307.
- [13] 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, 2015, 39(6):1137-1149.

作者简介:

王柳(1996-),女,硕士研究生,主要研究方向为空间目标识别、视觉导航。

国外无人在轨服务和模块化可重构航天器发展分析

贾平, 刘笛

(中国航天系统科学与工程研究院, 北京 100048)

摘要: 概述了无人在轨服务航天器和模块化可重构航天器的内涵和背景; 梳理了各国重点在轨服务项目概况和最新进展; 分析了美国服务保障航天器处于在轨验证阶段, 欧洲太空碎片移除技术率先开展在轨验证等无人在轨服务航天器发展现状; 阐述了美国和欧洲分别开展和即将开展关键技术验证等模块化可重构航天器发展现状; 总结了在轨服务航天器和模块化可重构航天器有望变革航天器设计、制造、部署和运用方式, 增强航天系统抗毁性等对航天器和航天能力发展的影响。

关键词: 在轨服务航天器; 模块化可重构航天器; 服务保障; 在轨制造; 太空碎片移除

中图分类号: V476.9 **文献标识码:** A **文章编号:** 2096-5915 (2019) 03-0502-06

Development Analysis of Unmanned On-Orbit Servicing Spacecraft and Modular Reconfigurable Spacecraft Abroad

JIA Ping, LIU Di

(China Aerospace Academy of Systems Science and Engineering, Beijing 100048, China)

Abstract: The connotations and backgrounds of unmanned on-orbit servicing spacecrafts and modular reconfigurable spacecrafts are summarized. The basic information and the latest news of on-orbit servicing programs are presented. The status quo of the unmanned on-orbit servicing spacecrafts of foreign countries is analyzed. For instance, the US servicing and supporting spacecrafts are in the on-orbit demonstration phase and the European space debris removing technologies have been demonstrated. The current development of modular reconfigurable spacecrafts is studied. The effects of unmanned on-orbit servicing spacecrafts and modular reconfigurable spacecrafts on the future development of spacecrafts and space capabilities are summarized. For example, they may change the way spacecrafts which are designed, manufactured, deployed, utilized and improve the survivability of space systems.

Keywords: On-Orbit Servicing Spacecraft; Modular Reconfigurable Spacecraft; Servicing and Supporting; On-Orbit Manufacturing; Space Debris Removing

1 引言

近年来, 国外无人在轨服务航天器和模块化可重构航天器发展势头强劲, 多国陆续开展了多次地面和在轨试验。模块化可重构航天器的设计和制造方式相比传统航天器更便于无人在轨服务

航天器进行在轨维修、装配和升级等操作。两者协同发展, 有望变革航天器的设计、制造、部署和运用方式, 对于增强军事航天能力等具有重要意义。

无人在轨服务航天器通常装有机械臂等执行机构, 具有一定自主能力可在太空中自由飞行。按任务类别可分为具有推进剂在轨加注、机械维

修、辅助变轨等功能的服务保障航天器，在轨制造航天器以及太空碎片移除航天器。模块化可重构航天器由多个外形尺寸相同的模块按任务需求组装而成，可通过软件或硬件方式在轨增减模块改变平台构型和能力^[1]。模块化可重构航天器有以下几种装配方式：一是在地面装配；二是由国际空间站上的航天员装配；三是由在轨服务航天器装配。随着自主技术等的发展，未来还可能实现不依赖外力，由各模块在轨自主机动对接装配而成。

无人在轨服务航天器自20世纪80年代兴起，经过数十年的发展，已陆续开展多次在轨试验。美国国防预先研究计划局(DARPA)曾于21世纪初启动具有快速、灵活、可分开和编队飞行能力的未来航天器计划(F6计划)，为后续可接受在轨服务的模块化可重构航天器发展储备了技术基础^[2]。2010年左右，美国和欧洲启动协同发展在轨服务和模块化可重构航天器的项目。DARPA于2011年启动凤凰计划，旨在验证通过无人在轨服务航天器将静止轨道退役卫星上的天线与新型模块化可重构平台在轨装配成新卫星的技术。在DARPA 2015财年预算中，凤凰项目被拆分为新凤凰和地球同步轨道卫星机器人服务(RSGS)两个项目，新凤凰仅保留原凤凰的前期阶段，致力于研究模块化可重构航天器。RSGS是原凤凰的后期阶段和拓展，主要研发在轨服务航天器。拆分后的两个项目各自发展在轨服务航天器和模块化可重构航天器，更有利于项目管理和集中资源分别促进两类技术发展^[3]。2010年，德国启动用于在轨卫星服务和装配的智能建造模块(iBOSS)项目，研究在轨服务航天器，以及用其将智能模块立方体装配成模块化可重构航天器的技术^[4]。

2 无人在轨服务航天器发展现状

美国是无人在轨服务航天器发展最先进的国家，欧洲和日本次之。这些国家发展的种类覆盖在轨服务保障、在轨装配和太空碎片移除各类。俄罗斯曾利用小卫星进行在轨交会与逼近技术试

验，并开展少量太空碎片移除技术研究项目，为研制无人在轨服务航天器储备了技术基础。

2.1 美国服务保障航天器处于在轨验证阶段，在轨制造航天器是近年发展重点

美国于2007年通过轨道快车项目，在近地轨道初步开展针对合作目标的在轨模块更换、在轨加注技术演示验证。此后发展了多个用于推进剂在轨加注、在轨维修、辅助变轨，且针对具有部分非合作特性目标进行操作的服务保障航天器，多个项目将于2020年左右开展在轨试验。其中，在轨加注航天器处于关键技术验证阶段：机器人推进剂加注(RRM)近年已利用空间站机械臂和安装在站外的模拟卫星开展多次关键技术试验^[5]；复元-L(Restore-L)在2019年完成平台关键设计评审，计划2022年进行在轨试验^[6]。辅助变轨机器人有望率先实现商业化运营：任务扩展飞行器(MEV)于2017年完成“交会、逼近操作与对接”系统的初始设计评审，计划2019年发射并提供商业服务^[7]。此外，具有在轨维修、辅助变轨及安装附件有效载荷功能的RSGS项目已于2018年完成有效载荷初始设计评审，计划2023年前开展在轨试验。

服务保障航天器的快速发展为美国近几年着力发展在轨制造航天器储备了较多技术基础。蜻蜓(Dragonfly)、大型结构系统太空装配(SALSSA)、太空建筑师(Architect)等项目分别从安装卫星部件、大型结构系统、结构制造与装配一体化等不同角度发展在轨制造和装配能




图1 MEV在轨服务概念图

Fig.1 The concept of MEV

表1 美国重点在轨服务项目
Table 1 Key on-orbit servicing programs of USA

项目名	类型	研发时间	研究内容或目标	进展
RRM	服务保障	2011年至今	针对无专门加注接口的卫星，测试在轨加注和在轨维修卫星的工具。	近年在国际空间站外进行部分技术在轨演示验证。
Restore-L	服务保障	2014年至今	为近地轨道卫星提供加注服务，验证机械臂操作、推进剂转移技术。	2019年平台完成关键设计评审，计划2022年在轨验证。
MEV	服务保障	2010年至今	通过交会、逼近和对接来辅助目标进行姿态控制和调整轨道。	2017年完成“交会、逼近操作与对接”系统的初始设计评审，计划2019年发射。
RSGS	服务保障	2015年至今	高分辨率检视，修正机械异常（展开故障），辅助变轨等；安装附加有效载荷。	2018年完成有效载荷初始设计评审，计划2023年前在轨试验。
Dragonfly	在轨制造	2015年至今	重点研究在轨装配与重构射频天线发射器技术。	2017年完成系统首次地面试验，演示验证了机械臂系统为模拟地球同步轨道卫星安装天线反射器的过程。
SALSSA	在轨制造	2015年至今	针对大型模块化结构系统，自动装配、翻新、重构及再利用。	—
Architect	在轨制造	2015年至今	在轨增材制造与装配大型、复杂结构，例如通信卫星的发射器。	2019年在模拟太空环境下完成增材制造与装配试验。
抓取、回收并保护有效载荷（GRASP）	太空碎片移除	—	利用充气管部署网或布捕获太空碎片。	2004年完成微重力试验。
脐带（SOUL）	太空碎片移除	—	利用有系绳连接的子母星移除太空碎片。	—

力，目前多处于系统地面验证阶段^[8]。Dragonfly、Architect项目都有望在2020年开展在轨验证。

此外，美国政府和军方很少自行开展太空碎片移除航天器和技术研究，主要通过资助私营企业开展前期研究工作，进展不显著。

2.2 欧洲太空碎片移除技术率先开展在轨验证，辅助变轨服务和在轨制造航天器并行推进

欧洲太空碎片移除技术发展世界领先，太空碎片移除（RemoveDebris）项目分别于2018年和2019年率先完成飞网和飞叉捕获模拟太空碎片的在轨验证。

欧洲多个在轨服务项目仅在进行了初步概念设计或地面演示验证后即被终止。原计划2018年在近地轨道验证在轨加注、在轨模块更换、太空碎片移除技术的综合性在轨服务项目——德国轨道服务任务（DEOS）也被取消。但这些项目已储

备诸多关键技术。目前，欧洲正在开展的在轨服务航天器研究项目以太空雄蜂（Space Drone）为主，主要用于辅助变轨，计划2020年发射^[9]。

此外，德国用于在轨卫星服务和装配的智能建造模块（iBOSS）在轨制造航天器项目已开展多年，在2018年开展了关键技术地面试验，有望在2020年进行在轨验证。




图2 太空雄蜂在轨服务概念图
Fig.2 The concept of Space Drone

表2 欧洲重点在轨服务项目

Table 2 Key on-orbit servicing projects of European

项目名	类型	研发时间	研究内容或目标	进展
Space Drone	服务保障	—	通过交会、逼近和对接来辅助目标进行姿态控制和调整轨道。	计划 2020 年发射。
iBOSS	在轨制造	2010 年	将“智能模块”立方体装配成模块化可重构航天器。	2018 年开展关键技术地面验证, 计划 2020 年进行在轨验证。
太空碎片移除 (RemoveDebris)	太空碎片移除	2013 年至今	利用飞网和飞叉等捕获并移除太空碎片。	2018 年和 2019 年分别完成飞网和飞叉捕获技术在轨验证。
E. 脱轨 (E.Deorbit)	太空碎片移除	2012 年至今	利用飞网和机械臂等捕获并移除太空碎片。	2015 年开展微重力试验; 2019 年计划扩展为综合性在轨服务验证项目, 计划 2021 年发射。

表3 日本重点在轨服务项目

Table 3 Key on-orbit servicing projects of Japan

项目名	类型	研发时间	研究内容或目标	进展
ETS-VII	服务保障	1997 年发射	在轨验证交会对接技术、机械臂捕获技术、在轨模块更换技术、地面遥操作技术。	1997 年完成在轨演示验证。
以规划项目牵引发展在轨制造技术	在轨制造	—	以天基太阳能发电系统的建设与运行保障任务为牵引。	—
KITE 等技术验证任务	太空碎片移除	2012 年至今	利用电动绳系系统移除太空碎片。	2017 年尝试在轨验证, 但系绳展开失败。
ELSA-d	太空碎片移除	—	利用磁力移除太空碎片。	计划 2020 年在轨试验。
SDMR	太空碎片移除	21 世纪初期	利用装有电动绳系系统和轻型折叠机械臂的微小机器人捕获碎片并清理。	2017 年或 2018 年完成了抓捕机构样机试验。

2.3 日本服务保障航天器率先开展在轨试验后多年未见显著进展, 太空碎片移除技术是当前发展重点

日本的工程技术试验卫星-7 (ETS-VII) 项目于 1997 年发射入轨, 是世界首个开展在轨试验的在轨服务航天器。ETS-VII 对在低轨道运行的合作航天器进行在轨模块更换等操作技术进行了在轨验证。在 ETS-VII 之后提出的轨道维护系统 (OMS)、可重构机器人卫星簇 (RRSC) 项目研究针对高轨非合作目标进行多种在轨操作能力的航天器, 但多年来一直未见详细进展情况^[10]。

近年来, 日本重点发展太空碎片移除技术: 利用电动绳系和轻型折叠机械臂系统移除太空碎片的太空碎片清理者 (SDMR) 完成了抓捕机构样机试验; 利用电动绳系系统移除太空碎片的白鹤号集成绳系实验 (KITE) 技术验证任务曾于 2017 年开展碎片移除在轨验证, 但系绳未能成功展开; 利用磁力移除太空碎片的宇航尺度寿命终结服务-验证 (ELSA-d) 计划 2020 年开展在轨试验^[11]。

3 模块化可重构航天器发展现状

美国、德国等从 21 世纪初开始开展模块化可重构航天器研究。近年, DARPA 资助的凤凰项目和德国航空航天中心 (DLR) 资助的 iBOSS 项目分别开展或即将开展关键技术验证。

3.1 美国开展关键技术验证

DARPA 从 2011 年开始通过凤凰项目资助研究利用细胞卫星装配成模块化可重构航天器。按当前设计方案, 这种航天器平台由多颗外形和尺寸相似的高度集成卫星 (HISat) 灵活按需组装而成。每颗 HISat 具有全部子系统功能, 由多颗同时具有 2 种或 2 种以上子系统功能的细胞卫星基础模块组成^[12]。为验证细胞卫星集成技术的可行性, 凤凰项目开展了多次试验。2015 年底至 2017 年, 航天员在国际空间站上手动组装了由 6 颗 HISat 和有效载荷构成的卫星, 并进行在轨试验。2018 年

3月，由4颗 HISat 构成的有效载荷在轨交付卫星 (PODSat) 寄宿在一颗通信卫星上发射入轨，验证细胞卫星平台容纳新补充细胞卫星模块的可行性，并提供试验数据。2018年12月，由14颗 HISat 构成的细胞卫星集成技术实验 (eXCITe) 卫星进入太阳同步轨道开展第3次在轨试验。此次试验卫星的细胞卫星模块数量为历次试验最多。

3.2 美国开始探索不依赖外力的模块自主对接装配概念

凤凰项目研究的模块化可重构航天器当前主要采取在地面装配或在空间站装配的方式，未来将随着在轨服务航天器的发展进行在轨装配。近年，美国多家公司陆续提出不依靠外力装配，利用模块/小卫星以在轨自主交会和对接方式装配成航天器的概念。DARPA 资助的太空光学孔径自组装 (OASIS) 项目计划研究通过小模块自主交会对接后装配成孔径大于5m的光学望远镜。2016年，OASIS 完成系统需求和初步设计评审，此后 DARPA 停止为该项目申请预算。2018年2月，美国航空航天公司宣布正通过蜂巢 (Hive) 项目研究利用智能单元模块按需在轨自组装成多种航天器平台的可行性^[13]。模块可能被做成立方体或蜂巢式的环状，可执行翻滚、跳跃、换位、爬升等动作。2018年3月，美国航空航天局 (NASA) 资助系绳无限公司 (Tethers Unlimited) 开展制造者卫星 (MakerSat) 项目，以验证小卫星在轨自主对接装配成大型航天器的可行性。



图3 蜂巢航天器概念图
Fig.3 The concept of Hive

3.3 德国即将开展在轨验证

DLR 于2010年开始资助 iBOSS 项目，拟研究利用在轨服务航天器将智能模块立方体装配成模块化可重构航天器。“智能模块”立方体边长40cm，内部可容纳几乎所有平台子系统，装有力、热、电和数据传输四合一接口，用于模块间连接以及模块与其他部件、子系统、航天器连接。该项目计划2020年进行在轨验证^[4]。



图4 iBOSS概念图
Fig.4 The concept of iBOSS

4 对未来航天器和航天能力发展的影响

在轨服务航天器和模块化可重构航天器将从设计、制造、部署和运用等各方面影响航天器的发展，同时也将更快速、灵活地响应作战需求，增强航天系统抗毁性。

(1) 对航天器设计的影响

随着相关技术不断发展，未来航天器设计将更多地采用可接受在轨服务的模块化可重构设计。一方面实现按客户和任务需求快速设计定制，另一方面航天器结构和性能的设计上限将得到提高，使尺寸和质量超出当前运载能力的、超大型模块化航天器，如超大口径望远镜、天基太阳能电站等的设计成为可能。

(2) 对航天器制造部署方式的影响

未来航天器将可由在轨制造航天器利用在轨存储的模块按需快速装配而成，实现“即需即造”

即装配”，节省制造和从地面发射航天器的成本和时间^[14]。随着自主技术的不断成熟，航天器还将由在轨制造航天器装配发展至通过模块自主对接装配，进一步提升航天器制造和部署速度。

(3) 对航天器运用与维护的影响

模块化可重构航天器可通过服务保障航天器在轨拆卸损坏和需升级的模块并安装新模块，实现“即破旧即维修和升级”。此外，废旧航天器功能完好的模块可被在轨服务航天器拆卸后重复利用，避免成为太空垃圾。

(4) 对航天能力的影响

一方面，在轨服务航天器和模块化可重构航天器配合发展，可快速、灵活响应作战任务。和平时，将航天器模块送入轨道存储；战时，可根据任务需求，选取模块定制航天器，快速形成作战能力，也可根据任务变化，利用在轨服务航天器重组或升级模块化可重构航天器，灵活满足新任务需求^[12]。另一方面，在轨服务航天器和模块化可重构航天器配合发展，有助于增强航天系统抗毁性。模块化可重构航天器受到攻击或自然损坏导致部分模块失效后，能通过在轨服务航天器更换新模块恢复系统能力。此外，可自主组装的模块化可重构航天器在遇到太空碎片等威胁时，能分散成零散模块，威胁解除后自行重组^[12]。

5 结束语

综上，国外无论政府、国防研究机构还是商业界，都在积极开展无人轨道服务航天器和模块化可重构航天器研究。无人轨道服务航天器和模块化可重构航天器有望广泛用于商业服务和军事航天能力建设，促使航天任务更经济、灵活、高效。

参 考 文 献

- [1] 庞羽佳,李志. 模块化可重构空间系统研究[J]. 航天器工程, 2016, 25(3).
- [2] Schmidt J, Phillips M R. A distributed, redundant navigation and fault detection system for DARPA system F6 [C]. Aiaa Guidance, Navigation, & Control. 2013.
- [3] DARPA-PS-16-01 RSGS program solicitation [R]. USA: DARPA, 2016.
- [4] GERMAN AEROSPACE CENTER. iBOSS - Intelligent building blocks for on-orbit satellite servicing and assembly [EB/OL]. 2017. <https://www.iboss.space/wp-content/uploads/2017/09/IAC-17D123x40674.pdf>
- [5] NASA. Administration robotic refueling mission 3 [EB/OL]. 2017. https://www.nasa.gov/sites/default/files/atoms/files/rrm3_factsheet_110718_final.pdf
- [6] Restore-L servicing technologies [EB/OL]. 2019. <https://sspd.gsfc.nasa.gov>.
- [7] ORBITAL ATK. Mission extension vehicle (MEV) fact sheets [EB/OL]. 2017. https://www.northropgrumman.com/Capabilities/SpaceLogistics/Documents/MEV_Factsheet.pdf
- [8] 贾平. 国外在轨服务空间机器人发展分析 [C]. 中国宇航学会2016年学术年会, 2016.
- [9] EFFECTIVE SPACE. Pioneering last-mile logistics in space [C]. The 54th session of the Scientific and Technical Subcommittee, 2017.
- [10] 陈小前, 袁建平. 航天器在轨服务技术 [M]. 北京: 中国宇航出版社, 2009.
- [11] Akira O, Miki I. Maximizing post mission disposal of mega constellations satellites reaching end of operational lifetime [C]. 7th European Conference on Space Debris, 2017.
- [12] 贾平. 模块化可重构航天器将成为航天器发展新方向 [J]. 国际太空, 2019(5).
- [13] Aerospace Corporation. Hive satellites redefine disaggregation. [EB/OL]. 2018. <https://aerospace.org/article/hive-satellites-redefine-disaggregation>.
- [14] 贾平. 从近年国外航天前沿技术动向看未来航天器发展 [C]. 第二届世界航天前沿发展论坛, 2018.

作者简介:

贾平(1986-),女,博士,高级工程师,主要研究方向为航天前沿技术领域情报分析。

刘笛(1990-),女,硕士,工程师,主要研究方向为航天器情报分析。

智能遥感研究现状与展望

陈 昕¹, 刘昌昊², 陈培永³, 华 春³, 刘延芳²

(1. 哈尔滨工业大学电气工程及自动化学院, 哈尔滨 150001; 2. 哈尔滨工业大学航天学院, 哈尔滨 150001;
3. 上海航天信息研究所, 上海 201109)

摘 要: 对智能遥感这一新兴领域的研究进行了综合评述, 并对未来智能遥感的发展进行了展望。首先分析了遥感任务规划的现状和面临的挑战, 归纳了智能遥感任务规划方法; 其次, 分析了观测卫星图像处理流程, 归纳了智能遥感图像数据处理方法; 最后, 对智能遥感技术未来的发展做出了展望。综述表明, 人工智能技术具备自主学习和推理能力, 是解决当前遥感技术存在的实时性差和数据利用率低下等问题的重要潜在技术手段, 可以与遥感任务规划和遥感图像处理两个层面结合, 开展进一步深入研究。

关键词: 人工智能; 遥感; 任务规划; 图像处理; 神经网络; 深度学习

中图分类号: X83 **文献标识码:** A **文章编号:** 2096-5915 (2019) 03-0508-09

The State-of-Art and Future of the Intelligent Remote Sensing

CHEN Xin¹, LIU Changhao², CHEN Peiyong, HUA Chun³, LIU Yanfang²

(1. School of Electrical Engineering and Automation, Harbin Institute of Technology, Harbin 150001, China;
2. School of Astronautics, Harbin Institute of Technology, Harbin 150001, China;
3. Space information Institute, Shanghai 201109, China)

Abstract: In this paper, the research in intelligent remote sensing is reviewed and the future development is prospected. Firstly, the status quo and challenges of remote sensing satellites' mission planning are analyzed and the methods used in this field are generalized; Secondly, image processing flow of observation satellites is dissected and the intelligent remote sensing image data processing method is summarized. Last, the future development of intelligent remote sensing technology is prospected. The review shows that artificial intelligence technology has the ability of self-learning and reasoning, it is an important potential technical means to solve the problems of poor real-time performance and low data utilization of remote sensing technology and can be combined with remote sensing mission planning and remote sensing image processing to develop further research.

Keywords: Artificial Intelligence; Remote Sensing; Task Planning; Image Processing; Artificial Neural Network; Deep Learning

1 引 言

遥感技术通过卫星或航空平台上的遥测仪器对地球表面的地物进行监测, 可以快速、大范围地获取综合数据。遥感技术根据工作平台分为地面遥感、航空遥感和航天遥感; 根据传感器的探

测波段分为紫外遥感、可见光遥感、红外遥感、微波遥感和多波段遥感; 根据记录方式分为成像遥感和非成像遥感等。目前遥感技术被广泛应用于农业评估与监测、水质处理、自然灾害监测与防治、地理数据及资源数据的获取等国民经济建设的多个方面^[1]。

收稿日期: 2019-04-15; 修回日期: 2019-05-13

基金项目: 上海航天创新基金项目 (SAST-2018-109)

遥感系统包含四大环节：信息源、信息获取、信息处理和信息应用。遥感任务规划和遥感图像处理是信息获取与处理的核心技术，是遥感系统两大关键环节。如何有效规划遥感任务，快速获取所需的实时数据，并高效地实现遥感数据的快速与高效冗余处理，是当前遥感技术中存在的主要难点。

人工智能通过智能体感知或认知外界环境并产生交互，具有自主学习和推理能力，应用于遥感领域，有望解决当前遥感技术的实时性差和数据利用率低下的问题，实现遥感的智能化与自主化。

本文针对人工智能技术在遥感卫星任务规划和图像处理两方面应用的研究现状进行综述，并提出展望。

2 遥感任务智能规划研究现状

2.1 遥感任务规划面临挑战与现状

随着航天技术的发展和航天应用的深化，遥感卫星数量越来越多且种类呈现多样化，遥感任务规划也随之急剧复杂化。遥感任务规划所面临的挑战主要体现：(1)人工任务规划无法应对数量众多的遥感卫星复杂任务规划，容易出现错误，亟待通过智能算法实现自主任务规划；(2)对于偶发目标和各种不确定性因素的自主处理能力需求增强，偶发目标通常具有较高的观测价值，而不确定性因素会导致原有观测任务无法按计划执行，若卫星不具备自主运行能力，就无法对观测任务进行及时调整，从而造成数据的浪费与资源的损失。因此，必须研究面向对地观测卫星的智能自主任务规划方法，实现卫星观测任务的自主规划和调度^[2]。

智能遥感任务规划就是应用基于人工智能的方法实现卫星观测任务的自主规划和调度。国外在卫星任务规划领域的研究持续时间长，技术比较成熟，且相关技术已投入实际的航天应用，如美国国家航空航天局(NASA)的喷气动力实验

室人工智能研究组所开发的规划系统CASPER (Continuous Activity Scheduling Planning Execution and Replanning)已应用到EO-1等任务中，并取得成功。国内在该领域的研究也取得了一定的成果，中科院和国防科大侧重于卫星任务规划的研究，哈工大研究的应用平台以深空探测器为主^[3]。

2.2 智能遥感任务规划方法

在遥感卫星规划的人工智能方法研究中，比较有代表性的有：启发式搜索算法、专家系统、基于Agent的规划调度方法、基于神经网络的方法、遗传算法、模拟退火算法和禁忌搜索算法等。

2.2.1 启发式搜索算法

启发式算法是指在可接受的花费(指计算时间、占用空间等)下给出待解决组合优化问题每一个实例的一个可行解。启发式算法常能在合理时间给出很不错的解，但在某些特殊情况下，启发式算法会得到很坏的答案或运行效率极差。幸运的是，造成那些特殊情况的数据结构也许永远不会出现在现实世界。因此现实世界中经常使用启发式算法来解决问题。启发式算法是否有效取决于其对问题的适应性、避免陷入局部最优的策略以及对问题基本结构的了解程度。另外，算法重启的程序、可控制的随机性、有效的数据结构及预处理也会帮助其获得合理正确的解^[4]。

早在1996年，Bensana E等^[5]就尝试用启发式算法对遥感卫星进行规划，并且在SPOT-5调度问题中，比较了完全搜索算法(深度优先搜索、动态规划)和非完全搜索算法(贪婪搜索、禁忌搜索)在不同规模问题实例下的计算性能。而Potter W等^[6]采用了另外一种思路，在Landsat-7调度系统中首先按照最早结束时间贪婪安排所有的观测需求，然后基于优先级替换已安排的观测需求和未安排的观测需求，得到了较好的结果。2002年，Jeremy在模型求解中基于Europa系统实现了一个基于随机搜索的启发式算法，但是随机搜索有局限性，目前还只能对较小规模的调度问题求解，所以Dilkina B等^[7]运用基于含约束传播的排列搜索

方法解决灵巧观测卫星的任务规划问题，并将其与爬山算法、模拟退火算法进行了比较，使调度问题的规模得以扩大。后来，Aldinger J等^[8]在解决单颗灵巧对地观测卫星的对地覆盖任务时，采用了基于启发式算法的规划器时间快速下降模块 (Temporal Fast Downward with Modules, TFD/M)，这种规划器用TFD来处理一般的逻辑和时序规划，将轨道控制、姿态调整等方面的约束外包给一个单独的计算模块来处理^[8]。

2.2.2 专家系统

专家系统是人工智能的一个重要分支，是一个具有大量的专门知识和经验的程序系统，它应用人工智能和计算机技术，根据某领域一个或多个专家提供的知识和经验，提供推理和判断，模拟人类专家的推理过程，以便解决那些需要人类专家处理的复杂问题，换句话说，专家系统是一种模拟人类专家解决领域问题的计算机程序^[9]。

调度专家系统可以产生复杂的启发式规则，利用定性和定量知识，具有一定的智能性。但是开发周期长、费用昂贵且所需的经验和知识难以获取，同时专家系统的学习能力有限，所以专家系统在任务规划中的发展前景并不被看好，且其常与其他算法混合使用^[10]。

专家系统常用于多星综合任务规划。文献[11]针对成像卫星任务规划与调度问题，结合多星多地面站的特点，设计并实现了一个结合了模型库的任务规划专家实验系统。文献[12]主要基于综合任务规划，以应用需求为指导，在分析成像卫星综合任务规划问题的基础上，提出了一种基于专家决策支持技术的解决方案，并且针对该专家决策支持系统，设计了知识库模块和解释机制，将关系数据库和专家系统相结合，还将多准则决策模型引入专家系统，将多准则评价模型用于专家系统的第三级推理。刘晓娣^[13]具体研究了多卫星综合任务规划关键技术，针对多卫星综合任务规划问题，采用可扩展性的星地资源组织方式，引入基于规则推理的专家系统，采用专家推理与模型决策相结合的综合任务规划方式，构

建了多卫星综合任务规划的总体框架，并且设计了综合任务规划专家系统结构，研究了专家系统中的知识表示方法，以语义网络表示事实，以产生式规则表示专家知识。杜莹^[14]对面向卫星任务规划的专家系统的知识表示方法、推理机制和解释机制等关键技术进行了深入研究，后又提出了基于C语言集成产生式系统 (C Language Integrate Dproduction System, CLISP) 的卫星任务规划专家系统的设计方法，详细分析了系统的结构和功能，重点讨论了中文产生式系统的巴科斯范式 (Bachus Naur Form, BNF)、基于上下文的推理机制和集合运算符^[15]。由于专家系统学习能力有限，常与其他算法混合使用，文献[16]采用了先通过专家系统进行遥感卫星的工作模式推理，再基于解修正的遗传算法完成卫星资源优化分配的两阶段机制，设计了基于面向服务的架构 (Service-Oriented Architecture, SOA) 遥感卫星任务规划系统 (RS⁴BS) 框架，取得了很好的效果。

2.2.3 基于Agent的规划调度方法

对Agent和多智能体系统 (Multi-Agent System, MAS) 的定义有很多，广义上，Agent是指具有一定的自主行为或智能特征的实体；MAS也称作多智能体系统，指由多个Agent构成的系统。Agent和MAS的方法是面向一定的任务目标，依据其它Agent以及周围环境的状态，并基于自身状态决策机构来规划实施的。Agent有能力与其它Agent协作解决共同面临的问题。基于MAS的决策和控制方法能够集成许多传统的和现代模型，包括人工智能和非人工智能模型。由于智能遥感任务规划是一个异常复杂而庞大的系统，MAS有着极强的协作求解问题的能力，于是随着软件Agent和MAS理论方法的引入，它已成为任务规划的主要技术途径，其前景被普遍看好，同时也是当前在轨运行和计划的各类空间系统中运用最多的一项综合性技术^[17]。

文献[18]对基于Agent调度方法的任务规划进行理论分析，将卫星按照其智能水平的高低分成4个层次的Agent，成像卫星作为其中的第一个

层次。张正强等^[19]建立了该方法的具体模型,根据分布式成像卫星系统的分布性和智能性特点,采用Agent及多Agent系统,即MAS的思想,给出了一种高可靠性的分布式成像卫星系统MAS结构及智能成像卫星Agent的分层混合结构模型,并提出了基于多Agent协商的分布式动态任务规划方法。由于实际中经常会出现各个卫星延迟通信的状况,文献[20]针对通信延迟条件下的卫星协同优化决策问题,建立了卫星协同优化决策模型,提出了适应延迟通信的统一处理策略,设计了卫星优化策略的搜索方法,建立了一种面向动态任务的多星混合学习框架,提出了任务不变条件下的任务分配策略算法和任务变化条件下的增量策略迁移学习算法。王海蛟^[21]提出了一种基于强化学习的卫星规模化在线调度方法,针对分布式结构下卫星在线调度问题,建立了一种基于马尔科夫游戏的卫星在线调度模型。2018年,北京航空航天大学公开了人工智能程序员书写天上遥感任务规划Agent程序的方法,使程序的使用得以公开化^[22]。

2.2.4 神经网络的方法

神经网络是指从信息处理角度对人脑神经网络进行抽象,建立某种简单模型,按不同的连接方式组成不同的网络。通过训练集对神经网络进行训练,从数据中学习一定规律,从而计算出解决问题的方法,并对下一步进行有效预测。如何训练神经网络是技术的关键所在。

2006年,神经网络的学习技术(深度学习)被提出,相比传统方法,深度学习的效果大幅提高。2008年,朱战霞^[23]用Hopfield神经网络算法对单个仪器的任务规划问题进行了研究,构造了一个由256个神经元构成的Hopfield对地观测网络,用以表示不同时间和不同观测目标的任务规划。而后,邢立宁等^[24]又结合实际情况进行了完善,在分析实际影响成像卫星任务执行因素,如任务重叠度、任务收益、气象信息等基础上,设计了一种基于BP神经网络的星上任务可调度性预测方法,并设计多个不同算例验证其效果。由于

神经网络前期较差的效果,以及深度学习兴起较晚,神经网络在任务规划中的应用较少,但前景依然可期。

2.2.5 遗传算法、模拟退火法和禁忌算法

遗传算法、模拟退火法和禁忌算法在本质上都属于全局算法,但都具有随机性,即可能得到全局最优解或得到一个较好的局部最优解。它们都模拟了自然过程,遗传算法借鉴了自然界优胜劣汰的进化思想,模拟退火法源于物理学中固体物质的退火过程,禁忌算法模拟了人类有记忆过程的智力过程,三种算法最大的区别在于跳出局部解的策略不同。

三种算法之间经常结合使用,比如模拟退火和遗传算法相结合形成的模拟退火遗传算法,就把它有机地结合在一起,取长补短,使得性能更加优良。虽然这三种方法都有明显的缺陷,但若灵活地运用它们,依然能很好地完成规划任务^[25]。例如文献[26]在对地观测卫星任务规划中使用遗传算法和贪婪算法相结合的方法,从而改进贪婪算法的缺点。Globus A等^[27]比较了爬山法、模拟退火和遗传算法等求解方法在点目标的成像卫星调度问题中的表现,发现在使用单独的一种算法时,模拟退火算法求解质量最好。但是在选择算法时应该考虑问题的规模,文献[28]比较了禁忌搜索算法和列生成法在面向点目标的多星联合调度问题中的表现。实验表明采用列生成法进行求解能够获得小规模问题的最优解,当问题规模变大时,采用禁忌搜索算法更适合。阮启明等^[29]又对问题进行了分级处理,根据问题模型中采用分级的两层优化目标特点,采取最大化整体收益优先于最小化观测成本的分级优化策略,设计了贪婪随机变邻域搜索、禁忌搜索和模拟退火等求解算法,并对这些算法的性能进行了比较和分析,得出以贪婪随机变邻域搜索算法得到的解作为初始解的禁忌搜索过程综合表现最好的结论。随着人们对算法的不断完善和更新,算法也呈现出新的内容,文献[30]应用了新的遗传算法模拟实际卫星任务调度问题,并创建了用

于自主卫星任务的图形用户界面 (Graphical User Interface, GUI) 设计。

3 智能遥感数据分类研究现状

3.1 观测卫星图像数据处理流程

遥感信息图像处理主要包括图像分类、图像分割、特征识别等过程，具体的图像数据处理流程如图 1。




图1 图像数据处理的流程

Fig.1 Flow chart of image data processing

(1) 根据任务对图像进行相应的预处理。这是影像处理流程中非常重要的环节，一般包括去噪、波段叠加与分离、影像增强、辐射校正、几何校正、影像裁剪、影像镶嵌、影像融合等。通过预处理可以改善图像质量，增强图像的视觉效果，将图像转换成一种更适合于人或机器进行分析处理的形式，为其后面的进一步处理分析工作奠定基础。

(2) 定义相关的、感兴趣的地物类别并标记训练样本。根据图像数据特性以及分类目的，选取合适的三个波段合成的伪彩色图像，然后从获取的训练样本数据集中提取出需要分类的地物目标类型，分别找出分类类型对应的特征量。

(3) 特征提取。同类物质样本的分布具有密集性，在特征空间中分隔不同类别的地物样本，关键是从原始特征中选取出一组最能反映其类别的新特征。

(4) 特征选择。特征选择的要求是在不损失原始数据有用信息的条件下，选择部分有效特征，同时抛弃多余特征，具体过程是依据原始波段图像的测量值，按照分类需要经过特定变换，构建一组能够有效描述地物类别特征的模式。

(5) 像元分类。选取适当的分类器及其判断准则，对未知区域的样本进行类别归属的判断，即对像元进行类别划分。方法大致分为监督分类和无监督分类两种，受使用不同分类方法的影响，取得的分类效果会存在一定的差异。

(6) 精度分析。分类结束后，图像类别信息都已确定，将整幅图像标记为相应的类别输出，比较已知类别的数据与分类结果，对分类精度进行判定^[31]。

无论目标提取、影像分类还是变化检测，核心都是利用地物的特征差异性，通过某种变换或处理手段，使有特征差异的点分离开来，地物的特征差异表现在光谱特征和空间特征上^[32]。目前图像处理存在的问题主要有空间分辨、光谱分辨率和时间分辨率不高，对数据利用不充分等。

3.2 智能遥感图像数据处理方法

目前人工智能技术在遥感图像处理方面的算法主要有决策树、神经网络、支持向量机方法以及深度学习方法等，这些分类算法可以提高图像处理的精度，更好地完成任务。

3.2.1 决策树方法

决策树方法是一种以特征值作为基准值分层逐次进行比较归纳的分类方法。它具有树形结构，其叶节点代表类的分布，内部节点代表对某个属性的一次测试，每条分支代表一次测试结果。整颗树采用递归构造方法，测试从根节点开始，对每个非叶节点对应的样本集进行测试，根据不同的属性值引出该节点的向下分支，直到某一节点只包含同一类别的样本或样本集没有特征进行再分时停止。用决策树进行图像分类时，训练样本速度快；结构简单直观，便于用户理解；且除了训练样本数据集中包含的信息外不需要其他领域知识融入；同时决策树分类主观操作性强，根据先验知识及经验，可以确定或调整各个属性之间的权重关系（重要性）或地物分类先后层次关系。决策树的构造结果可以是一棵二叉的或多叉的构造，因此在高光谱图像分类中，二叉决策树作为

决策树的一种特殊形式，因其简单灵活的构造被广泛应用。

然而决策树依然存在一些缺点，如：对连续性的字段比较难预测，对有时间顺序的数据需要很多预处理的工作；可重复性较强，在树结构的构造过程中反复地读取数据、顺序扫描和排序训练样本数据集，影响算法的效率；且只要在树结构的其中某一个节点处出现误差，都会随着树结构的分枝传递下去^[33]。

决策树用于对地观测始于20世纪90年代，1996年，Hansen M^[34]采用决策树的方法，通过对年全球遥感数据的分类处理，得到了全球土壤覆盖分类图。同年，Tadjudin S等^[35]提出了利用基于使两个子类统计距离最大化的特征提取技术构造的复合决策树。1997年，Friedl M A^[36]总结了多种决策树方法，将它们应用于遥感数据中并进行比较与改进。为了进一步提高精度，2000年，Palaniappan K等^[37]提出了一种加强二叉树遗传算法进行地表覆盖的自动分类并得到了90%的分类精度^[37]。随着模糊理论的兴起，Bruzzo M等^[38]提出了整合二叉决策树和模糊分类技术，并将其用于遥感图像数据库的搜索机制。在提高了决策树的精度以后，文献[39]又提出了一种Peano Count Tree，相比一般决策树，在处理越来越多的空间数据时，处理效率大大提高，从而节省了大量时间。文献[40]使用两种决策树CART和C4.5，对中国东北250m分辨率的数据进行土地覆盖和分类研究，并且比较了两种决策树的特点。由于高光谱图像中常存在混合像素，文献[41]采用纯像素指数（PPI）在选择各种样本时提取端元作为训练样本，进行决策树训练，解决了混合像素的问题。

3.2.2 神经网络方法

神经网络与传统算法相比，在进行图像分类时，无须考虑像元分布特征，此外它还广泛应用于多源遥感数据分类。与其在遥感卫星任务规划领域应用类似，神经网络在遥感数据处理中的应用兴起较早，且伴随着深度学习的出现焕发了新的生机。

早在1994年，Abuelgasim A等^[42]研究了人工神经网络方法在对土地覆盖数据进行分类的有效性，提出了一种结合了Kohonen的自组织网络和反向传播模型的神经网络模型。同年，Chiuderi A等^[43]将神经网络用于执行主题测绘仪（Thematic Mapper, TM）数据与合成孔径雷达（Synthetic Aperture Radar, SAR）数据的融合，获得了佛罗伦萨（意大利）周围的农业区域的土地覆盖分类，提出并使用了两种不同的NN体系结构，即反向传播网络和Kohonen映射，报告并讨论了两种情况下获得的结果。这两种方法还不适用于大量的航空航天图像的处理，文献[44]指出了一种航空航天图像的高性能分类方法，即使用地理信息系统（Geographic Information System, GIS）空间数据作为输入和输出数据，使用神经网络对被研究类物体的光谱和空间图像进行建模。神经网络也常与其他算法结合使用，文献[45]利用人工神经网络和遗传算法相结合的方法，探讨了降雨在台湾东部的土地利用和山体滑坡之间的关系。文献[46]将基于轮廓的方法和Hopfield神经网络两种分类方法结合，产生一种基于轮廓的Hopfield神经网络（Contour-Based Hopfield Neural Network, CHNN）的新方法。在进行特征提取时，常采用降维提取的方法，文献[47]将自联想神经网络（Auto-Associative Neural Network, AANN）用于实现降维高光谱数据的非线性主成分分析中。文献[48]通过自动关联神经网络执行用于高光谱数据的降维的特征提取，将算法性能与主成分分析和最大噪声分数进行比较，并报告了由减少的矢量和专用神经网络分类算法产生的陆地覆盖基于像素的地图结果。

3.2.3 深度学习方法

深度学习是机器学习研究中的一个新的领域，其动机在于建立、模拟人脑进行分析学习的神经网络，其模仿人脑的机制解释数据，例如图像、声音和文本^[49]。深度学习在遥感图像分类中的应用兴起很晚但由于其效率高、准确度高，因此发展迅速，受到了广大研究者的青睐。

2014年, 深度学习的概念首次被引入到高光谱数据分类中, 构建了一个包含主成分分析(Principal Component Analysis, PCA)、深度学习和逻辑回归的混合体学习框架^[50]。2015年, Makantasis K等^[51]利用卷积神经网络对像素的光谱和空间信息进行编码, 并利用多层感知器进行任务分类, 自动提取图像特征。但是以上方法均由于标记数据有限, 容易产生过拟合问题, 文献[52]提出先设计预训练卷积神经网络(Convolutional Neural Networks, CNN)提取一组初始值, 并将其和其类标签一起用于受监督的CNN分类器中, 从而更有效地训练系统, 有效地解决了过拟合问题。为了提高分类精度, 文献[53]提出了一种包含主成分分析、深度置信网络和逻辑回归的深度神经网络, 将光谱空间和分类相结合, 大大提高了分类精度。但上述方法对标记样本依赖程度较高, 因此文献[54]提出了一种基于加权增量字典学习的主动深度学习算法, 算法通过在每次迭代中主动选择训练样本有效地训练深度网络, 从而减少了对高质量的标记样本的依赖。深度学习中的深度卷积神经网络常用于图像分类领域, 同时, 高空间分辨率图像逐渐成为图像分类方法中的主要对象。2017年, Nicholus M等^[55]使用CNN学习判别空间特征, 在非常高分辨率的卫星图像中提取信息, 自动识别不同的城市类别。文献[56]研究了深度卷积神经网络(Deep Convolutional Neural Networks, DCNNs)在遥感影像分类中的应用, 分别设计了一种复数域的DCNNs模型以及一种端到端的DCNNs模型。后又不断扩展图像分类的光谱带和准确度, 文献[57]提出了一种基于Sentinel-2卫星图像, 涵盖了13个不同的光谱带、10个类别和27000个标记图像的全新数据集, 在此数据集使用卷积神经网络达到了98.57%的分类准确度。

4 结束语

遥感一词最早由美军海军科学部提出, 后在

1961年正式被采纳, 经过半个多世纪的发展, 遥感技术已广泛应用于工业、农业、气象、水文、环保、地质、海洋等各个领域。人工智能的发展非常迅猛, 是当今研究的几大热点之一, 将人工智能技术应用于遥感, 未来遥感卫星的任务规划必将越来越少的依赖人工规划与计算, 变得自主化与智能化, 能独立地处理问题和应对挑战。未来遥感图像的空间分辨率、光谱分辨率和时间分辨率都将大幅提高, 人类可以更准确、快速地对遥感图像进行处理, 相信人工智能终有一天会代替传统技术, 成为对地观测中最关键的科技手段。当前人工智能在遥感技术的应用呈现出百花齐放的特点, 不同的学者针对不同的应用采用不同的方法, 一定程度上实现了遥感任务规划和遥感数据处理。但这些研究具有很大的局限性, 面向的任务单一, 工程应用的成熟度不足, 还很难达到智能遥感的需求。在工程应用上, 各航天大国正在开展广泛而深入的研究, 实现遥感技术的智能化和自主化成为未来智能航天的重要方面。

参考文献

- [1] 马建文, 田国良, 王长耀, 等. 遥感变化检测技术发展综述[J]. 地球科学进展, 2004(02):192-196.
- [2] 王海波. 不确定条件下天地测控资源一体化调度问题研究[D]. 哈尔滨: 哈尔滨工业大学, 2012.
- [3] 薛志家. 对地观测卫星自主任务规划技术研究[D]. 南京: 南京航空航天大学, 2015.
- [4] 孙凯. 基于启发式算法的成像卫星星地联合调度问题研究[D]. 长沙: 国防科学技术大学, 2008.
- [5] Bensana E, Verfaillie G, Agnese J, et al. Exact & INEXACT methods for daily management of earth observation satellite[J]. 1996.
- [6] Frank J, Ari Jónsson, Morris R, et al. Planning and scheduling for fleets of earth observing satellites[J]. Proceedings of Sixth Int. symp. on Artificial Intelligence Robotics Automation & Space, 2001.
- [7] Dilikina B, Havens B. Agile satellite scheduling via permutation search with constraint propagation[R]. Actenum Corporation, Vancouver, British Columbia. 2005.

- [8] Aldinger J, Löhr J, Planning for agile earth observation satellites [C]. The Proceedings of the ICAPS-2013 Workshop on Planning in Continuous Domains, Rome, Italy, 2013.
- [9] 毕学工, 杭迎秋, 李昕, 等. 专家系统综述 [J]. 软件导刊, 2008 (12):7-9.
- [10] 余建军, 张定超, 周铭新. 生产调度研究综述 [J]. 机械设计与制造工程, 2009, 38 (17):13-17.
- [11] 陈慧中. 成像卫星任务规划调度机制与辅助决策技术研究 [D]. 长沙: 国防科学技术大学, 2005.
- [12] 高恒振. 成像卫星综合任务规划专家决策支持技术研究 [D]. 长沙: 国防科学技术大学, 2006.
- [13] 刘晓娣. 多卫星综合任务规划关键技术研究 [D]. 长沙: 国防科学技术大学, 2007.
- [14] 杜莹. 面向卫星任务规划的专家系统应用技术研究 [D]. 长沙: 国防科学技术大学.
- [15] 杜莹, 陈浩, 李军, 等. 基于CLIPS的卫星任务规划专家系统设计 [J]. 计算机工程与科学, 2009, 31 (12):138-141.
- [16] 谷宏志. 基于SOA的遥感卫星任务规划框架设计 [J]. 无线电工程, 2014 (12).
- [17] 王沛, 谭跃进. 卫星对地观测任务规划问题简明综述 [J]. 计算机应用研究, 2008, 25 (10):2893-2897.
- [18] Schetter T P, Campbell M E, Surka D M. Multiple agent-based autonomy for satellite constellations [C]. Second International Symposium on Agent Systems and Applications and Fourth International Symposium on Mobile Agents, 2000.
- [19] 张正强. 基于MAS的分布式成像卫星系统任务规划与控制问题研究 [D]. 长沙: 国防科学技术大学, 2006.
- [20] 王冲. 基于Agent的对地观测卫星分布式协同任务规划研究 [D]. 长沙: 国防科学技术大学, 2013.
- [21] 王海蛟. 基于强化学习的卫星规模化在线调度方法研究 [D]. 北京: 中国科学院大学, 2018.
- [22] 人工智能程序员书写天上遥感任务规划Agent程序方法: 中国, 01129210.5 [P/OL]. 2018. <http://www.vipzhuanli.com/pat/books/201810290518.1/2.html>.
- [23] 朱战霞, 杨博, 袁建平. 人工智能在卫星任务规划中的应用 [J]. 飞行力学, 2008, 26 (1):79-82.
- [24] 邢立宁, 王原, 何永明, 等. 基于BP神经网络的星上任务可调度性预测方法 [J]. 中国管理科学, 2015 (s1):117-124.
- [25] 肖美华, 王命延, 王洪发, 等. 基于遗传算法和模拟退火算法的布局问题研究 [J]. 计算机工程与应用, 2003, 39 (36):70-72.
- [26] Wolfe W J, Sorensen S E. Three scheduling algorithms applied to the earth observing systems domain. [M]. INFORMS, 2000.
- [27] Globus A, Crawford J, Lohn J, et al. A comparison of techniques for scheduling earth-observing satellites [C]. Conference on Nineteenth National Conference on Artificial Intelligence, 2004.
- [28] 贺仁杰. 成像侦察卫星调度问题研究 [D]. 长沙: 国防科学技术大学, 2004.
- [29] 阮启明. 面向区域目标的成像侦察卫星调度问题研究 [D]. 长沙: 国防科学技术大学, 2006.
- [30] Baek S W, Han S M, Cho K R, et al. Development of a scheduling algorithm and GUI for autonomous satellite missions [J]. Acta Astronautica, 2011, 68 (7-8):1396-1402.
- [31] 万余庆, 谭克龙, 周日平. 高光谱遥感应用研究 [M]. 北京: 科学出版社, 2006.
- [32] 翁代云, 杨莉. 人工智能技术在遥感图像分类中的应用 [J]. 计算机仿真, 2012 (6):240-243.
- [33] 申文明, 王文杰, 罗海江, 等. 基于决策树分类技术的遥感影像分类方法研究 [J]. 遥感技术与应用, 2007, 22 (3):333-338.
- [34] Hansen M, Dubayah R, Defries R S. Classification trees: An alternative to traditional land cover classifiers [J]. International Journal of Remote Sensing, 1996, 17 (5):1075-1081.
- [35] Tadjudin S, Landgrebe D A. A decision tree classifier design for high-dimensional data with limited training samples [C]. International Geoscience & Remote Sensing Symposium, 1996.
- [36] Friedl M A, Brodley C E. Decision tree classification of land cover from remotely sensed data [J]. Remote Sensing of Environment, 1997, 61 (3):399-409.
- [37] Palaniappan K, Zhu F, Zhuang X, et al. Enhanced binary tree genetic algorithm for automatic land cover classification [C]. IEEE International Geoscience & Remote Sensing Symposium, 2000.
- [38] Bruzzo M, Dellepiane S, Vaccaro R. Content fuzzy learning for remote sensing image database systems [C]. IEEE International Geoscience & Remote Sensing Symposium, 2001.
- [39] Ding Q, Ding Q, Perrizo W. Decision tree classification of spatial data streams using peano count trees [C]. Acm Symposium on Applied Computing, 2002.

- [40] Wang C Y, Du Z T, Liu Z J, et al. Study on Decision Tree Land Cover Classification Based on MODIS Data [C]. International Workshop on Earth Observation & Remote Sensing Applications, 2008.
- [41] Li S L S, Zhang B Z B, Gao L G L, et al. Classification of coastal zone based on decision tree and PPI [C]. Geoscience & Remote Sensing Symposium, 2010.
- [42] Abuelgasim A, Gopal S. Classification of multiangle and multispectral ASAS data using a hybrid neural network model [C]. International Geoscience & Remote Sensing Symposium, 1994.
- [43] Chiuderi A, Fini S, Cappellini V. An application of data fusion to landcover classification of remote sensed imagery: a neural network approach [M]. 1994.
- [44] Salahova S. Remote Sensing and GIS Application for Earth Observation on the base of the Neural Networks in Aerospace Image Classification [C]. International Conference on Recent Advances in Space Technologies. IEEE, 2007.
- [45] Chen Y R, Ni P N, Chen J W, et al. The application of remote sensing technology to the interpretation of land use for rainfall-induced landslides based on genetic algorithms and artificial neural networks [J]. IEEE Journal of Selected Topics In Applied Earth Observations And Remote Sensing, 2009, 2 (2):87-95.
- [46] Su Y F, Foody G M, Muad A M, et al. Combining hopfield neural network and contouring methods to enhance super-resolution mapping [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5 (5):1403-1417.
- [47] Licciardi G, Frate F D, Duca R. Feature reduction of hyperspectral data using Autoassociative neural networks algorithms [C]. Geoscience & Remote Sensing Symposium, 2009.
- [48] Licciardi G, Del Frate F, Schiavon G, et al. Dimensionality reduction of hyperspectral data: Assessing the performance of Autoassociative Neural Networks [C]. Geoscience & Remote Sensing Symposium, 2010.
- [49] 郭元祥. 深度学习:本质与理念 [J]. 新教师, 2017 (7):11-14.
- [50] Abuelgasim A, Gopal S. Classification of multiangle and multispectral ASAS data using a hybrid neural network model [C]. International Geoscience & Remote Sensing Symposium, 1994.
- [51] Makantasis K, Karantzas K, Doulamis A, et al. Deep supervised learning for hyperspectral data classification through convolutional neural networks [C]. Geoscience and Remote Sensing Symposium (IGARSS), 2015 IEEE International, 2015.
- [52] Marmanis D, Datcu M, Esch T, et al. Deep learning earth observation classification using imageNet pretrained networks [J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13 (1):105-109.
- [53] Chen Y, Zhao X, Jia X. Spectral - spatial classification of hyperspectral data based on deep belief network [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8 (6):1-12.
- [54] Liu P, Zhang H, Eom K B. Active deep learning for classification of hyperspectral images [J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2016, 10 (2):712-724.
- [55] Nicholus M, Claudio P, John B, et al. Detection of informal settlements from VHR images using convolutional neural networks [J]. Remote Sensing, 2017, 9 (11).
- [56] 王海军. 深度卷积神经网络在遥感影像分类的应用研究 [D]. 北京: 中国地质大学, 2018.
- [57] Helber P, Bischke B, Dengel A, et al. Introducing euroSAT: a novel dataset and deep learning benchmark for land use and land cover classification [C]. IEEE International Geoscience and Remote Sensing Symposium, 2018.

作者简介:

陈 昕(1998-), 女, 本科生, 主要研究方向为人工智能与自动化。

刘昌昊(1995-), 男, 硕士研究生, 主要研究方向为人工智能与航天应用、航天器机电一体化。

陈培永(1986-), 男, 硕士, 工程师, 主要研究方向为对地观测卫星。

华 春(1983-), 男, 本科, 工程师, 主要研究方向为情报研究。

刘廷芳(1986-), 男, 博士, 副教授, 主要研究方向为人工智能技术在航天领域的应用、智能材料与结构、航天器力学环境模拟于天地一致性等。

特约主编寄语

随着智能化、自主化水平的不断提升，无人系统的应用范围和价值逐渐突显，无论是军事领域还是民生领域，都有着切实的落地。在解放了劳动力的同时，大大提高了完成任务的效率、质量和可靠性。

空间作为人类探索未知世界、开展地外探测活动的主要对象，逐渐成为世界各国研究的重点。空间无人系统更是在整个过程中起到了关键的作用，从第一颗人造卫星发射，到全球星座系统部署构建，从阿波罗登月到好奇号火星之旅，从空间站组装运行到在轨服务任务开展，几乎所有的空间探测任务都或多或少有着无人系统的参与，它为任务的完成、目标的实现提供了有效的支撑。故对空间无人系统技术的研究势在必行、意义深远。

展望未来，具有智能化、自主化的空间无人系统是下一步技术发展的必然趋势，它将会对空间探测任务、探测模式以及探测意义做出巨大的改变。希望通过所有科技工作者的共同努力，早日实现我国空间无人系统的智能化建设，为后续的空间任务提供强有力的保障。

郭继峰



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 王飞跃

第 一 届 编 委 会

主 任

李风雷

副主任

王长青 宋 斌 谷满仓 张 涛 符文星

委 员 (按姓氏拼音排序)

昂海松 蔡顺才 陈 斌 陈家斌 戴江勇 邓宏彬 都基焱 方 浩 符小卫 郭继峰 黄 强
黄长强 李必军 李东光 李贻斌 林 平 刘 莉 刘培志 罗 均 马洪忠 孟 红 孟凡彬
潘 泉 齐俊桐 时兆峰 田大新 王宏伦 韦锦峰 吴向阳 夏元清 向锦武 徐 昕 徐海刚
薛建儒 颜国正 杨 宁 杨宏晖 于进勇 于林宇 赵 杰 张 梅 张 宁 张 山 张冬青
张卫平 朱 枫 朱小燕 Simon X.YANG Wei Ren Yang SHI Yantao Shen

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)

中国指挥与控制学会无人系统专业委员会

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: 010-68190652 (编辑部)

010-68375084 (发行部)

邮 箱: chinauas310@163.com

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

Unmanned Systems Technology Started in 2018 (Bimonthly)

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

Technical Committee on Unmanned Systems, CICC

Research Center for Unmanned System Strategy

Development, NWPU

Unmanned System Research Institute, NWPU

Editor-in-Chief: ZHANG Dongqing

Associate Editor: CAI Shuncai 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) 68190652 (Editorial office)

(8610) 68375084 (Circulation office)

E-mail: chinauas310@163.com

Distributed by: Beijing HIWING Scientific and Technological Information Institute

Printed by: Beijing BOHS Colour Printing Co., Ltd.

本期责任编辑: 李 志

ISSN 2096-5915

CN 10-1565/TJ

国内定价: 30.00元/期

