

基于 C-TOF 成像的位姿测量与地物目标识别技术研究

卢纯青¹, 杨孟飞², 武延鹏¹, 梁 满¹

(1. 北京控制工程研究所, 北京 100080; 2. 中国空间技术研究院, 北京 100094)

摘要: 深空探测器的功耗和体积有限, 任务工况多样, 与低轨道地球探测器相比, 深空探测器对导航敏感器的任务能力提出了更高的要求。提出了一种基于飞行时间成像的快速位姿测量和地物目标识别技术。为了在保证位姿测量精度的前提下满足对位姿测量时间性能的需求, 提出了一种基于深度信息的动态尺度估计方法。该方法提升了物方多尺度变化条件下点云配准的时间稳定性, 平均配准时间缩短 60% 以上, 平均配准精度约为 0.04 m。为了满足多尺度、多形态地物目标识别的需求, 使用了基于轻量化深度神经网络, 可根据场景深度信息进行地物检测。结果表明, 该方法可对地物特征进行快速感知, 在真实场景中的准确率达到 70% 以上。

关键词: 深空探测; 飞行时间成像; 正态分布变换; 语义分割

中图分类号: TP391.41 **文献标志码:** A **DOI:** 10.3788/IRLA202049.0113005

Research on pose measurement and ground object recognition technology based on C-TOF imaging

Lu Chunqing¹, Yang Mengfei², Wu Yanpeng¹, Liang Xiao¹

(1. Beijing Institute of Control Engineering, Beijing 100080, China;

2. China Academy of Space Technology, Beijing 100094, China)

Abstract: Deep space probes have limited power consumption and volume, and have diverse mission conditions. Compared with low-orbit earth probes, deep space probes have higher requirements for the mission capabilities of navigation sensors. This paper proposed a fast pose measurement and ground object recognition technology based on time-of-flight imaging. In order to meet the time requirements of pose measurement under the premise of ensuring the accuracy of pose measurement, a dynamic scale estimation method based on depth information was proposed. This method improved the temporal stability of point cloud registration under multi-scale object-side changes. The average registration time was reduced by more than 60% and the average registration accuracy was about 0.04 m. In order to meet the needs of multi-scale and multi-morph object recognition, a light-weight deep neural network was used to detect ground objects based on scene depth information. The results show that this method can quickly perceive the features of ground features, and the accuracy rate is more than 70% in real scenes.

Key words: deep space exploration; time-of-flight imaging; normal distribution transformation; semantic segmentation

收稿日期: 2019-05-05; 修订日期: 2019-06-15

基金项目: 十三五预研基金

作者简介: 卢纯青(1988-), 男, 工程师, 博士, 主要从事空间成像感知与智能导航控制技术方面的研究。Email: cust0702@sina.com

0 引言

深空探测是近年来空间技术领域的热点方向。各国相继开展月球^[1]、火星^[2]、小行星^[3-4]等天体的探测活动,任务场景的未知信息逐渐增加,任务风险逐渐增大。与近地轨道(LEO)任务相比,深空探测任务存在通讯延时长、数据传输带宽低、任务耗时长、空间环境风险高等问题,因此对航天器的导航精度、任务能力、执行机构的可靠性均提出了更高的要求。对于位姿测量和目标识别需求,目前应用较为广泛的解决方案有基于单目视觉的方法、基于双目视觉的方法和基于扫描式激光雷达的方法,但上述方法在测量精度、实时性和可靠性方面存在一定限制。文中提出了一种基于 C-TOF 成像的动态尺度位姿估计方法和基于轻量化神经网络的物识别算法,具备现在轨实时位姿测量和物识别的能力,对提升深空探测器在轨智能化具有重要研究意义和工程应用价值。

1 飞行时间成像原理与特点

目前飞行时间成像方法可分为脉冲式(D-TOF)和连续调制式(C-TOF)两大类^[5]。脉冲式飞行时间成像获取点云的空间形式非结构化,点云的数据量具有不确定性。由于目前数据获取形式一般为串行方式,因此在高动态场景中使用容易产生运动畸变。连续调制式飞行时间成像通过并行方式获取深度数据,点云的形式为结构化点云,点云的数据量由成像器件的硬件参数决定,硬件参数一旦确定,点云的数据量即可确定,成像系统的数学模型可由经典二维成像系统的数学模型扩展^[6]。两类点云的典型形式如图 1 所示。虽然连续调制式激光固态成




图 1 脉冲扫描式激光点云(a)与连续调制式激光点云(b)
Fig.1 Pulse scanning laser point cloud (a) and continuous modulation laser point cloud (b)

像传感器的势阱型像元结构导致其误差来源多于脉冲式激光扫描成像方法^[7]。但与非结构化点云相比,结构化点云的优势在于其数据更新频率较高且为并行输出,可满足实时性要求较高的应用场景,提高了数据预处理效率,便于点云相关算法的应用。

2 基于点云配准的位姿测量

2.1 点云配准技术

目前点云配准技术可分为基于局部特征的方法、基于全局特征的方法、基于全局搜索的方法和基于统计的方法四种类型。基于局部特征的方法比较典型的是基于快速点特征直方图(FPFH)^[8],该方法通过计算点云中每个数据点邻域的直方图特征确定两个点云中数据点之间的对应关系计算变换矩阵;基于全局特征的经典算法是四点法,通过选取点云中共面的四个点对,利用空间结构的仿射不变性求解变换矩阵;基于全局搜索的经典算法是迭代最近点算法(ICP)^[9-10],该算法在两个点云之间随机选取几何特征一致的点组成点对,计算对应点对之间的变换关系获得变换矩阵,该方法的配准精度最高,但需要建立点云的树形结构便于搜索对应点,在未知动态场景中实时性不高且易陷入局部最小值。基于统计模型的经典算法是正态分布变换算法(NDT)^[11],该算法先将点云网格化,根据点云的正态分布确定对应点,计算两个点云之间的变换矩阵。该算法适用于结构化点云。

针对基于飞行时间成像的位姿测量在配准精度和实时性方面的需求,文中提出了一种基于快速点特征直方图(FPFH)和正态分布变换(NDT)的配准方法,点特征直方图用于选取两个点云中的特征点,完成位姿的快速收敛;正态分布变换用于位姿优化,可避免经典 ICP 方法易陷入局部最小值的缺点,同时在预处理中加入下采样,兼顾配准精度、鲁棒性和实时性。

2.2 基于动态尺度点云配准的位姿测量

基于点云的位姿测量算法分为预处理、粗配准和精配准三个阶段。预处理过程由成像系统硬件完成物方数据采集,并对点云进行下采样计算。对于连续调制式飞行时间成像方式,物方数据采集过程是并行完成的。在粗配准阶段,计算空间距离较远的两个

点云之间的坐标变换关系,获得初始变换矩阵 $[R, T]$;精配准算法以初始变换矩阵作为输入,计算精确的变换矩阵 $[R', T']$ 。考虑到对于输出数据的时间延迟的要求,粗配准使用基于点特征直方图的采样一致性初始配准算法,精配准使用正态分布变换算法^[7-8]。算法流程如图 2 所示。

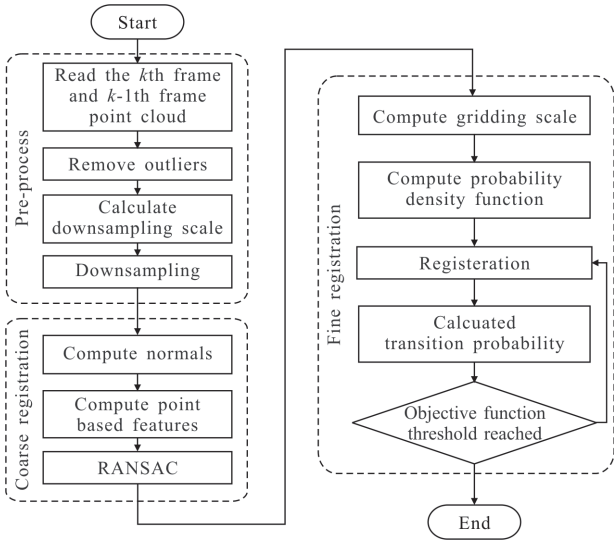


图 2 基于动态尺度的位姿估计流程

Fig.2 Pipeline of pose estimation based on dynamic scale

为了优化配准算法的时间性能,在预处理阶段使用体素滤波器对点云进行下采样计算。对于基于点特征的配准算法,配准过程的大部分时间用于每个点的特征计算。设点云中有 n 个数据点,每个点的邻域中包括 m 个数据点,则计算 FPFH 特征的时间复杂度为 $O(nm)$ 。因此点云进行适当尺度的下采样可以有效提升点云的配准效率。但下采样计算是空间频率域的低通滤波,过于稀疏的点云会损失地形特征,导致迭代算法无法收敛。飞行时间成像具有确定的物方视场 θ ,因此物方空间尺度 L 不断减小,二者之间的关系可用下式表达:

$$L=2 \cdot \tan \frac{\theta}{2} \cdot D \quad (1)$$

式中: D 为视场中心像元的深度值。从公式中可以看到,由于点云的空间尺度不断变化,单一尺度的体素滤波器不能适应物方空间尺度的变化,因此需要引入动态尺度的下采样滤波器。设体素滤波器空间尺度 V 和物方空间尺度 L 之间的比例因子为 γ ,则体素滤波器空间尺度为:

$$V=\frac{1}{\gamma} \cdot 2 \tan \frac{\theta}{2} \cdot D \quad (2)$$

比例因子 γ 由地形特征的最小空间尺度决定。由此体素滤波器尺度 V 由固定值转化为与深度信息耦合的动态参数对点云进行下采样计算,每个体素滤波器内局部点云的空间信息以其三维质心表达。

粗配准阶段包括法线计算、点特征计算和采样一致性配准三个部分。每个数据点的法线通过其邻域点的最小二乘拟合平面估计,可用邻域空间点构建的协方差矩阵的特征值和特征向量计算。得到法线信息后,计算每个数据点的特征直方图,然后根据特征直方图使用采样一致性方法进行对应点的匹配。

精配准阶段的正态分布变换首先将点云网格化,将点云划分为若干个子空间。对于每个子空间的点云,设子空间中有 m 个数据点,则基于子空间内的点计算其概率密度函数^[10]:

$$\vec{\mu}=\frac{1}{m} \sum_{k=1}^m \vec{y}_k \quad (3)$$

$$\Sigma=\frac{1}{m} \sum_{k=1}^m (\vec{y}_k-\vec{\mu})(\vec{y}_k-\vec{\mu})^T \quad (4)$$

其中 $k=1 \cdots m$,则网格的概率密度函数为^[10]:

$$f(\vec{x})=\frac{1}{(2\pi)^{\frac{3}{2}} \sqrt{|\Sigma|}} e^{-\frac{(\vec{x}-\vec{\mu})^T \Sigma^{-1}(\vec{x}-\vec{\mu})}{2}} \quad (5)$$

对于给定的点云 X 和变换矩阵 \vec{p} ,空间转换函数 $T(\vec{p}, \vec{x}_k)$ 表示使用姿态变换 \vec{p} 移动点 \vec{x}_k ,则最优的变换矩阵应使变换后的似然函数达到最大值:

$$\text{Likelihood: } \Theta=\prod_{k=1}^n f(T(\vec{p}, \vec{x}_k)) \quad (6)$$

等价于似然函数的负对数最小化:

$$-\log \Theta=-\sum_{k=1}^n \log(f(T(\vec{p}, \vec{x}_k))) \quad (7)$$

然后使用最优化算法搜索使上述目标函数最小的变换矩阵。

设 C-TOF 成像的空间分辨率为 $M \times N$,即每帧点云有 $M \times N$ 个数据点。对于 ICP 算法,当迭代次数为 D 时,其时间复杂度为 $O(D \cdot MN)$;对于 NDT 方法,算法复杂度集中于求解目标函数中的 Hessian 矩阵,一般使用牛顿法或拟牛顿法计算。设点云划分为 K 个子空间,Hessian 矩阵为 s 阶矩阵,当使用牛顿法时,迭代次数为 D 时的时间复杂度为 $O(D \cdot K \cdot s^3)$,因

此 NDT 方法在时间性能方面优于 ICP 方法。

得到相邻两帧点云的变换矩阵后,可进一步估计传感器在星体固连坐标系中的空间位姿,获得探测器的运动轨迹。设星体固连坐标系为 W 。在初始时刻 t_0 , 传感器坐标系 S_0 在星体固连坐标系下的姿态为 P_0 , P_0 可通过卫星在星体固连坐标系中的位姿进行计算,在 t_1 时刻,传感器坐标系 S_1 在星体固连坐标系中的姿态定义为 P_1 , t_0 时刻和 t_1 时刻传感器获取的两个点云之间变换矩阵为 P_{Trans} , 则根据点云配准变换矩阵, t_1 时刻,传感器在星体固连坐标系的姿态 P_1 为:

$$P_1 = P_0 \cdot P_{Trans}^{-1} \quad (8)$$

设传感器共进行 N 次采样, 则传感器的姿态序列 P 为:

$$P = \{P_0; P_1 \cdots P_N\} \quad (9)$$

2.3 验证结果

用于仿真的点云序列使用 C-TOF 成像系统在模拟着陆半物理仿真平台采集,如图 3 所示。视场中的模拟地形包括岩石、陨石坑和坡度三类典型的地形特征。距离变化范围为 0.5~4 m 之间,传感器视场为 $70^\circ \times 60^\circ$ 。在 4 m 距离传感器的探测区域约为 $7\text{ m} \times 5.8\text{ m}$ 的矩形区域,在 0.5 m 距离传感器的探测区域

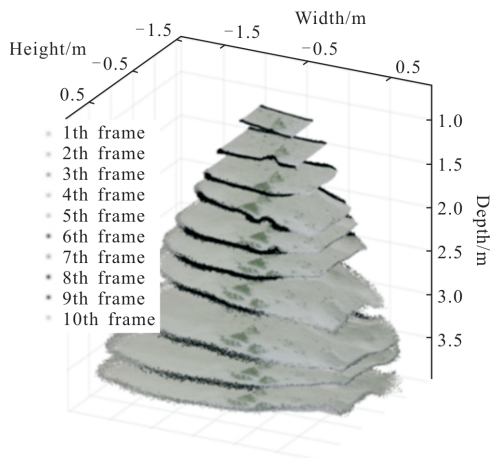


图 3 多尺度地形点云序列

Fig.3 Multi-scale point cloud sequence of terrain

约为 $0.7\text{ m} \times 0.58\text{ m}$ 的矩形区域,物方尺度在上述范围内连续变化。相邻两帧点云配准过程使用粗配准和精配准两阶段进行,粗配准使用采样一致性算法(SAC-IA)。为了提升特征点的搜索速度,使用了多核心并行的方式进行搜索。为了减小下采样计算造

成的地形特征损失,设置动态尺度因子 γ 为 15;在精配准阶段使用正态分布变换方法。定义点云的配准精度为配准后的两个点云之间对应点的欧式距离。图 4 为点云配准的可视化结果,点云经配准并转换坐标系后的重合度较高。图 5 为点云序列在粗配准阶段的配准时间和配准精度曲线。图 6 和图 7 分别对比了 NDT 方法和 ICP 方法的运行时间和配准误差。

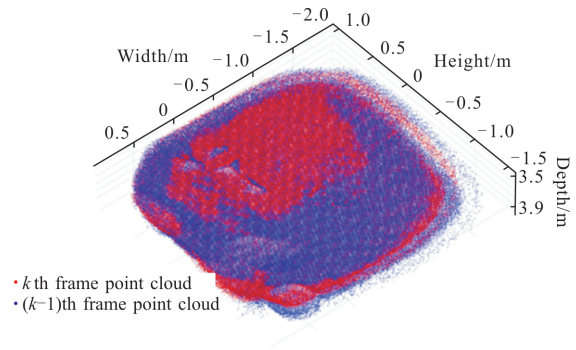


图 4 帧间点云配准结果

Fig.4 Result of frame-by-frame registration




图 5 采样一致性初始配准时间曲线与配准精度

Fig.5 Sampling consistency initial registration time and registration accuracy

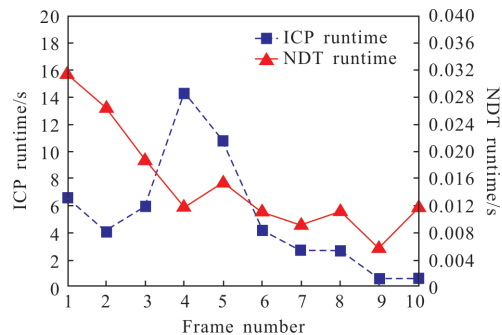


图 6 迭代最近点与正态分布变换配准时间对比

Fig.6 Runtime comparison of ICP and NDT




图 7 迭代最近点与正态分布变换配准误差对比

Fig.7 Registration error comparison of ICP and NDT

配准算法以配准精度和配准时间两个方面进行评估。粗配准阶段使用 SAC-IA 方法计算的初始转换矩阵作为初值,可以使 NDT 方法和 ICP 方法正确收敛,在预处理阶段引入的动态尺度下采样滤波使粗配准时间更为稳定;在精配准阶段,NDT 方法的配准误差为厘米数量级,ICP 方法的配准误差可以达到毫米数量级;但从图 6 可以看到,基于 ICP 方法导致耗时很长,并不适用于实时性需求较高的应用场景,而 NDT 方法的时间性能远优于 ICP 方法。

3 基于深度学习的地物目标识别

3.1 基于深度学习的地物目标识别难点

C-TOF 成像应用于地外天体地物目标的识别,存在以下三个难点:(1) 目标形态特征的多样性、场景的尺度变化和 C-TOF 成像的噪声导致识别概率不佳;(2) 缺乏较大规模已标注地物信息的数据集,导致神经网络模型训练不充分;(3) 面向视觉任务的神经网络以卷积神经网络为基础,参数量普遍较大,网络推理过程在算力充足的设备上运行的时间性能较好,但在算力有限的嵌入式系统的时间性能不佳。为克服上述难点,文中设计了基于编码器-解码器和条件随机场的语义分割深度网络,建立了包括分类误差和回归误差的混合损失函数;先使用大规模标准数据集 VOC2012 进行网络初始化,后使用小规模 C-TOF 地物目标数据集进行迁移学习;利用卷积子网络减少网络的参数量,以加快推理速度。

3.2 数据集的构建

大规模数据集使用 PASCAL VOC2012 数据集

对网络进行初始训练。数据集中原始图像的空间尺度为 $500 \times 366 \times 3$,标注图像的空间尺度为 $500 \times 366 \times 1$,共二十种类别的 5 717 张图像。小规模 C-TOF 地物目标数据集有两个来源:(1) 基于 C-TOF 成像的地物目标仿真系统^[12-13],该系统根据虚拟三维地形模型生成深度图像。这种数字生成的场景深度与 C-TOF 成像传感器参数耦合;(2) 使用 C-TOF 传感器对半物理仿真表面中的地物目标成像,获取地物目标的深度图像。通过上述两种方法共采集了 100 张深度图像并对其中的地物目标进行了标注,作为迁移学习阶段的数据集。

3.3 地物目标识别轻量化网络

文中的深度神经网络用于提取深度图像中每个数据点的语义信息,再将具有相同语义标签的数据点进行聚类优化,实现地物目标的识别。网络包含提取语义信息的编码-解码网络和语义信息优化网络。编码器逐层减少空间维度,提取全局特征;解码器逐步恢复场景结构和空间维度。编码器和解码器的相同层级之间进行复制,将各层次的特征引入解码器的反卷积计算,使解码器更好地恢复场景的高频信息,输出数据点的语义分类概率图后,使用条件随机场对语义信息进行优化。网络结构如图 8 所示。

输入数据为飞行时间成像传感器采集的深度图像,每个像元包括深度数据和语义标签。编码器部分用于特征提取,使用最大池化方法对宽度和高度两个维度的中间层特征图进行三次下采样计算。在解码网络中,为了获得每个数据点的分类推理标签,使用转置卷积网络对两个维度的特征映射进行上采样,每次反卷积计算都将特征通道数量减半,特征图尺寸加倍,并将编码网络中相同层级的特征图映射到解码网络中对应层级的特征图,由归一化指数函数激活的卷积层生成每个数据点的分类概率。由于编码网络中的特征图尺寸稍大与解码网络的尺寸,因此需要将其裁剪。对拼接后的特征图进行卷积。最后一层的卷积核尺寸为 1×1 ,将 64 通道的特征图转化为特定深度的结果。编码网络中相同层级的特征张量复制到解码网络中,与反卷积后的特征张量组合,进行后续卷积层的计算,各层级特征图的融合弥补了编码过程中特征图空间频率的衰减,提高图像特征的恢复精度。概率图由基于循环神经网络的条件随机场层进一步优化。

为了减少卷积网络的参数量,加快网络的推理速度,在卷积层中使用了 fireModules 和 fireDeconvs^[14-15] 替换了卷积和反卷积层。两个子网络的体系结构如图 8 所示。与标准卷积层/反卷积层相比,这两种子网络的网络参数分别压缩为原参数量的 1/6 和 7/16。




图 8 地物目标识别网络结构图

Fig.8 Ground object recognition network structure diagram

此外,在解码网络中的卷积层还引入随机失活^[16],用于在深度神经网络训练中减小过拟合,提高网络的泛化能力。随机失活的实现方式是在单一神经元的激活函数中引入伯努利函数,未使用随机失活前,神经元的输入、激活函数与输出之间的表达式为^[16]:

$$\begin{cases} z_i^{(l+1)} = w_i^{(l+1)} y^{(l)} + b_i^{(l+1)} \\ y_i^{(l+1)} = f(z_i^{(l+1)}) \end{cases} \quad (10)$$

引入随机失活之后,表达式更新为^[16]:

$$\begin{cases} r_j^{(l)} \sim \text{Bernoulli}(p) \\ \hat{y}^{(l)} = r^{(l)} * y^{(l)} \end{cases} \quad (11)$$

$$\begin{cases} z_i^{(l+1)} = w_i^{(l+1)} \hat{y}^{(l)} + b_i^{(l+1)} \\ y_i^{(l+1)} = f(z_i^{(l+1)}) \end{cases} \quad (12)$$

式中: r 为服从概率为 p 的伯努利分布系数,神经元输入 y 与伯努利系数 r 相乘,与权重 w 和偏置 b 进行线性组合后,通过激活函数 f 计算后得到输出 y 。由于系数 r 的引入,每次神经元参与计算时神经元的输入有一定概率输出为0,等效于神经元的输入被随机的阻断。当网络的节点数为 N 时,引入随机失活之后的该网络为 2^N 个网络的集合,同时减弱了神经元之间的联合适应性,增加随机失活后的网络增强了神经元的独立性,从而增强网络的泛化能力。

3.4 损失函数的确定

训练语义分割神经网络的损失函数使用像元的二进制交叉熵,定义为:

$$l_i = x_i - x_i z_i + \log(1 + \exp(-x_i)) \quad (13)$$

式中: z_i 为像元 i 的标签真值; x_i 为像元 i 的标签预测值。为了优化网络的超参数,定义了精确率 P 、召回率 R 和准确率 A :

$$P = \frac{T_p}{T_p + F_p} \quad (14)$$

$$R = \frac{T_p}{T_p + F_n} \quad (15)$$

式中: T_p 为真正例; F_p 为伪正例; F_n 为伪反例。根据上述公式,精确率和召回率之间需要折衷,使用 F_1 度量,定义如下:

$$F_1 = 2 \frac{P \cdot R}{P + R} \quad (16)$$

式中: F_1 值越大,说明训练后的模型在精确率和召回率之间达到的折衷程度越好,即模型越稳健。根据 F_1 值选取超参数,最终确定 $D_{L,L}=2.6, D_R=1.8$ 时 F_1 达到最大,其值为0.67。

为评估提取出的地物目标位置精度和尺寸精度,定义如下约束:

$$\frac{dL}{R} = \frac{|L_P - L_G| \cos \frac{\pi \langle L \rangle}{180^\circ}}{R_G C_{KD}} \quad (17)$$

$$\frac{dR}{R} = \frac{|R_P - R_G|}{R_G} \quad (18)$$

$$\langle L \rangle = \frac{(L_P + L_G)}{2} \quad (19)$$

式中：下标 P 表示根据网络预测的地物位置计算的结果；下标 G 表示根据真实位置计算的结果。网络检测到的新地物的比例为：

$$P = \frac{N}{N+G} \quad (20)$$

式中： N 为网络提取的未标注的地物目标的数量； G 为地物目标的真实数量。

3.5 验证结果与分析

在初始训练阶段使用 VOC2012 数据集，在迁移学习阶段采用上述方法对网络进行了 21 次训练，网络精度和损失函数曲线如图 9 和图 10 所示，损失函数随训练次数的增加而逐渐降低。

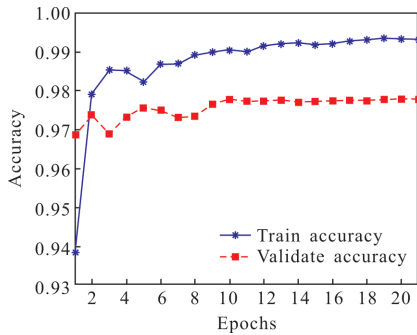


图 9 训练精度曲线

Fig.9 Training accuracy curve

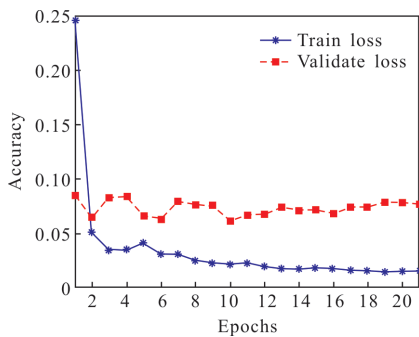


图 10 损失函数曲线

Fig.10 Loss function curve

对于训练结果的测试，使用交并比(IoU)指标评估语义分割的精度，定义为像元分别在标注图像和推理图像的交集和并集之比。该网络在测试集的 IoU 曲线如图 11 所示，平均交并比(IoU)达到 85%，表明网络对地物目标的识别具有较好的位置精度和语义精度。

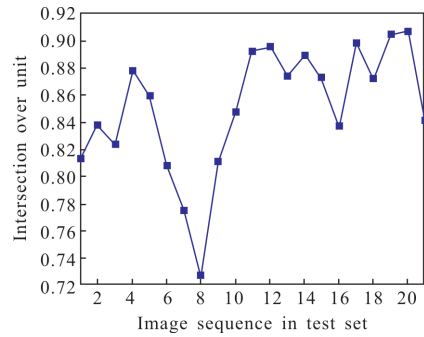


图 11 测试集序列图像语义分割精度

Fig.11 Accuracy of semantic segmentation in test set

图 12 为测试数据集中三组 C-TOF 深度图像及其地物目标区域语义分割的对比结果。左侧测试集中的图像有以下四个特点：(1) 地物目标的尺度逐渐增大；(2) 地物目标的形态差异较大，无显著的几何特征；(3) 场景地形复杂，导致多个地物区域中存在多路径误差，深度图像中均存在不同程度的噪声，与地物目标区域交叠；(4) 由于 C-TOF 成像调制光源的不均匀性和光学系统渐晕，导致边缘视场的深度信息误差较大。




图 12 测试数据集原始图像与语义分割图像

Fig.12 Original image in test dataset and semantic segmentation image

根据语义分割的结果，网络在上述场景中均能较为准确的提取多形态、多尺度的地物目标，表明网

络对地物目标特征提取的准确性；从测试结果可以看到，深度网络的语义分割结果去除了场景中的深度噪声和边缘视场的深度信息误差，实现了深度网络从理想的完备数据应用到现实场景高噪声数据应用的重要拓展。

4 总结与展望

文中研究了基于连续调制式飞行时间成像的导航传感器的位姿计算和基于深度学习的地物目标识别算法。传感器采用飞行时间成像方式，输出地形的结构化点云。由于该成像方式可以并行采集深度信息，解决了扫描式激光成像因场景的动态变化而产生空间分辨率和空间结构的误差，因此在数据实时性和可靠性方面具有优势，满足深空探测器对三维成像的需求。

位姿计算算法使用正态分布变换方法，通过点云网络的三维正态分布函数代替点特征进行姿态变换矩阵的优化，由于避免了点云搜索和特征计算，有效减小了计算量。经过实验验证，与迭代最近点方法相比，正态分布方法在几乎不损失精度的前提下提高了运行效率，提升了算法的实时性地物目标识别算法使用深度编码器结构，对深度信息进行语义分割。其优势在于，深度编码器网络在小数据集上进行训练可取的较好的训练效果，且网络模型的规模可控，可在嵌入式系统上运行。深度学习的优势在于其较强的特征表达能力使得算法可以提升传感器在多尺度和复杂环境中的适应能力且随着地形数据的不断完善，该网络具备进一步学习的潜力。

与点特征方法相比，基于深度网络学习的方法在特征表达能力方面具有较大优势。点特征提取数据中的低维特征且可视化程度较高，而深度网络提取了数据中的高维特征，而可视化程度较低。在位姿计算的需求中使用低维度特征，有利于平衡算法准确性与实时性；在地物目标识别的过程中使用高维度特征，用于获取数据的语义信息。

参考文献：

- [1] Yano H, Kubota T, Miyamoto H, et al. Touchdown of the Hayabusa spacecraft at the Muses Sea on Itokawa [J]. *Science*, 2006, 312(5778): 1350–1353.
- [2] Tsuchiyama A, Uesugi M, Matsushima T, et al. Three-dimensional structure of Hayabusa samples: origin and evolution of Itokawa regolith [J]. *Science*, 2011, 333(6046): 1125–1128.
- [3] Tsuda Y, Yoshikawa M, Abe M, et al. System design of the Hayabusa 2–Asteroid sample return mission to 1999 JU3 [J]. *Acta Astronautica*, 2013, 91: 356–362.
- [4] Tsuda Y, Yoshikawa M, Saiki T, et al. Hayabusa2–Sample return and kinetic impact mission to near-earth asteroid Ryugu [J]. *Acta Astronautica*, 2019, 156: 387–393.
- [5] Titterton D H. *Military Laser Technology and Systems* [M]. US: Artech House, 2015.
- [6] Lu Chunqing, Song Yuzhi, Wu Yanpeng, et al. 3D information acquisition and error analysis based on C–TOF computational imaging [J]. *Infrared and Laser Engineering*, 2018, 47(10): 1041004. (in Chinese)
卢纯青, 宋玉志, 武延鹏, 等. 基于 C–TOF 计算成像的三维信息获取与误差分析 [J]. *红外与激光工程*, 2018, 47(10): 1041004.
- [7] Lu Chunqing, Song Yuzhi, Wu Yanpeng, et al. Theoretical investigation on correlating time-of-flight 3D sensation error [J]. *Infrared and Laser Engineering*, 2019, 48(11): 1113002. (in Chinese)
卢纯青, 宋玉志, 武延鹏, 等. 基于相关法飞行时间三维感知的误差机理研究 [J]. *红外与激光工程*, 2019, 48(11): 1113002.
- [8] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration [C]//2009 IEEE International Conference on Robotics and Automation. IEEE, 2009: 3212–3217.
- [9] Zhang Z. Iterative point matching for registration of free-form curves and surfaces [J]. *International Journal of Computer Vision*, 1994, 13(2): 119–152.
- [10] Rusinkiewicz S, Levoy M. Efficient variants of the ICP algorithm [C]//3-D Digital Imaging and Modeling, 2001. Proceedings. Third International Conference on. IEEE, 2001: 145–152.
- [11] Biber P, Strasser W. The normal distributions transform: A new approach to laser scan matching [C]//Proceedings 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003) (Cat. No. 03CH37453). IEEE, 2003, 3: 2743–2748.
- [12] Lu Chunqing, Liu Xingtian, Wu Yanpeng, et al. Computer simulation technology of time-of-flight imaging system [J]. *Aerospace Control and Application*, 2019, 45(2): 56–66. (in Chinese)

- Chinese)
- 卢纯青, 刘兴潭, 武延鹏, 等. 飞行时间成像系统的数字仿真技术[J]. 空间控制技术与应用, 2019, 45(2): 56–66.
- [13] Yue X, Wu B, Seshia S A, et al. A lidar point cloud generator: from a virtual world to autonomous driving [C]// Proceedings of the 2018 ACM on International Conference on Multimedia Retrieval. ACM, 2018: 458–464.
- [14] Wu B, Wan A, Yue X, et al. Squeezeseg: Convolutional neural nets with recurrent crf for real-time road-object segmentation from 3d lidar point cloud [C]//2018 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2018: 1887–1893.
- [15] Wu B, Zhou X, Zhao S, et al. Squeezesegv2: Improved model structure and unsupervised domain adaptation for road-object segmentation from a lidar point cloud [C]//2019 International Conference on Robotics and Automation (ICRA). IEEE, 2019: 4376–4382.
- [16] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. *Journal of Machine Learning Research*, 2014, 15(1): 1929–1958.