



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象 图形学报

2020
08
VOL.25

ISSN1006-8961
CN11-3758/TB



三维建模和步态识别 P1539



第25卷第8期（总第292期）

2020年8月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院

主办单位 中国科学院遥感与数字地球研究所

中国图象图形学学会

北京应用物理与计算数学研究所

主 编 顾行发

编辑出版《中国图象图形学报》编辑出版委员会

通信地址 北京市海淀区北四环西路19号

邮 编 100190

电子信箱 jig@radi.ac.cn

电 话 010-58887035

网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号

总 发 行 北京报刊发行局

订 购 全国各地邮局

海外发行 中国国际图书贸易集团有限公司

（邮政信箱：北京399信箱 邮编：100048）

印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian

Monthly, Started in 1996

Superintended by Chinese Academy of Sciences

Sponsored by Institute of Remote Sensing and Digital Earth, CAS

China Society of Image and Graphics

Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Gu Xingfa

Editor, Publisher Editorial and Publishing Board of Journal of
Image and Graphics

Address No. 19, North 4th Ring Road West, Haidian District,
Beijing, P. R. China

Zip code 100190

E-mail jig@radi.ac.cn

Telephone 010-58887035

Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals

Domestic All Local Post Offices in China

Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China))

Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB


ISSN 1006-8961

CODEN ZTTXFZ


国外发行代号 M1406

国内邮发代号 82-831


国内定价 60.00元



神经纤维跟踪算法研究进展
(第1513页)



结合注意力机制的双路径语义分割(第1627页)



突变策略下多通路Metropolis光照传播(第1658页)

综述

神经纤维跟踪算法研究进展

李茂, 何建忠, 冯远静 1513

多模态生物特征提取及相关性评价综述

杨雪鹤, 刘欢喜, 肖建力 1529

图像分析和识别

异常步态3维人体建模和可变视角识别

罗坚, 黎梦霞, 罗诗光 1539

扩展点态卷积网络的点云分类分割模型

张新良, 付陈琳, 赵运基 1551

特征一致性约束的视频目标分割

征煜, 陈亚当, 郝川艳 1558

增量角度域损失和多特征融合的地标识别

毛雪宇, 彭艳兵 1567

部件检测和语义网络的细粒度鞋类图像检索

陈前, 刘骊, 付晓东, 刘利军, 黄青松 1578

图像理解和计算机视觉

图注意力网络的场景图到图像生成模型

兰红, 刘秦邑 1591

跨层多模型特征融合与因果卷积解码的图像描述

罗会兰, 岳亮亮 1604

Haar-like特征双阈值Adaboost人脸检测

刘禹欣, 朱勇, 孙结冰, 王一博 1618

结合注意力机制的双路径语义分割

翟鹏博, 杨浩, 宋婷婷, 余亢, 马龙祥, 黄向生 1627

自学习规则下的多聚焦图像融合

刘子闻, 罗晓清, 张战成 1637

车路视觉协同的高速公路防碰撞预警算法

蔡创新, 高尚兵, 周君, 黄子赫 1649

计算机图形学

突变策略下多通路Metropolis光照传播

贺怀清, 赵煜桢, 刘浩翰, 王旭 1658

融合DNN与AABB-圆形包围盒自碰撞检测

靳雁霞, 程琦甫, 张晋瑞, 齐欣, 马博, 贾瑶 1674

医学图像处理

压缩感知下溃疡性结肠炎辅助诊断

杨海清, 孙道洋 1684

特征重用和注意力机制下肝肿瘤自动分类


冯诺, 宋余庆, 刘哲 1695

融合注意力机制和高效网络的糖尿病视网膜病变识别与分类


张子振, 刘明, 朱德江 1708

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Research progress of neural fiber tracking(P1513)



Two-path semantic segmentation algorithm combining attention mechanism(P1627)



Improved multiplexed Metropolis light transport based on fusion mutation strategy(P1658)

Review

Research progress of neural fiber tracking

Li Mao, He Jianzhong, Feng Yuanjing 1513

Extraction and relevance evaluation for multimodal biometric features

Yang Xuehe, Liu Huanxi, Xiao Jianli 1529

Image Analysis and Recognition

Parametric 3D body modeling and view-invariant abnormal gait recognition

Luo Jian, Li Mengxia, Luo Shiguang 1539

Extended pointwise convolution network model for point cloud classification and segmentation

Zhang Xinliang, Fu Chenlin, Zhao Yunji 1551

Video object segmentation algorithm based on consistent features

Zheng Yu, Chen Yadang, Hao Chuanyan 1558

Landmark recognition based on ArcFace loss and multiple feature fusion

Mao Xueyu, Peng Yanbing 1567

Fine-grained shoe image retrieval by part detection and semantic network

Chen Qian, Liu Li, Fu Xiaodong, Liu Lijun, Huang Qingsong 1578

Image Understanding and Computer Vision

Image generation from scene graph with graph attention network

Lan Hong, Liu Qinyi 1591

Image caption based on causal convolutional decoding with cross-layer multi-model feature fusion

Luo Huilan, Yue Liangliang 1604

Improved Adaboost face detection algorithm based on Haar-like feature statistics

Liu Yuxin, Zhu Yong, Sun Jiebing, Wang Yibo 1618

Two-path semantic segmentation algorithm combining attention mechanism

Zhai Pengbo, Yang hao, Song Tingting, Yu Kang, Ma Longxiang, Huang Xiangsheng 1627

Multi-focus image fusion with a self-learning fusion rule

Liu Ziwen, Luo Xiaoqing, Zhang Zhancheng 1637

Freeway anti-collision warning algorithm based on vehicle-road visual collaboration

Cai Chuangxin, Gao Shangbing, Zhou Jun, Huang Zihe 1649

Computer Graphics

Improved multiplexed Metropolis light transport based on fusion mutation strategy

He Huaqing, Zhao Yuzhen, Liu Haohan, Wang Xu 1658

Self-collision detection algorithm based on fused DNN and AABB-circular bounding box

Jin Yanxia, Cheng Qifu, Zhang Jinrui, Qi Xin, Ma Bo, Jia Yao 1674

Medical Image Processing

Adjunctive diagnosis of ulcerative colitis under compressed sensing

Yang Haiqing, Sun Daoyang 1684

Automatic classification of liver tumors by combining feature reuse and attention mechanism

Feng Nuo, Song Yuqing, Liu Zhe 1695

Automatic recognition and classification of diabetic retinopathy images by combining an attention mechanism and an efficient network

Zhang Zizhen, Liu Ming, Zhu Dejiang 1708

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2020)08-1551-07

论文引用格式: Zhang X L, Fu C L and Zhao Y J. 2020. Extended pointwise convolution network model for point cloud classification and segmentation. Journal of Image and Graphics, 25(08):1551-1557 (张新良, 付陈琳, 赵运基. 2020. 扩展点态卷积网络的点云分类分割模型. 中国图象图形学报, 25(08):1551-1557) [DOI:10.11834/jig.190508]

扩展点态卷积网络的点云分类分割模型

张新良, 付陈琳, 赵运基

河南理工大学电气工程与自动化学院, 焦作 454000

摘要: **目的** 点态卷积网络用于点云分类分割任务时,由于点态卷积算子可直接处理点云数据,逐点提取局部特征向量,解决了结构化点云带来的维度剧增和信息丢失等问题。但是为了保持点云数据结构的一致性,点态卷积算子及卷积网络模型本身并不具有描述点云全局特征的结构,因此,对点态卷积网络模型进行扩展,扩展后的模型具有的全局特征是保证分类分割准确性的重要依据。**方法** 构造中心点放射模型来描述点云逐点相对于全局的几何约束关系,将其引入到点态卷积网络的特征拼接环节扩展特征向量,从而为点态卷积网络构建完善的局部—全局特征描述,用于点云数据的分类分割任务。首先,将点云视为由中心点以一定方向和距离放射到物体表面的点的集合,由中心点指向点云各点的放射矢量,其矢量大小确定了各点所存在的曲面和对于中心点的紧密程度,矢量方向描述了各点对于中心点的包围方向及存在的射线。进而由点云中的坐标信息得到点云的中心点,逐点计算放射矢量构造中心点放射模型,用以描述点云的全局特征。然后,利用点云数据的坐标信息来检索点的属性,确定卷积中参与特定点卷积运算的邻域,点态卷积算子遍历点云各点,输出逐点局部特征,进一步经多层点态卷积操作得到不同深度上的局部特征描述。最后,将中心点放射模型的全局特征和点态卷积的局部特征拼接,完成特征扩展,得到点态卷积网络的扩展模型。拼接后的局部—全局特征输入全连接层用于类标签预测,输入点态卷积层用于逐点标签预测。**结果** 在 ModelNet40 和 S3DIS (Stanford large-scale 3D indoor spaces dataset) 数据集上分别进行实验,验证模型的分类分割性能。在 ModelNet40 的分类实验中,与点态卷积网络相比,扩展后的网络模型在整体分类精度和类属分类精度上分别提高 1.8% 和 3.5%,在 S3DIS 数据集的分割实验中,扩展后的点态卷积网络模型整体分割精度和,类属分割精度分别提高 0.7% 和 2.2%。**结论** 引入的中心点放射模型可以有效获取点云数据的全局特征,扩展后的点态卷积网络模型实现了更优的分类和分割效果。

关键词: 点云;点态卷积;中心点放射模型;分类;分割;特征扩展

Extended pointwise convolution network model for point cloud classification and segmentation

Zhang Xinliang, Fu Chenlin, Zhao Yunji

School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454000, China

Abstract: Objective A pointwise convolution network (PCN) has great potential for the classification and segmentation of point cloud data. The pointwise convolution operator in each layer directly functions on the point cloud data to generate the local feature vectors point-by-point. The PCN can solve the problems caused by dimension increase and information loss

收稿日期:2019-10-04;修回日期:2019-12-13;预印本日期:2019-12-20

基金项目:河南省创新型科技人才队伍建设工程项目(CXTD2016054);中原高水平人才专项支持计划项目(ZYQR201912031);河南理工大学基础科研基金项目(NSFRF170501, 2018YJ04);2019年河南省高等学校大学生实践创新训练计划项目(201910460032)

Supported by: Innovation Scientists and Technicians Troop Construction Projects of Henan Province(CXTD2016054)

because of the avoidance of point data structuration. However, the structure of PCN is responsible for the consistent maintenance of the point cloud during the implementation of pointwise convolution. Consequently, the PCN has no constituent that can describe the global features of point cloud. The PCN essentially needs a characteristic expansion considering the global features in terms of classification and segmentation accuracies for the point cloud data. **Method** A so-called central point radiation model is proposed in this paper to pointwisely describe the global geometric properties. With the introduction of the radiation model into feature concatenation, the resultant extended PCN (EPCN) realizes a complete representation of local and global features for point cloud classification and segmentation. First, the point cloud in the central point radiation model is regarded as a set of projection point on the object surface by a radiation line from the central point. The amplitude of radiation vector determines the owner surface and tightness of each point around the central point, and the direction specifies the pointwise encircling direction and contributing radiation line. The central point is prescribed by the calculation of coordinate information in the point cloud, and the pointwise radiation vector is generated. Thus, the central point radiation model is constructed to describe global features. Second, the local feature description of the point cloud data at each depth is obtained through a multilayer pointwise convolution. The coordinates of the point cloud data provide an index for retrieving point attributes and determining the neighborhood points involved in the convolution of a concerned point. The pointwise convolution traverses all points in the point cloud and completely yields the pointwise local features. Finally, an EPCN is derived through the concatenation of the global features from the central point radiation model and the local features from the pointwise convolution. The complete feature description vector is adopted as the input of the fully connected layer of PCN for the category label prediction, and the input of the pointwise convolution layer is used for the label prediction point-by-point. **Result** The classification and segmentation performance of the proposed EPCN model are validated on the point cloud data sets of ModelNet40 and S3DIS (Stanford large-scale 3D indoor dataset), respectively. The EPCN classification on ModelNet40 leads to 1.8% and 3.5% increases in mean and m -class accuracies compared with the PCN. The EPCN segmentation on S3DIS provides 0.7% and 2.2% increases in s -mean and ms -class accuracies compared with the PCN. **Conclusion** Experimental results verify the effectiveness of the proposed central point radiation model for the global feature extraction of the point cloud data. The EPCN model provides an improved performance in terms of classification and segmentation.

Key words: point cloud; pointwise convolution; central point radiation model; classification; segmentation; feature extension

0 引言

理解 3 维场景,完成语义场景分割和对象识别任务,获取对象上下文信息(Cavaliere 等,2019;Qiu 等,2019),是机器人和无人机实现自主导航的核心技术。基于 3 维点云数据和卷积神经网络(convolutional neural networks, CNNs)的场景理解是一个新的研究热点(Garcia-Garcia 等,2017;Su 等,2015)。相比于 3 维体积数据和多视图数据 CNNs 模型,3 维点云数据具有结构灵活、处理高效、信息丰富等优势,使其在无人驾驶、实时定位与建图(simultaneous localization and mapping, SLAM)等领域体现出更广阔的应用前景(Davison 等,2007)。

3 维点云结合 CNNs 完成语义场景分割关键在于非结构化点云特征的提取。解决这一问题常用的方式有两种,结构化点云方法和 CNNs 网络直接学

习的方法。结构化点云的方法如体素化点云 CNNs 模型(Huang 和 You, 2016; Klovov 和 Lempitsky, 2017; Maturana 和 Scherer, 2015; Le 和 Duan, 2018; Wang 等, 2017; Zhou 和 Tuzel, 2018)、网格化点云 CNNs 模型(Feng 等, 2018; Hanocka 等, 2019)等。VoxNet(Maturana 和 Scherer, 2015)将点云置于固定的体素框架中,从而使得目标的 3 维点被框架内指定索引的体素唯一确定。在此基础上,Huang 和 You(2016)结合 3D 卷积神经网络,对点云二值体素化,实现了现实场景中点云标签化,在大规模点云分割中取得了不错的效果。其不足是高分辨率时点云数据量庞大,网络模型处理时间过长,内存消耗严重。O-CNN(octree-based CNN)(Wang 等, 2017)对结构化点云方法进一步优化,采用分层编码的八叉树结构,结构化点云。将体素覆盖于目标表面,建立快速的邻域搜索,并将编码后的点云送入网络实现语义分割。Truc(Le 和 Duan, 2018)选取体素内固定

数目点的坐标张成特征向量,来解决分辨率不足的问题,该方法一定程度上可平衡分辨率与内存消耗之间的矛盾。上述结构化点云方法都需要设计点云数据的预处理过程。网络学习方法中,PointNet模型(Charles等,2017)通过学习一个顺序不变性函数将送入网络的有序点云转换为有序不变性的点云。PointCNN模型(Li等,2018)改进为等方差意义下的点云变换函数,这一类模型提出了直接处理点云的网络架构,因此避免了预处理点云带来的维度剧增、信息丢失等问题,提高了点云数据的处理效率,但这类网络结构仍然十分复杂。Pointwise(Hua等,2018)通过设计点态卷积核将特征提取细化到点云的每一个点,构建了一种点态卷积网络模型(pointwise convolutional network, PCN),简化点云数据CNNs模型结构,取得了具有竞争力的结果。

但是受点态卷积方式需与点云数据保持一致性的要求所限,PCN本身并不具有描述点云全局特征的网络结构,而全局特征是指导CNNs完成分类分割任务的重要依据。基于此,本文引入中心点放射模型来描述逐点相对于全局过渡量的特征,结合点态卷积算子的局部特征提取运算,构造了一种扩展的点态卷积网络模型(extended pointwise convolutional network, EPCN),提高点云数据的分类分割精度。

1 点态卷积局部特征网络

点态卷积核点对点云的处理过程如图1所示。图中九宫格中心星型点表示点云中点进行点态卷积运算的当前点,即点态卷积的中心。方格表示点态卷积核参与运算的邻域范围,并为点态卷积运算邻域范围内的所有点分配相同的权重。卷积时点态卷积核依次逐点为中心,动态查询附近的邻近点,并将邻近点绑定到内核单元格中进行卷积操作,作为当前点的卷积结果。

点态卷积网络本质上是一种局部特征网络。点态卷积仅能考虑点云局部表面的邻点,在特定点卷积运算时,网络模型中每一层卷积结果只包含各点局部邻域的特征描述。如图2所示,若点A、B、C为点云的3个点,以A、B和C为圆心的圆为点态卷积邻域搜索范围,圆锥的顶点 A_1 、 B_1 和 C_1 代表经一次点态卷积后对应的卷积结果。由图2可以看出, A_1 中含有点A相对于B的特征, B_1 中含有点B相对于




图1 点态卷积示意图

Fig. 1 Diagram of pointwise convolution operator

A和C的特征, C_1 中含有点C相对于B的特征,但没有A和C关系特征的提取。由点态卷积的性质可知,多层卷积网络,卷积层的增加仅丰富逐点相对局部邻域的特征表达,模型结构本身缺乏当前点相对于全局的特征描述。




图2 特征提取示意图

Fig. 2 Feature extraction schematic diagram

扩大点态卷积的感知域,可以在一定程度上补偿网络模型的全局特征描述能力,但对于逐点进行的点态卷积操作,极小邻域搜索范围增加将导致运算量剧增,模型运行效率低。

2 扩展点态卷积网络模型

以中心点为全局信息的过渡量,将点云视为由中心点以一定的距离和方向放射到物体表面的投影点的集合,构造中心点放射模型,如图3所示。点云中心点定义为

$$P_c(x_c, y_c, z_c) = \frac{1}{m^3} \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m P_t(x_i, y_j, z_k) \quad (1)$$

式中, $P_t(x_i, y_j, z_k)$ 为逐点点云数据, m 为点云在X、Y、Z各维度上点的个数。




图3 中心点辐射图

Fig. 3 Central point emission diagram

放射向量描述为

$$\mathbf{P}_e = \mathbf{P}_i - \mathbf{P}_c = d \cdot \angle \theta \quad (2)$$

式中, d 为放射向量 $\mathbf{P}_e$ 的幅值, 描述了点云相对于中心点的紧密程度, 确定了点所在的具体曲面; 矢量角 θ 描述了点云对中心点的包围方向, 并确定当前点 $\mathbf{P}_i$ 所在射线。

放射向量 $\mathbf{P}_e$ 唯一地确定了当前点相对于过渡量 $\mathbf{P}_c$ 的位置关系。因此, 中心点放射模型采用非网络的形式构造了当前点相对于全局的特征描述, 得到的特征和原始数据对应, 在构建网络时可与点态卷积核得到的局部特征相适配。

将中心点放射模型引入点态卷积网络中, 对卷积网络进行扩展, 完成点云的分类分割任务, EPCN 网络结构如图4所示。图4中, 点云数据经点态卷积层完成局部特征的提取。中心点放射模型完成全局特征的提取, 与逐层局部特征输出拼接, 构造每一个点的完备特征向量, 输入全连接层用于点云分类任务, 另一方面输入点态卷积层用于点云分割任务。同时, 网络从输入的点云数据中分离出点的坐标信息, 传递至每一层点态卷积, 用于逐点邻域查询和临近点属性检索。




图4 扩展点态卷积网络模型

Fig. 4 Extended pointwise convolution network model

扩展后网络的训练方法描述如下: 点态卷积运算应用于点云中的每一个点, 输出逐点的特征, 点态卷积核定义为

$$x_i^\tau = \sum_k \omega_k \frac{1}{|\Omega_i(k)|} \sum_{p_j \in \Omega_i(k)} x_j^{\tau-1} \quad (3)$$

式中, x_i^τ 是第 i 个点为中心卷积核的点卷积输出; $\Omega_i(k)$ 为卷积核的第 k 个子域, ω_k 为子域的权值, $|\Omega_i(k)|$ 为该子域内所有点, $x_j^{\tau-1}$ 为卷积核的输入, 即上一卷积层的输出。

设 L 为网络训练的损失函数, 损失函数对于点态卷积核输入的灵敏度函数可表示为

$$\frac{\partial L}{\partial x_j^{\tau-1}} = \sum_{i \in \Omega_j} \frac{\partial L}{\partial x_i^\tau} \frac{\partial x_i^\tau}{\partial x_j^{\tau-1}} \quad (4)$$

根据链式法则, 在反向传播过程中由 τ 层计算的梯度 $\partial L / \partial x_i^\tau$ 已知, 可得

$$\frac{\partial x_i^\tau}{\partial x_j^{\tau-1}} = \sum_k \omega_k \frac{1}{|\Omega_i(k)|} \sum_{p_j \in \Omega_i(k)} 1 \quad (5)$$

类似地, 用于卷积核权值调整的灵敏度函数可以通过遍历给定点 j 的所有邻域点 i 来定义, 即

$$\frac{\partial L}{\partial \omega_k} = \sum_i \frac{\partial L}{\partial x_i^\tau} \frac{\partial x_i^\tau}{\partial \omega_k} \quad (6)$$

式中

$$\frac{\partial x_i^\tau}{\partial \omega_k} = \frac{1}{|\Omega_i(k)|} \sum_{p_j \in \Omega_i(k)} x_j^{\tau-1} \quad (7)$$

由式(3)点态卷积工作原理和式(4)~(7)的网络训练灵敏度函数表达式可以看出, 与结构化点云卷积神经网络不同, 点态卷积不依赖网格或体素提供的结构化信息, 而是作用于点云中的每一个点, 逐点输出局部特征。点云在卷积之后与原始数据保持对应, 原始点的顺序只影响最终特征向量的排序而对卷积结果没有影响。

与传统卷积网络模型结构相比, EPCN 中没有池化层操作和点云处理的上采样与下采样过程, 简化了网络结构。卷积操作过程中点云数据的形式保持不变, 只需构建邻域查询加速结构, 模型运算的速度和性能大幅改进。

3 实验验证

使用 ModelNet40 (Wu 等, 2015) 和 S3DIS (Stanford large-scale 3D indoor dataset) (Armeni 等, 2016) 数据集对提出的扩展网络模型 EPCN 分类分割有效

性进行验证。实验硬件系统为 GPU Nvidia1080ti。软件环境由 ubuntu16.04、cuda9.0 和 cuDNN7.05 构成,深度学习框架采用 tensorflow1.8。EPCN 的网络参数设置,点态卷积核大小为 $3 \times 3 \times 3$,卷积核单元内的所有点权重相同;批处理大小 $\text{batch_size} = 32$,动量优化算法 $\text{momentum} = 0.9$,衰减周期 $\text{decay_steps} = 100\,000$, $\text{decay_rate} = 0.96$,采用亚当优化器,初始学习率为 10^{-3} 。

3.1 EPCN 分类模型测试

EPCN 的点云数据分类性能在 ModelNet40 数据集上进行测试,该数据集是斯坦福大学提供的点云基准数据集,含有训练集和测试集两部分,共 40 类物品的点云数据,同一类点云数据含有各自的点云数据和相同的类标签。

EPCN 模型以训练集迭代 200 次获得点云分类模型参数,测试过程 EPCN 输出点云模型的分类预测结果。分别定义网络模型的整体分类精度和类属分类精度。

整体分类精度定义为

$$m_a = \frac{t_c}{t_s} \quad (8)$$

式中, m_a 为模型的整体分类评估指标, t_c 为所有被正确预测的类的数量, t_s 为参与测试的所有点云模型的数量。

类属分类精度定义为

$$m_c = \frac{1}{40} \sum_{i=1}^{40} \frac{c_c}{s_c} \quad (9)$$

式中, m_c 反映了模型在每一类中的平均分类精度。 c_c 为当前类中被正确预测的类标签的数量, s_c 为参与测试的当前类中类标签总数。

EPCN 模型的分类精度分别为 $m_a = 84.7\%$, $m_c = 81.7\%$ 。

在同样的实验条件下,使用相同的训练数据集对 PCN 模型进行训练,经迭代 200 次后获得模型参数,模型的分类性能比较如表 1 所示。表 2 给出了两种算法对 ModelNet40 中每一类目标的分类准确率,图 5 描述了两种算法准确率对比曲线。可以看出,EPCN 在整体分类性能和每一类的平均分类性能上都优于传统的 PCN 模型,整体分类精度提升了 1.8%,类属分类精度提升了 3.5%,分类准确率提升高达 30% (wardrobe) 和 20% (curtain),最大准确率下降值为 9.3% (desk)。测试结果表明,中心点放射模型构建的全局特征描述能有效提高深

表 1 PCN 和 EPCN 分类性能对比

Table 1 Classification comparison of PCN and EPCN

方法	m_a	m_c
PCN	0.829 770	0.781 882
EPCN	0.847 039	0.816 771

注:加粗字体为分类性能最优值。

表 2 ModelNet40 数据集上 PCN 和 EPCN 逐类分类准确率

Table 2 Comparison of per-class accuracy of PCN and EPCN on ModelNet40

方法	airplane	bathtub	bed	bench	bookshelf	bottle	bowl	car	chair	cone
PCN	1.000	0.800	0.950	0.684	0.867	0.979	0.950	0.919	0.950	0.800
EPCN	1.000	0.780	0.940	0.737	0.867	0.980	0.950	0.919	0.950	0.900
	cup	curtain	desk	door	dresser	flower pot	glassbox	guitar	keyboard	lamp
PCN	0.650	0.550	<u>0.814</u>	0.750	0.547	0.150	0.707	1.000	1.000	0.778
EPCN	0.700	0.750	<u>0.721</u>	0.900	0.477	0.150	0.818	0.990	1.000	0.722
	laptop	mantel	monitor	nightstand	person	piano	plant	radio	rangehood	sink
PCN	1.000	0.889	0.869	0.690	0.842	0.835	0.717	0.650	0.859	0.700
EPCN	1.000	0.909	0.879	0.726	0.895	0.835	0.788	0.800	0.909	0.700
	sofa	stairs	stool	table	tent	toilet	Tv stand	vase	wardrobe	xbox
PCN	0.939	0.750	0.778	0.838	0.950	0.949	0.732	0.792	0.050	0.600
EPCN	0.970	0.800	0.778	0.859	0.950	0.949	0.753	0.771	0.350	0.800

注:加粗字体为类属分类准确率上升最高的两类,加下划线字体为类属分类准确率最大下降类。




图5 PCN 和 EPCN 模型分类准确度

Fig. 5 Classification results of PCN and EPCN

度网络模型分类性能。

3.2 EPCN 分割模型测试

使用 S3DIS 数据集对 EPCN 的点云分割性能进行测试。S3DIS 是真实场景的点云数据集, 每一个场景的点云分为 13 类。测试中, EPCN 分割模型对每一个点输出预测标签, 验证分割性能。

定义整体分割精度为

$$p_a = \frac{p_c^t}{p_s^t} \quad (10)$$

式中, p_a 为整体分割的评估指标, p_c^t 为所有预测正确的点的数量, p_s^t 为所有参与测试的点的数量。

定义类属分割精度为

$$p_c = \frac{1}{13} \sum_{j=1}^{13} \frac{p_{jc}^c}{c_{jp}^t} \quad (11)$$

式中, p_c 反映了网络模型在每一类中的平均分割精度。 p_{jc}^c 为当前类中预测正确点标签的数量, c_{jp}^t 为参与测试的当前类中所有点的数量。

EPCN 模型经 200 次迭代训练获得分割模型参数, 在测试集上的 $p_a = 83.4\%$, $p_c = 60.2\%$ 。

同样测试条件下, PCN 网络模型经 200 次迭代训练后, 模型的分割性能与 EPCN 对比如表 3 所示。

表3 PCN 和 EPCN 的点云分割性能对比

Table 3 Segmentation comparison of PCN and EPCN

方法	p_a	p_c
PCN	0.827 543	0.579 645
EPCN	0.834 322	0.601 984

注: 加粗字体为分割性能最优值。

由 S3DIS 数据集上的测试结果可以看出, 引入的中心点放射模型在 EPCN 场景分割过程中, 能提

供全局特征辅助信息, 对模型的分割性能提高有帮助, 相比于 PCN 分割模型, EPCN 的整体分割精度和类属分割精度分别提升了 0.7% 和 2.2%。

4 结 论

针对点态卷积网络用于点云分类分割任务时, 因点态卷积算子特性所限造成的全局特征缺失问题, 从完善网络模型对特征描述能力的角度入手, 通过构造中心点放射模型, 来描述点云逐点相对于全局的几何约束关系, 获得逐点全局特征。在网络的特征拼接部分引入该算子, 得到了点态卷积网络的局部—全局完备的特征描述, 进一步构造了扩展的点态卷积网络模型 EPCN, 用于点云数据的分类分割任务。在 ModelNet40 分类基准数据集和现实场景的 S3DIS 数据集的分类分割测试结果表明, 扩展的点态卷积网络模型有效提升了点云的分类分割精度, 保证了分类分割性能。

另外, 分析 EPCN 分类分割实验结果可以得到, 构建的全局特征对于分类任务的性能提升明显, 说明全局特征是分类问题中的重要依据。而对于点云分割任务, EPCN 点云分割性能虽然有一定程度提升, 但本质上局部特征网络 PCN 即可完成分割任务, 全局特征在 EPCN 分割性能的提升中贡献有限。

构建的中心点放射模型采用非网络的形式, 改进深度学习网络 PCN 的学习能力, 简化了网络的复杂程度, 全局特征可以直接与点态卷积提取的局部特征数据结构适配, 保证了网络的计算效能。下一步的工作, 将考虑引入网络算子进一步提取不同深度下中心点放射模型构建的全局特征, 使得逐点的特征描述进一步趋于完备。

参考文献 (References)

- Armeni I, Sener O, Zamir A R, Jiang H, Brilakis I, Fischer M and Savarese S. 2016. 3D semantic parsing of large-scale indoor spaces//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas; IEEE: 1534-1543 [DOI: 10.1109/CVPR.2016.170]
- Cavaliere D, Loia V, Saggese A, Senatore S and Vento M. 2019. Semantically enhanced UAVs to increase the aerial scene understanding. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 49 (3): 555-567 [DOI: 10.1109/TSMC.2017.

- 2757462]
- Charles R Q, Su H, Kaichun M 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: IEEE: 77-85 [DOI: 10.1109/CVPR.2017.16]
- Davison A J, Reid I D, Molton N D and Stasse O. 2007. MonoSLAM: real-time single camera SLAM. IEEE Transactions on Pattern Analysis and Machine Intelligence, 29(6): 1052-1067 [DOI: 10.1109/TPAMI.2007.1049]
- Feng Y T, Feng Y F, You H X, Zhao X B and Gao Y. 2018. MeshNet: mesh neural network for 3D shape representation[EB/OL]. [2019-09-27]. <https://arxiv.org/pdf/1811.11424.pdf>
- Garcia-Garcia A, Orts-Escolano S, Oprea S, Villena-Martinez V and Garcia-Rodriguez J. 2017. A review on deep learning techniques applied to semantic segmentation[EB/OL]. [2019-09-27]. <https://arxiv.org/pdf/1704.06857.pdf>
- Hanocka R, Hertz A, Fish N, Giryas R, Fleishman S and Cohen-Or D. 2019. MeshCNN: a network with an edge[EB/OL]. [2019-09-27]. <https://arxiv.org/pdf/1809.05910.pdf>
- Hua B S, Tran M K and Yeung S K. 2018. Pointwise convolutional neural networks//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE: 984-993 [DOI: 10.1109/CVPR.2018.00109]
- Huang J and You S Y. 2016. Point cloud labeling using 3D convolutional neural network//Proceedings of the 23rd International Conference on Pattern Recognition. Cancun: IEEE: 2670-2675 [DOI: 10.1109/ICPR.2016.7900038]
- Klokov R and Lempitsky V. 2017. Escape from cells: deep Kd-networks for the recognition of 3D point cloud models//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice: IEEE: 863-872 [DOI: 10.1109/ICCV.2017.99]
- Le T and Duan Y. 2018. PointGrid: a deep network for 3D shape understanding//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE: 9204-9214 [DOI: 10.1109/CVPR.2018.00959]
- Li Y Y, Bu R, Sun M C, Wu W, Di X H and Chen B Q. 2018. PointCNN: convolution on X-transformed points//Proceedings of the Neural Information Processing Systems. [s.l.]: [s.n.]: 820-830
- Maturana D and Scherer S. 2015. VoxNet: a 3D convolutional neural network for real-time object recognition//Proceedings of 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems. Hamburg: IEEE: 922-928 [DOI: 10.1109/IROS.2015.7353481]
- Qiu Z S, Zhuang Y, Yan F, Hu H S and Wang W. 2019. RGB-DI images and full convolution neural network-based outdoor scene understanding for mobile robots. IEEE Transactions on Instrumentation and Measurement, 68(1): 27-37 [DOI: 10.1109/TIM.2018.2834085]
- Su H, Maji S, Kalogerakis E and Learned-Miller E. 2015. Multi-view convolutional neural networks for 3D Shape recognition//Proceedings of 2015 IEEE International Conference on Computer Vision. Santiago: IEEE: 945-953 [DOI: 10.1109/ICCV.2015.114]
- Wang P S, Liu Y, Guo Y X, Sun C Y and Tong X. 2017. O-CNN: octree-based convolutional neural networks for 3D shape analysis[EB/OL]. [2019-09-27]. <https://arxiv.org/pdf/1711.201537.pdf>
- Wu Z R, Song S R, Khosla A, Yu F, Zhang L G, Tang X O and Xiao J X. 2015. 3D ShapeNets: a deep representation for volumetric shapes//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE: 1912-1920 [DOI: 10.1109/CVPR.2015.7298801]
- Zhou Y and Tuzel O. 2018. VoxelNet: end-to-end learning for point cloud based 3D object detection//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE: 4490-4499 [DOI: 10.1109/CVPR.2018.00472]

作者简介



张新良, 1978年生, 男, 副教授, 硕士生导师, 主要研究方向为智能控制、检测技术与自动化装置等。

E-mail: zxldq@hpu.edu.cn

付陈琳, 男, 硕士研究生, 主要研究方向为点云语义分割。

E-mail: 571246870@qq.com

赵运基, 男, 副教授, 主要研究方向为模式识别与智能控制。

E-mail: auyjz@hpu.edu.cn