

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2025)02-0546-13
论文引用格式: Zhang C, Li J, Wang P Z, Shi J H, Wang H Y and Wang Q. 2025. Tactile-enhanced graph convolutional point cloud superresolution network. Journal of Image and Graphics, 30(02):0546-0558(张驰, 李剑, 王普正, 石键瀚, 王怀钰, 王琴. 2025. 触觉增强的图卷积点云超分网络. 中国图象图形学报, 30(02):0546-0558)[DOI:10.11834/jig.230662]

触觉增强的图卷积点云超分网络

张驰, 李剑, 王普正, 石键瀚, 王怀钰, 王琴*

南京邮电大学通信与信息工程学院, 南京 210003

摘要: **目的** 随着三维扫描仪以及三维点云采集技术的飞速发展, 三维点云在计算机视觉、机器人导引和工业设计等方面的应用越来越广泛。但是由于传感器分辨率、扫描时间以及扫描条件等限制, 采集到的点云通常比较稀疏, 无法满足许多应用任务的要求, 因此人们一般采用上采样的方法获取稠密点云。但是由于原始稀疏点云缺失细节信息, 对单一低分辨率点云进行上采样得到的结果往往较差。**方法** 首次提出一种触觉增强的图卷积点云超分网络, 主要思想是通过动态图卷积提取触觉特征并与低分辨率点云特征进行融合, 以得到更加精确的高分辨率点云。由于触觉点云相比于低分辨率点云更加密集、精确, 而且比较容易获取, 因而本文将其与原始稀疏点云进行融合辅助后可以获得更加准确的局部特征, 从而有效提升上采样的精度。**结果** 首先构建用于点云超分的三维视触觉数据集(3D vision and touch, 3DVT), 包含 12 732 个样本, 其中 70% 用于训练新模型, 30% 用于测试; 其次, 采用倒角距离作为评价指标对数据集进行测试和验证。实验结果表明, 不添加触觉辅助信息时, 超分后点云的平均倒角距离为 3.009×10^{-3} , 加入一次触觉信息融合后, 平均倒角距离降低为 1.931×10^{-3} , 加入两次触觉信息融合后, 平均倒角距离进一步降低为 1.916×10^{-3} , 验证了本文网络对点云超分效果的提升作用。同时, 不同物体的可视化效果图也表明, 加入触觉信息辅助后的上采样点云分布更加均匀、边缘更加平滑。此外, 进一步的噪声实验显示, 在触觉信息的辅助下, 本文提出的网络对噪声具有更好的鲁棒性。在以 3DVT 数据集为基础的对比实验中, 相比于现有最新算法, 本文算法的平均倒角距离降低了 19.22%, 取得了更好的实验结果。**结论** 通过使用本文提出的触觉增强的图卷积点云超分网络, 借助动态图卷积提取触觉点云特征并融合低分点云, 可以有效提高超分重构后高分率点云的质量, 并且对周围噪声具有良好的鲁棒性。

关键词: 点云超分; 触觉点云; 特征提取; 特征融合; 动态图卷积; 多模态

Tactile-enhanced graph convolutional point cloud superresolution network

Zhang Chi, Li Jian, Wang Puzheng, Shi Jianhan, Wang Huaiyu, Wang Qin*

School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: Objective With the rapid development of 3D scanners and 3D point cloud acquisition technologies, the application of 3D point clouds in computer vision, robot guidance, industrial design, and other fields has become increasingly widespread. As long as the point cloud is sufficiently dense, accurate models can be constructed to meet the demands of various advanced point cloud tasks. Accurate point clouds facilitate better performance in tasks such as semantic segmenta-

收稿日期: 2023-10-20; 修回日期: 2024-07-18; 预印本日期: 2024-07-25

* 通信作者: 王琴 qinw@njupt.edu.cn

基金项目: 江苏省重点研发计划资助(BE2022071); 江苏省自然科学基金项目(BK20192001)

Supported by: Jiangsu Provincial Key R&D Program, China(BE2022071); Natural Science Foundation of Jiangsu Province, China(BK20192001)

tion, completion, and classification. However, given the limitations of sensor resolution, scanning time, and scanning conditions, the acquired point clouds are often sparse. Existing point cloud upsampling methods address only single low-resolution point clouds, yield poor results when highly sparse point clouds are upsampled at relatively high magnification rates, and do not use additional modalities for assistance. Moreover, tactile information has gradually been applied to 3D reconstruction tasks, reconstructing complete 3D models via multimodal information such as RGB images, depth images, and tactile information. However, tactile point clouds have not yet been applied to point cloud superresolution tasks.

Method A tactile-enhanced graph convolutional point cloud superresolution network that uses dynamic graph convolution is proposed in this study. The proposed network is used to extract tactile features and fuse them with low-resolution point cloud features to obtain more accurate high-resolution point clouds. This network consists of a feature extraction module and an upsampling module. The feature extraction module extracts features from low-resolution point clouds and tactile point clouds, whereas the upsampling module performs feature expansion and coordinate reconstruction to output high-resolution point clouds. The key to this network lies in extracting features from tactile point clouds and fusing them with low-resolution point cloud features. The tactile feature extraction module adopts a multilayer perceptron (MLP) and 4-layer cascaded dynamic graph convolution. The tactile point cloud is mapped to a high-dimensional space by using a multilayer perceptron for subsequent feature extraction. The dynamic graph convolution module consists mainly of K-nearest neighbors (KNN) and edge convolution. In each dynamic graph convolution, the KNN algorithm is used to recompute the neighboring points of each point and construct the graph structure. The KNN algorithm can effectively aggregate local feature information, and edge convolution extracts features of center points and neighboring points. The K-nearest neighbors of each point vary in different network layers, leading to the graph structure being dynamically updated in each layer. The feature extraction for the low-resolution point cloud adopts graph convolution. The graph structure is first constructed via the KNN algorithm and then shared with subsequent layers. After the features of the low-resolution point cloud and the tactile point cloud are fused, the point cloud features undergo further progressive feature extraction, mainly via dense connected graph convolution modules. The bottleneck layer compresses features to reduce the computational complexity in subsequent layers. Two parallel dense graph convolutions extract local features, whereas the global pooling layer extracts global features. Finally, the feature rearrangement module and coordinate reconstruction module map the high-dimensional features back to the 3D coordinate system. Compared with low-resolution point clouds, local tactile point clouds are denser and more precise, whereas low-resolution point clouds are often sparser and contain less local information. With the assistance of tactile information, enhanced local features can be obtained. **Result** A 3D Vision and Touch point cloud superresolution dataset with tactile information was reconstructed and trained. This dataset contains a diverse range of object categories and a sufficiently large number of samples. Using the chamfer distance as the evaluation metric, the experimental results reveal that without adding tactile information, the average chamfer distance is 3.009×10^{-3} ; when one instance of tactile information is added, the average chamfer distance decreases to 1.931×10^{-3} ; and when two instances of tactile information are added, the average chamfer distance further decreases to 1.916×10^{-3} . Tactile point clouds can enhance the quality of high-resolution point clouds and serve as auxiliary aids in point cloud superresolution tasks. Visualizations of different objects demonstrate that the distribution of upsampled point clouds becomes more uniform, and the edges become smoother with the assistance of tactile information. With the assistance of tactile point clouds, the network can better fill in the holes in the point cloud and reduce the generation of outliers. The quantitative results of chamfer distance and density-aware chamfer distance obtained by superresolution experiments on different objects confirm the effectiveness of tactile point cloud assistance in the superresolution task. Furthermore, for complex objects, this improvement is even more pronounced. The noise experiments show that at a noise level of 1%, the average chamfer distance without tactile information is 3.132×10^{-3} , whereas with the inclusion of two instances of tactile information, the average chamfer distance is 1.954×10^{-3} . At a noise level of 3%, the average chamfer distance without tactile information is 3.331×10^{-3} , and with the inclusion of two instances of tactile information, the average chamfer distance is 2.001×10^{-3} . The experiments demonstrate that with the assistance of tactile information, the impact of noise on the network is reduced, indicating that the network exhibits strong robustness. **Conclusion** Dynamic graph convolution can effectively extract initial features from tactile point clouds, and the tactile point cloud features contain rich local information. Through feature fusion, it can effectively assist

in the point cloud superresolution task. The proposed tactile-enhanced graph convolutional point cloud superresolution network in this study uses dynamic graph convolution to extract tactile features and fuse them with low-resolution point cloud features, effectively improving the quality of high-resolution point clouds and exhibiting strong robustness. The superiority of the method lies in its ability to achieve better results by incorporating tactile information without updating the network architecture. This method can provide high-quality point clouds for advanced visual tasks such as point cloud classification and object detection, laying the foundation for further development and application of point clouds.

Key words: point cloud super-resolution; tactile point clouds; feature extraction; feature fusion; dynamic graph convolution; multimodality

0 引言

三维计算机视觉在机器人、自动驾驶和增强现实等人工智能中显示出巨大的潜力,引起了学术界和工业界的广泛关注。点云作为三维数据的基本表示形式,包含丰富的形状信息。点云是三维坐标空间中点的集合,可以精确地表示三维形状或对象。随着激光雷达等单位扫描仪的发展与应用,从现实场景中捕获点云变得更加方便,因此点云在测绘、机器人和遥感等领域中取得了广泛的应用(Guo等,2021)。但是3D扫描仪和深度相机采集的原始点云通常比较稀疏、杂乱,有时还有小孔(Li等,2021),极大地影响了下游任务的性能,如点云分类(Qiu等,2022a)、分割(Hu等,2020)和检测(Qiu等,2021)等。因此,将原始点云上采样以得到分布均匀、密集以及富有精确几何细节的高分辨率点云是至关重要的。

传统的点云超分辨率算法需要很强的先验形状信息。移动最小二乘法(moving least squares, MLS)(Alexa等,2003)对于点云的表面形状有很强的先验假设。由于点云的复杂性、无序性,经典算法在域迁移和鲁棒性方面表现很差。近几年,研究者开始专注于构建深度学习网络完成点云超分辨率任务(张健翔,2022)。现有的基于深度学习的点云超分方法,如PU-Net(point cloud upsampling network)(Yu等,2018)、PU-GAN(point cloud upsampling generative adversarial network)(Li等,2019)、PU-GCN(point cloud upsampling using graph convolutional networks)(Qian等,2021)、PU-Transformer(Qiu等,2022b)等,都在不断使用更先进的网络技术架构提升超分任务的效果。

现有的基于深度学习的点云超分网络存在两个

有待改进的问题:1)在高倍率点云超分任务中,传统网络生成的高分点云仍然容易出现不均匀分布和过多噪声点。这可能是由于高倍率上采样任务中低分辨率点云密度不足,导致点云特征提取效果不佳。2)忽略了在现有网络技术的基础上结合多模态信息提升点云的超分效果。在一些下游点云任务,如三维重建(Wang等,2018)、点云补全(Rustler等,2022)等,已经开始探索将原始点云与触觉信息结合,提升点云任务的完成效果。

触觉作为感知三维形状的另一种方式,近年来随着触觉传感器 Gelsight(Yuan等,2017)、DIGIT(digit tactile sensor)(Lambeta等,2020)的不断发展,逐渐应用于机械手与现实世界进行交互。通常将传感器安装在机械手末端,机械手控制传感器与物体接触,可以测量小接触面积上的力分布或几何形状。然而触觉感知受到传感器大小和规模的限制,每次触摸只获得局部区域的信息,需要多次触摸和很长时间才能重建物体的完整形状。因此触觉信息常常作为辅助信息,应用于三维重建(Watkins-Valls等,2019)、触觉伺服等任务中。Smith等人(2020)提出了基于图卷积(graph convolutional network, GCN)的视觉触觉融合三维重建网络,首先将触觉信息转化成网格,然后将RGB视觉信息和触觉网格送入GCN网络,不断更新三维物体的形状,最后得到精确的点云模型。同时,近年来工业机器人的应用有了迅速的发展,在一些工业级小目标场景下,需要视觉传感器和配备触觉传感器的机械臂协同操作来完成特定的任务。例如,在自动化精密作业中,机器人通过使用触觉传感器来测定物体的表面细节,与视觉点云数据结合,能够精确地构建作业区域的三维结构。这种信息融合显著提高了机器人执行切割、焊接等操作的精确性。此外,受触觉传感器规模的限制,这种信息融合并不适用于大场景下的作业。

总体来说,多模态信息融合在点云任务中的辅助应用逐渐被探索出来,然而现有超分方法中多数工作只关注于网络技术架构的更新,并没有尝试加入触觉信息提升超分效果。同时现有超分方法在高采样倍率下表现较差。基于此,本文提出了一种新的范式,在点云超分任务中,加入触觉信息进行辅助,对触觉信息进行处理并与低分点云特征相互融合,以达到更好的结果。

本文构建了首个含有触觉信息的点云超分三维视觉触觉数据集3DVT(3D vision and touch),现有的点云超分数据集,如PU-GAN构建的数据集(Li等,2019)、PU1K数据集(Qian等,2021)等都没有触觉点云。基于触觉辅助点云超分任务的需求,本文构建了首个包含触觉信息的点云超分数据集,并在此数据集上进行网络训练和测试实验。

本文搭建了基于图卷积的触觉辅助点云超分网络,使用动态图卷积对触觉点云进行特征提取,然后与低分点云特征进行融合,将融合后的特征进行进一步的特征提取、特征扩展和坐标重建操作以得到高分点云。本文具体贡献如下:1)首次提出了利用触觉信息辅助点云超分任务,并且构建了触觉特征提取和融合模块,搭建了基于图卷积与触觉信息辅助的点云超分网络。2)构建了首个含有触觉信息的点云超分辨率数据集3DVT,具体包含:触觉点云信息、低分辨率点云信息和高分率点云信息。同时在此数据集上进行了训练与测试,相比于不添加触觉信息,添加两次触觉信息的平均倒角距离降低了36.32%,本文算法平均倒角距离比现有最新算法降低了19.22%。3)通过在点云超分任务中引入触觉信息进行辅助,不仅提高了模型在常规条件下的超分辨率效果,而且显著增强了模型对环境噪声的鲁棒性。经实验证明能有效抵抗高达3%的随机噪声,显著优于未融合触觉信息的方法。

1 相关工作

1.1 基于深度学习的点云超分辨率算法

Yu等人(2018)首次使用深度学习网络PU-Net处理低分辨率点云,其借鉴了PointNet(Qi等,2017)首先将低分点云提取成不同尺度的小块,然后使用多个多层感知机(multilayer perceptron, MLP)进行

不同尺度下的特征提取,将多尺度特征聚合后输入上采样模块进行特征扩展,最后通过坐标重建模块重新映射回三维坐标空间得到高分辨率点云。后续的许多方法都在其基础上发展而来,基于深度学习的点云超分辨率算法主要分为两个模块,特征提取模块和上采样模块。特征提取模块将稀疏点云的三维坐标映射到特征空间,提取出高维特征;经过上采样模块进行特征扩展,得到更加密集的特征,经过特征重排操作后,再重新映射回三维坐标空间得到高分辨率点云。

MPU(multi-step progressive upsampling network)(Wang等,2019b)采用了一种渐进式的上采样网络结构设计,其中,16倍超分任务分成4个级联的2倍上采样单元,并且采用渐进式训练方法。在上采样单元的特征提取模块中,使用K近邻算法(K-nearest-neighbors, KNN)对特征进行分组,然后使用密集连接块进行特征特化。但其渐进训练的步骤过于烦琐,训练效率较低。Li等人(2021)认为点云超分生成密集点云,需同时实现分布均匀性和接近真实形状,并且尽可能修复空缺。但是现有方法中这些任务都在一个网络中实现,于是提出DisPU将点云超分任务分解成两个子网络实现——密集生成器和空间细化器。密集生成器只需要生成粗略的密集点云,不需要复杂的网络结构,具有较强的灵活性和扩展性;空间细化器包含局部细化和全局细化,使密集点云满足均匀性和准确性。

Qiu等人(2022b)提出了首个引入Transformer的点云超分模型PU-Transformer,其网络结构分为头部、主体和尾部。PU-Transformer头部使用MLP对输入点云进行初步特征提取,PU-Transformer主体通过级联编码器逐步对更全面的特征图进行编码。最后,在PU-Transformer尾部,使用重排操作来形成密集的特征图,并通过MLP重建3D坐标。现有的点云超分网络都只使用单模态的低分辨率点云信息,本文方法加入了更加密集、精确的触觉点云信息进行辅助,可以得到更加均匀、局部表现更好的高分率点云。

1.2 基于触觉信息辅助的点云处理任务

传统上,研究者们多使用视觉信息进行形状重建,随着触觉传感器的发展,Li等人(2014)开发了一种称为Gelsight的新型触觉传感器,通过Gelsight传感器,能够借助光度立体算法重建物体表面的三维

几何形状。

Wang 等人(2018)提出了一种新的范式,通过结合视觉信息和触觉信息,以及从大规模数据集中学习的常见物体形状的先验视觉知识,从而准确预测 3D 物体形状。首先从 RGB 图像重建物体的 3D 模型,然后触摸不确定性最大的区域。触觉数据提供了物体表面的精确形状信息,以触觉信息为约束细化 3D 模型形状。Watkins-Valls 等人(2019)分别使用触摸信息和深度图来预测独立的体素模型,然后将其组合以产生最终预测。

Smith 等人(2020)提出了基于 GCN 的视觉触觉融合三维重建网络,其使用 U-Net 网络将触觉信息转化成网格,然后预设一个三维球形物体,将 RGB 视觉信息和触觉网格送入网络,不断更新三维物体的形状,最后得到精确的点云模型。Rustler 等人(2022)提出的 ActVH(active visuo-haptic)首先将深度相机采集到的深度信息重建成点云模型,然后主动触摸不确定性大的区域,根据得到的触觉信息不断迭代细化三维形状。目前触觉信息多用于三维重建任务中,表明触觉信息可以提供精确的局部信息。本文首次在超分任务中引入触觉信息,并且在 Smith 等人(2020)的三维重建数据集的基础上构建了含有触觉信息的点云超分数据集 3DVT。

2 本文方法

2.1 网络框架

本文提出的基于图卷积的触觉辅助点云超分网

络框架如图 1 所示,整体框架分为特征提取模块和上采样模块两个部分。输入包括低分辨率点云 $P \subseteq \mathbf{R}^{N \times 3}$ 和触觉点云 $T \subseteq \mathbf{R}^{N \times 3}$,通过该网络可以得到高分辨率点云 $Q \subseteq \mathbf{R}^{rN \times 3}$,其中 N 为点的个数, r 是上采样倍率,3 表示输入点的特征是三维(X, Y, Z)。

在特征提取模块,低分点云和触觉点云采用不同的处理方式。首先低分辨率点云使用 K 近邻算法算出每个点的 K 个最近邻点,以此来构建图结构。图结构中的节点是点云中每个点,边由 K 个最近邻点确定。然后使用一层的图卷积将点云 $P \subseteq \mathbf{R}^{N \times 3}$ 从三维坐标空间映射到特征空间,得到点云特征 $F_p \subseteq \mathbf{R}^{N \times 24}$ 。

本文使用多层动态图卷积对触觉特征进行初步提取。相比于普通图卷积,动态图卷积可以使用更多的卷积层数,并且特征空间中的邻域信息可以学习到原空间中长距离的特征。触觉点云 $T \subseteq \mathbf{R}^{N \times 3}$ 首先通过多层感知机 MLP 映射到高维空间以便进行后续特征的提取,然后使用 4 层级联的动态图卷积模块得到触觉特征 $F_t \subseteq \mathbf{R}^{N \times 6}$ 。将得到的低分点云特征和触觉点云特征进行融合,瓶颈层(单层 MLP)对特征维度进行压缩以减小后续层的计算量。压缩后的特征被传递到两个平行的密集图卷积模块。同时增加了全局池化层提取全局信息,因此该特征提取模块可以提取到多尺度信息。

在上采样模块中,进行重排操作,生成大小为 $rN \times 30$ 的更密集的特征,坐标重建层将其重新映射到三维空间,得到 $rN \times 3$ 的高分辨率点云。




图1 点云超分网络框架

Fig. 1 Point cloud super resolution network architecture

2.2 触觉特征初步提取模块

触觉特征初步提取模块如图2所示,包括1个多层感知机模块和4个级联的动态图卷积。每个动态图卷积模块由K近邻算法、卷积层 Convolution、归一化层 Group Normalization、激活函数 LeakyReLU (leaky rectified linear unit)等组成。动态图卷积模块如图3所示, f 表示每个输入点的特征维度, f' 表示每个输出点的特征维度。每次动态图卷积都会重新

使用KNN算法计算邻近点并且构建图结构(Wang等,2019a),然后使用卷积层对局部特征进行提取,4个动态图卷积的维度分别是24、48、12、6。

本文在加入一次触觉信息的基础上,还搭建了加入两次触觉信息的特征初步提取模块,如图4所示,两次触觉共享参数,与加入一次触觉信息不同的是,每个触觉特征的维度改变为 $N \times 3$,并将两个触觉特征进行融合。



图2 触觉特征提取模块（一次触觉）

Fig. 2 Touch feature extraction module (1 touch)




图3 动态图卷积模块

Fig. 3 Dynamic graph convolution module




图4 触觉特征提取模块（两次触觉）

Fig. 4 Touch feature extraction module (2 touches)

2.3 动态图卷积

深度学习中处理的数据结构大体分为两种:欧几里得结构和拓扑结构。欧几里得数据通常表示为规则排列的像素点或矩阵,如一维的文本语言、二维的图像;拓扑数据又称为非欧几里得结构数据,这类数据没有规则的排列,常见的如化学分子结构、人际关系和社交网络等。图(graph)用 $G=(V, E)$ 表示, V 中元素为顶点(vertex), E 中元素为边(edge)。图中边为无序对时为无向图,为有序对时为有向图。点云数据就是一种典型的拓扑结构数据,可以构建图结构的形式,其中顶点是点云中的坐标点,边根

据每个点的邻近点构建。在图结构数据上的卷积称为图卷积,图卷积网络GCN可以很好地处理这种不规则的图结构数据,现有对点云语义分割的研究(Thomas等,2019)表明图卷积网络在编码局部和全局信息方面具有显著效果。

在图上的卷积分为基于空间域的图卷积和基于频谱域的图卷积。本文使用的图卷积是基于空间域的图卷积,相比于基于频谱域的图卷积,它具有更好的泛化能力并且更易于实现。一般的图卷积在整个网络中使用一个固定的图结构,图卷积神经网络层数增多后,聚合的邻居变多,不同节点重合的邻居节

点数变多,因此会出现过度平滑的现象。导致GCN模型一般在2~3层左右。本文使用的动态图卷积在每一层都会使用K近邻算法重新计算每个点的邻近点并且重新构建图结构,这种动态图卷积操作一定程度上解决了过度平滑问题,并且能够更好地提取特征信息。

K近邻算法是一种用于分类和回归的非参数统计方法,可以用来聚集点云的局部信息。K近邻算法通过某种计算方法和评价指标得到点 p 距离最近的 k 个点,这 k 个点包含了点 p 的局部邻域信息。如图5所示,对于点 $p_i \in P$,计算点云 P 中每个点与点 p_i 的欧氏距离,得到距离最小的 k 个点 $p_{i1}, p_{i2}, \dots, p_{ik}$,后续将使用K近邻算法来构建每层动态图卷积的有向图结构。 k 值过小,聚集的信息不够全面; k 值过大,泛化能力虽有一定提高,但是容易过拟合,经过实验,本文的 k 值选取为20。

如图5(b)所示,在得到 p_i 的 k 个最近邻点之后,构建有向图结构 $G=(V, E)$,顶点是点云中的点,有向边 E 由 p_{ij} 确定。得到图结构之后,在图上进行边卷积操作,对边特征进行提取。作为动态图卷积的核心模块,边卷积会根据邻近节点提取边信息,然后确定局部特征作为边卷积的输出。如图5(c)所示,定义每条边的边特征为 $e_{ij}, j \in \{1, 2, \dots, k\}$,为了同时考虑以点 p_i 为中心捕获的全局信息和由 $p_i - p_{ij}$ 捕获的局部邻域信息,本文采用了Wang等人(2018)对边特征的定义,具体为

$$e_{ij} = \text{ReLU}(\theta_m \cdot (p_i - p_{ij}) + \phi_m \cdot p_i) \quad (1)$$

式中, ReLU 表示激活函数,参数集合为 $\Theta = (\theta_1, \dots, \theta_m, \phi_1, \dots, \phi_m)$ 。

本文使用共享MLP来实现对边特征的提取。然后使用最大池化来聚合局部特征,具体为

$$p'_i = \max_{j(i, j) \in E} e_{ij} \quad (2)$$

式中, p'_i 表示聚合后的特征, $\max$ 表示最大聚合。

本文使用4层动态图卷积对触觉特征进行初步提取,有效地聚合了触觉点云中的局部特征信息,同时动态更新图结构的操作避免了图卷积层数过多带来的过度平滑等问题。

3 实验验证

现有的点云超分数据集并不包含触觉信息,为




图5 KNN算法构建图结构与边卷积

Fig. 5 Graph structure construction using KNN and edge convolution

了验证触觉信息对点云超分任务的有效性,本文在Smith等人(2020)的三维重建数据集基础上,构建了首个含有触觉信息的点云超分数据集3DVT,并且在此数据集上进行16倍上采样模型的训练与测试。将加入触觉信息与不加入触觉信息的实验结果作对比,并且验证了本文网络在加性高斯噪声影响下的鲁棒性。

3.1 数据集

为了完成触觉辅助的三维重建任务,Smith等人(2020)构建了一个新的数据集。在3D机器人模拟器Pybullet中,仿真机械手的4根手指装载DIGIT传感器,将机械手随机放置在其表面,并闭合手指,让传感器平面与物体表面接触。通过模拟DIGIT原理,得到触觉数据。由于触摸位置和姿态不同,每次触摸都只保留传感器成功接触到的部分点云,因此每次触觉点云中点的数量是不同的。本文选取了物体模型中8 192个点作为高分辨率真实点云(ground truth, GT),并采用最远点采样将其下采样到512个点作为低分点云。触觉点云选取成功触摸并且不低于1 000个点的触觉信息,首先使用欧拉角将其与物体点云进行坐标对齐,然后采用最远点采样将其下采样到512个点作为本文网络要使用的一次触摸点云。本文数据集中一共有12 732个样本,包括简单和复杂的物体,以验证模型的泛化能力,取其中70%作为训练集,30%作为测试集。

3.2 损失函数与实验参数设置

本文采用倒角距离(chamfer distance, CD)作为损失函数最小化低分点云与真实点云之间的距离,倒角距离CD定义为

$$CD(P, Q) = \frac{1}{|P|} \sum_{p \in P} \min_{q \in Q} \|p - q\|_2^2 + \frac{1}{|Q|} \sum_{q \in Q} \min_{p \in P} \|p - q\|_2^2 \quad (3)$$

式中, P 代表网络预测的高分点云, Q 代表真实高分点云, $p \in P$ 代表预测点云中的点, $q \in Q$ 代表真实高分点云中的点。第 1 项表示 P 中任意一点 p 到 Q 的最小距离之和, 第 2 项表示 Q 中任意一点 q 到 P 的最小距离之和。倒角距离越大说明 P 、 Q 两组点云差异越大; 倒角距离越小, 说明预测点云与真实点云越接近, 相似度越高, 预测结果越好。

本文模型采用 PyTorch 深度学习框架, 并对点云进行了归一化、数据增强(旋转、缩放和随机扰动)等预处理操作。本文通过多次实验并结合 PU-GCN (Qian 等, 2021) 的实验设置进行参数调整, 使模型达到最优的效果。网络参数设置如下: 优化方法为 Adam 算法 (Zhang, 2018), 学习率为 0.001, 上采样倍率为 16, Batchsize 为 48, 训练 100 个 epoch。

3.3 实验结果分析

表 1 给出了本文在测试集上的实验结果, 本文对比了使用不同特征提取方法和不同触摸次数的实验, 输入低分辨率点云为 512 个点, 每个触觉点云为 512 个点, 输出高分率点云为 8 192 个点, 上采样倍率为 16, 评价指标为倒角距离 CD。直接使用图卷积提取特征指的是触觉特征的提取方法采用与低分点云一样的处理方法, 均只使用一层普通图卷积网络来实现。

表 1 不同模型实验结果 (CD)			
Table 1 Experimental results of different models (CD)			
模型	触摸次数		
	不添加	1	2
直接使用图卷积提取特征	3.009×10^{-3}	2.219×10^{-3}	2.202×10^{-3}
使用动态图卷积提取特征	3.009×10^{-3}	1.931×10^{-3}	1.916×10^{-3}

从表 1 中数据可以看到, 无论是哪种特征提取方法, 加入触觉信息比不加触觉信息效果更好, 并且两次触觉信息比一次触觉信息的辅助效果有一定提升。使用本文的动态图卷积提取触觉特征并且融合的方法, 要比直接使用图卷积提取特征的方法更有效。本文提出的基于图卷积的触觉辅助点云超分网络在加入两次触觉信息时取得了最好的测试结果。由此可以得出, 在点云超分任务中, 加入触觉信息可以显著提升上采样的效果。

为了更加直观地表示加入触觉信息后, 高分辨

率点云的区别, 使用本节中训练的模型在测试集上进行了定性分析。如图 6 所示, 本文选取 3 个物体模型进行可视化并且对局部进行放大观察, 从左到右 3 列依次为圆环、螺母和薄片。第 1 行是网络的输入低分辨率点云 (512 个点), 阴影部分是两块密集的触觉点云, 每个触觉点云同样包含 512 个点; 第 2 行是真实高分率点云 GT (8 192 个点); 第 3 行是不加入触觉信息的上采样结果 (8 192 个点); 第 4 行是使用动态图卷积提取触觉特征并且加入两次触摸信息的上采样结果 (8 192 个点)。

从图 6(a) 可以看出, 当低分辨率点云在边缘有空缺时, 没有加入触觉信息的上采样结果没有很好地填补空缺, 加入触觉信息的上采样结果可以相对均匀地填补空缺。从图 6(b)(c) 可以明显地看出, 没有加入触觉信息时的上采样结果容易出现分布不均匀的问题, 加入触觉后的高分辨率点云整体上更加均匀, 边缘更加平滑。图 6(c) 中薄片添加触觉辅助后在整体质量上有显著提升, 但是孔洞部分被填充的现象没有明显改善。这是由于现有数据集中两个触觉点云都位于该薄片的外部边缘, 所以对恢复孔洞细节起到的改进作用较小。但是原则上倘若添加位于孔洞内部边缘位置的触觉点云, 将会对恢复孔洞细节起到改善作用。如何通过优化策略来优化触觉传感器触碰物体的位置, 将是下一步工作的重点。由可视化结果对比可得出, 加入触觉信息后, 不仅会影响到点云上采样时的局部效果, 而且触觉信息还会作为全局信息的一部分对上采样结果产生影响, 得到的高分辨率点云从视觉效果上来看更加均匀、局部异常点更少。

同时, 对上述 3 个物体模型的可视化结果进行了定量分析, 表 2 是 3 个物体上采样的实验结果, 评价指标为倒角距离 CD。表中第 1 行是不加入触觉信息时上采样结果与真实高分率点云的倒角距离计算结果; 第 2 行是使用动态图卷积对触觉特征进行提取时, 加入一次触摸信息进行辅助的上采样结果; 同理, 第 3 行是加入两次触摸信息时的倒角距离指标。从表中可以看到对于复杂物体(圆环、螺母), 加入触觉的提升更为明显, 而且加入两次触觉比加入一次触觉效果有一定提升。对于简单物体(薄片), 加入触觉的提升效果不是特别显著。造成以上结果的原因是由于简单物体, 其结构较为简单, 点云分布较为规律, 在不加入触觉信息时已经可以得到




图6 本文算法在不同物体上进行上采样的可视化效果
Fig. 6 Visualization results of the proposed algorithm for upsampling on different objects ((a) cirque; (b) nut; (c) slice)

很好的上采样结果。因此加入触觉信息后提升效果不明显;而对于复杂物体,常常有弧形结构、孔状结构等,自身上采样结果较差,触觉信息提供了额外的局部信息和全局信息,可以更好地辅助超分任务的完成,提升效果更加明显。

此外,为了进一步验证使用本文算法的有效性

以及上采样得到的超分点云的质量,表3记录了使用密度感知倒角距离(density-aware chamfer distance, DCD)(Wu等,2021)作为评价指标的结果对比。DCD定义为

$$DCD(P, Q) = \frac{1}{2} \left[\frac{1}{|P|} \sum_{p \in P} \left(1 - \frac{1}{nq} e^{-\alpha \|p - q'\|_2} \right) + \frac{1}{|Q|} \sum_{q \in Q} \left(1 - \frac{1}{np} e^{-\alpha \|q - p'\|_2} \right) \right] \quad (4)$$

式中, P 代表网络预测的高分点云, Q 代表真实高分点云, $p \in P$ 代表预测点云中的点, $q \in Q$ 代表真实高分分辨率点云中的点。 α 为比例因子,参考Wu等人(2021)设置为1 000。 nq 表示在 P 中有 nq 个以点 q 作为距离最小的点, np 表示在 Q 中有 np 个以点 p 作为距离最小的点, p' 和 q' 的定义为

表2 本文算法对不同物体上采样的结果对比(CD)
Table 2 Results of the proposed algorithm for upsampling on different objects (CD)

触摸次数	圆环	螺母	薄片
不添加	4.199×10^{-3}	3.241×10^{-3}	3.781×10^{-4}
1	2.599×10^{-3}	2.127×10^{-3}	3.126×10^{-4}
2	2.445×10^{-3}	2.041×10^{-3}	2.905×10^{-4}

$$p' = \min_{p \in P} \|q - p\|_2 \tag{5}$$

$$q' = \min_{q \in Q} \|p - q\|_2 \tag{6}$$

相比 CD,DCD 可以更好地体现点云的分布,并且不会被密集的局部点云所影响,更加关注局部结构的均衡分布。从表 3 中数据可以看出,加入触觉信息得到的超分点云指标更好,意味着触觉信息的加入可以提高超分点云的质量,一定程度上改善点云的均匀分布。

表 3 不同物体上采样的结果对比(DCD)
Table 3 Results of upsampling on different objects(DCD)

触摸次数	圆环	螺母	薄片
不添加	7.767×10^{-1}	7.125×10^{-1}	5.655×10^{-1}
1	7.433×10^{-1}	6.886×10^{-1}	5.510×10^{-1}
2	7.430×10^{-1}	6.871×10^{-1}	5.489×10^{-1}

3.4 对比实验

为了进一步验证触觉融合的有效性以及本文算法的优越性,在 3DVT 数据集的基础上与其他算法进行了对比实验。

实验结果如表 4 所示,其中本文算法指使用动态图卷积提取特征并且融合,评价指标为平均倒角距离 CD。其中输入低分辨率点云为 512 个点,每个触觉点云为 512 个点,输出高分辨率点云为 8 192 个

点,上采样倍率为 16。表 4 中记录了 PU-GAN(Li 等, 2019)和 Grad-PU(He 等, 2023)的实验结果,分别为 4.634×10^{-3} 、 2.372×10^{-3} 。本文算法在不加入触觉信息时的实验结果为 3.009×10^{-3} ,比 PU-GAN 算法效果更好,但是次于 Grad-PU 算法;加入两次触觉信息进行辅助的超分实验结果为 1.916×10^{-3} ,优于 Grad-PU 算法,平均倒角距离降低了 19.22%。

表 4 不同算法实验结果(CD)
Table 4 Experimental results of different algorithms(CD)

模型	触摸次数		
	不添加	1	2
Grad-PU	2.372×10^{-3}	/	/
PU-GAN	4.634×10^{-3}	/	/
本文	3.009×10^{-3}	1.931×10^{-3}	1.916×10^{-3}

注:“/”表示不参与对比。

为了更加直观地表示不同算法得到的高分辨率点云的区别,使用训练好的模型在测试集上进行定性分析。如图 7 所示,选取一个木板物体模型进行可视化并且对局部进行放大观察。其中图 7(a)表示低分辨率点云(512 个点),阴影部分是两块密集的触觉点云,每个触觉点云同样包含 512 个点,图 7(b)是真实高分辨率点云 GT(8 192 个点)。图 7(c)是使




图 7 不同算法在同一物体上进行上采样的可视化效果

Fig. 7 Visualization results of different algorithms for upsampling on the same object

用动态图卷积提取触觉特征并且加入两次触摸信息的上采样结果(8 192个点),图7(d)是不加入触觉信息的上采样结果(8 192个点)。图7(e)和图7(f)分别表示PU-GAN和Grad-PU算法的上采样结果。从图中可以看出,不加触觉信息的上采样结果图7(d)和PU-GAN的上采样结果图7(e)在木板的缺口处异常点较多且点云整体分布不均匀。Grad-PU的上采样结果在缺口处有所改善,本文算法图7(c)异常点最少,表面更加光滑,并且木板主体没有较大的空洞。

同时,本节对上述模型的可视化结果进行了定量分析,如表5所示。本文算法在加入两次触觉信息后取得了最低的平均倒角距离 1.197×10^{-3} ,优于Grad-PU算法。综上所述,本节实验充分说明了触觉信息的融合可以显著改善超分任务的实验结果,进一步验证了本文算法在超分实验中的优越性。

表5 不同算法上采样结果(CD)

Table 5 Upsampling results of different algorithms(CD)

模型	触摸次数	
	不添加	2
Grad-PU	1.309×10^{-3}	/
PU-GAN	1.405×10^{-3}	/
本文	1.397×10^{-3}	1.197×10^{-3}

注:“/”表示不参与对比。

3.5 噪声实验

为了验证本文基于图卷积的触觉辅助点云超分网络的鲁棒性,在不同的噪声水平下用加性高斯噪声扰动输入点云。表6是加入两次触觉时加性高斯噪声影响下的实验结果,评价指标为倒角距离CD。通过对比可以看出,在噪声水平为1%和3%时,加入触觉信息均比不加触觉信息取得了更好的实验结果。并且加入触觉信息后,噪声对网络的测试结果影响更小,表明本文的网络具有较强的鲁棒性。

表6 噪声影响下的实验结果对比(两次触觉)

Table 6 Experimental results under the influence of noise (2 touches)

模型	噪声水平		
	0	1%	3%
不添加触觉信息	3.009×10^{-3}	3.132×10^{-3}	3.331×10^{-3}
使用动态图卷积提取特征	1.916×10^{-3}	1.954×10^{-3}	2.001×10^{-3}

3.6 模型复杂度

本文模型中一次触觉与两次触觉特征提取模块共享参数,保证了触觉次数增加时,模型参数量不变。表7显示了不同触摸次数下,模型的参数量大小以及处理一个低分点云所需要的平均时间。从中可以看出,相比于不添加触觉信息的模型,本文模型中触觉特征初步提取模块的动态图卷积会带来参数量的增长,但是两次触觉点云共享参数的设计使得模型大小不会随着触摸次数的增加而增加。同时,触觉特征初步提取模块处理的触觉点云点数较多,并且在每次动态图卷积中需要使用KNN算法重新构建图结构,增加了计算成本,需要的处理时间也会随之增长。但增长幅度在可接受范围内,可以满足实际应用的实时需求。

表7 不同触摸次数下的模型相关参数

Tabel 7 Model parameters under different touch times

触摸次数	参数量/KB	平均处理时间/ms
0	21.0	4.1
1	37.1	9.6
2	37.1	12.7

4 结 论

本文首次在点云超分任务中引入了触觉点云信息,提出了一种基于图卷积的触觉信息辅助的点云超分网络,利用触觉点云信息中包含的局部特征和全局特征,可以更好地完成点云的超分任务。本文采用动态图卷积对触觉点云进行初步特征提取,并与低分点云特征融合后进行统一处理,实验结果表明,触觉信息的辅助使点云超分任务在定量、定性上都有所改善。通过触觉信息的辅助,可以得到更精确的超分辨率点云,并且点云的分布更加均匀,一定程度上会对低分点云的空缺进行均匀填补。同时,本文网络在不同加性高斯噪声的影响下表现出较强的鲁棒性。此外,在与现有算法的对比实验中,本文算法也取得了最好的超分效果。

本文提出了一种新的范式,使用多模态信息融合完成点云超分任务,在点云超分网络中加入触觉信息进行辅助,并且在实验中验证了相比于不加入触觉信息取得了明显的提升,证实了此方法的可行

性和有效性。其优越性在于,在不更新网络技术架构的基础上,加入触觉信息比原有方法效果更好。本文网络构建在图卷积网络架构之上,同样地,这种方法可以应用于更先进的网络架构中,比如Pu-Transformer,这也是下一步工作的重点。

近年来,工业机器人的应用取得迅速的发展。在某些情况下需要视觉传感器和配备触觉传感器的机械臂协同操作来完成特定任务。将触觉信息与视觉数据相结合,并利用触觉辅助点云上采样,即使在有限数量的点云下也可以完成任务。因此,该方法可以为点云分类和目标检测等高级视觉任务提供高质量的点云,为点云的进一步发展应用奠定了基础。

值得注意的是,本文只设计了加入一次、两次触摸信息的网络并进行实验,随着触摸次数的增加,特征提取和特征融合应该具有较强的扩展性。同时在本文的可视化实验中,上采样得到的高分辨率点云往往会出现过于密集和过于稀疏的区域,导致点云分布不均匀。因此未来工作的重点是设计出一种可以满足任意增加触觉次数、扩展性更强的网络,并且在训练的损失函数中使用合理的计算处理对点云的均匀性进行一定的约束,以达到更好的上采样结果。

参考文献(References)

- Alexa M, Behr J, Cohen-Or D, Fleishman S, Levin D and Silva C T. 2003. Computing and rendering point set surfaces. *IEEE Transactions on Visualization and Computer Graphics*, 9(1): 3-15 [DOI: 10.1109/TVCG.2003.1175093]
- Guo Y L, Wang H Y, Hu Q Y, Liu H, Liu L and Bennamoun M. 2021. Deep learning for 3D point clouds: a survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(12): 4338-4364 [DOI: 10.1109/TPAMI.2020.3005434]
- He Y, Tang D H, Zhang Y D, Xue X Y and Fu Y W. 2023. Grad-PU: arbitrary-scale point cloud upsampling via gradient descent with learned distance functions//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada: IEEE: 5354-5363 [DOI: 10.1109/CVPR52729.2023.00518]
- Hu Q Y, Yang B, Xie L H, Rosa S, Guo Y L, Wang Z H, Trigoni N and Markham A. 2020. RandLA-net: efficient semantic segmentation of large-scale point clouds//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA: IEEE: 11105-11114 [DOI: 10.1109/CVPR42600.2020.01112]
- Lambeta M, Chou P W, Tian S, Yang B, Maloon B, Most V R, Stroud D, Santos R, Byagowi A, Kammerer G, Jayaraman D and Calandra R. 2020. DIGIT: a novel design for a low-cost compact high-resolution tactile sensor with application to in-hand manipulation. *IEEE Robotics and Automation Letters*, 5(3): 3838-3845 [DOI: 10.1109/LRA.2020.2977257]
- Li R, Platt R, Yuan W Z, Pas A T, Roscup N, Srinivasan M A and Adelson E. 2014. Localization and manipulation of small parts using gelsight tactile sensing//*Proceedings of 2014 IEEE/RSJ International Conference on Intelligent Robots and Systems*. Chicago, USA: IEEE: 3988-3993 [DOI: 10.1109/IROS.2014.6943123]
- Li R H, Li X Z, Fu C W, Cohen-Or D and Heng P A. 2019. PU-GAN: a point cloud upsampling adversarial network//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision*. Seoul, Korea (South): IEEE: 7202-7211 [DOI: 10.1109/ICCV.2019.00730]
- Li R H, Li X Z, Heng P A and Fu C W. 2021. Point cloud upsampling via disentangled refinement//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, USA: IEEE: 344-353 [DOI: 10.1109/CVPR46437.2021.00041]
- Qi C R, Su H, Mo K C and Guibas L J. 2017. PointNet: deep learning on point sets for 3D classification and segmentation//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE: 77-85 [DOI: 10.1109/CVPR.2017.16]
- Qian G C, Abualshour A, Li G H, Thabet A and Ghanem B. 2021. PU-GCN: point cloud upsampling using graph convolutional networks//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, USA: IEEE: 11678-11687 [DOI: 10.1109/CVPR46437.2021.01151]
- Qiu S, Anwar S and Barnes N. 2022a. Geometric back-projection network for point cloud classification. *IEEE Transactions on Multimedia*, 24: 1943-1955 [DOI: 10.1109/TMM.2021.3074240]
- Qiu S, Anwar S and Barnes N. 2022b. PU-transformer: point cloud upsampling transformer//*Proceedings of the 16th Asian Conference on Computer Vision*. Macao, China: Springer: 2475-2493 [DOI: 10.1007/978-3-031-26319-4_20]
- Qiu S, Wu Y F, Anwar S and Li C Y. 2021. Investigating attention mechanism in 3D point cloud object detection//*Proceedings of 2021 International Conference on 3D Vision (3DV)*. London, UK: IEEE: 403-412 [DOI: 10.1109/3DV53792.2021.00050]
- Rustler L, Lundell J, Behrens J K, Kyrki V and Hoffmann M. 2022. Active visuo-haptic object shape completion. *IEEE Robotics and Automation Letters*, 7(2): 5254-5261 [DOI: 10.1109/LRA.2022.3152975]
- Smith E J, Calandra R, Romero A, Gkioxari G, Meger D, Malik J and Drozdal M. 2020. 3D shape reconstruction from vision and touch//*Proceedings of the 34th Conference on Neural Information Processing Systems*. Vancouver, Canada: Curran Associates Inc.: 14193-14206 [DOI: 10.48550/arXiv.2007.03778]

- Thomas H, Qi C R, Deschaud J E, Marcotegui B, Goulette F and Guibas L J. 2019. KPConv: flexible and deformable convolution for point clouds//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South): IEEE: 6410-6419 [DOI: 10.1109/ICCV.2019.00651]
- Wang S X, Wu J J, Sun X Y, Yuan W Z, Freeman W T, Tenenbaum J B and Adelson E H. 2018. 3D shape perception from monocular vision, touch, and shape priors//Proceedings of 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Madrid, Spain: IEEE: 1606-1613 [DOI: 10.1109/IROS.2018.8593430]
- Wang Y, Sun Y B, Liu Z W, Sarma S E, Bronstein M M and Solomon J M. 2019a. Dynamic graph CNN for learning on point clouds. ACM Transactions on Graphics (TOG), 38(5): 1-12 [DOI: 10.1145/3326362]
- Wang Y F, Wu S H, Huang H, Cohen-Or D and Sorkine-Hornung O. 2019b. Patch-based progressive 3D point set upsampling//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 5951-5960 [DOI: 10.1109/CVPR.2019.00611]
- Watkins-Valls D, Varley J and Allen P. 2019. Multi-modal geometric learning for grasping and manipulation//Proceedings of 2019 International Conference on Robotics and Automation (ICRA). Montreal, Canada: IEEE: 7339-7345 [DOI: 10.1109/ICRA.2019.8794233]
- Wu T, Pan L, Zhang J Z, Wang T, Liu Z W and Lin D H. 2021. Density-aware chamfer distance as a comprehensive metric for point cloud completion//Proceedings of the 35th International Conference on Neural Information Processing Systems. Red Hook, USA: Curran Associates Inc.
- Yu L Q, Li X Z, Fu C W, Cohen-Or D and Heng P A. 2018. PU-Net: point cloud upsampling network//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE: 2790-2799 [DOI: 10.1109/CVPR.2018.00295]
- Yuan W Z, Dong S Y and Adelson E H. 2017. GelSight: high-resolution robot tactile sensors for estimating geometry and force. Sensors, 17(12): #2762 [DOI: 10.3390/s17122762]
- Zhang J X. 2022. Research on Point Cloud Super-Resolution and Completion Algorithm Based on Graph Convolution. Beijing: Beijing Jiaotong University (张健翔. 2022. 基于图卷积的点云超分辨率和补全算法研究. 北京: 北京交通大学)
- Zhang Z J. 2018. Improved adam optimizer for deep neural networks//IEEE/ACM 26th International Symposium on Quality of Service (IWQoS). Banff, Canada: IEEE: 1-2 [DOI: 10.1109/IWQoS.2018.8624183]

作者简介

张驰,男,硕士研究生,主要研究方向为三维成像。

E-mail: 2634852973@qq.com

王琴,通信作者,女,教授,主要研究方向为量子信息和单光子成像。E-mail: qinw@njupt.edu.cn

李剑,男,讲师,主要研究方向为量子光学量子通信和三维成像。E-mail: jianli@njupt.edu.cn

王普正,男,硕士研究生,主要研究方向为三维成像。

E-mail: 1002386667@qq.com

石键瀚,男,硕士研究生,主要研究方向为三维成像。

E-mail: 1490249761@qq.com

王怀钰,男,硕士研究生,主要研究方向为三维成像。

E-mail: 2075887290@qq.com