DOI:10.14188/j.2095-6045.20250492

文章编号:2095-6045(2026)05-0169-11

基于曲线特征与注意力机制的桥梁点云语义分割方法

周宝定[1] 黄乾峰[1] 宋江波[1] 詹 璐[1] 刘 默[2] 焦 峰[2] 刘 阳[3] 雷 磊[4]

1 深圳大学土木与交通工程学院,广东 深圳,518060

2 鲁南高速铁路有限公司,山东 济南,250001

3 山东建筑大学交通工程学院,山东 济南,250101

4 中铁第一勘察设计院集团有限公司,陕西 西安,710043

Semantic Segmentation Method of Bridge Point Clouds Based on Curvilinear Features and Attention Mechanism

ZHOU Baoding[1] *HUANG Qianfeng*[1] *SONG Jiangbo*[1] *ZHAN Lu*[1] *LIU Mo*[2] *JIAO Feng*[2] *LIU Yang*[3] *LEI Lei*[4]

1 College of Civil and Transportation Engineering, Shenzhen University, Shenzhen 518060, China

2 Lunan High-Speed Railway Co., Ltd., Jinan 250001, China

3 School of Transportation Engineering, Shandong Jianzhu University, Jinan 250101, China

4 China Railway First Survey and Design Institute Group Co., Ltd., Xi'an 710043, China

摘 要:语义信息的有效提取对桥梁点云模型分析具有决定性作用,然而三维激光扫描获取的原始点云数据普遍存在语义缺失问题。因此,本文基于开源桥梁数据构建标准化的点云语义分割数据集,评估主流点云语义分割算法在复杂桥梁场景下的分割性能,针对PointNet++、DGCNN和CurveNet等主流算法在桥梁点云分割中存在的局部特征提取能力弱和长距离依赖关系建模不足的问题,本文提出了一种基于长距离曲线特征与注意力机制的桥梁点云语义分割算法BCA-Net,增强了局部特征的表达能力,显著提高了桥梁点云的分割精度。通过构建桥梁点云数据集验证了BCA-Net算法的有效性。

关键词:桥梁点云模型;三维激光扫描系统;深度学习;语义分割;注意力机制

中图分类号:P228;U442

文献标志码:A

Abstract: Effective extraction of semantic information plays a crucial role in the analysis of bridge point cloud models; however, raw point cloud data acquired through 3D laser scanning generally suffers from semantic gaps. Therefore, this paper constructs a standardized point cloud semantic segmentation dataset based on open-source bridge data and evaluates the segmentation performance of mainstream point cloud semantic segmentation algorithms in complex bridge scenarios. To address the weaknesses in local feature extraction and insufficient long-range dependency modeling of mainstream algorithms such as PointNet++, DGCNN, and CurveNet in bridge point cloud segmentationm, this paper proposes a bridge point cloud semantic segmentation algorithm, BCA-Net, based on long-range curve features and an attention mechanism, which enhances the expressive power of local features and significantly improves the segmentation accuracy of bridge point clouds. The effectiveness of the BCA-Net algorithm is verified through the constructed bridge point cloud dataset.

Key words: bridge point cloud model; 3D laser scanning system; deep learning; semantic segmentation; attention mechanism

桥梁是交通基础设施的重要组成部分,其在建设与运营阶段的管理对保障桥梁的安全性与耐久性具有至关重要的作用[1]。随着我国桥梁数量的持续增长,桥梁管理的工作量也随之增大。然而,人工目测以及接触性测量等传统管理手段存在效率低下、主观性强、人力成本高以及数据更新滞后等诸多问

引用格式:周宝定,黄乾峰,宋江波,等. 基于曲线特征与注意力机制的桥梁点云语义分割方法[J]. 测绘地理信息,2026,51(5):169-179(ZHOU Baoding, HUANG Qianfeng, SONG Jiangbo, et al. Semantic Segmentation Method of Bridge Point Clouds Based on Curvilinear Features and Attention Mechanism[J]. Journal of Geomatics, 2026, 51(5): 169-179)

基金项目:山东省交通运输厅科技计划(2022B90);中铁第一勘察设计院集团有限公司科研项目(2022KY56(ZDZX)-02);国家重点研发计划(2022YFB3904602)。

题，难以满足日益增长的管理需求。因此，迫切需要数智化的方法来提高桥梁全周期管理的效率与准确性[2]。

本文基于三维激光扫描系统构建桥梁点云模型，能够自动且快速地获取桥梁的几何信息，并通过提出的桥梁点云语义分割算法，实现了桥梁部件的自动分割。最终完成部件级桥梁点云模型的构建，从而为桥梁全周期管理提供了可靠的数据支撑。本文阐述了桥梁点云数据集的制作过程，并选取PointNet++、DGCNN与CurveNet三种具有代表性的点云语义分割算法，在桥梁点云数据集上进行详细的性能评估，从评价指标、混淆矩阵以及可视化结果三个方面进行分析，揭示现有算法的局限性[3]。针对现有算法的不足，提出了基于曲线特征与注意力机制的桥梁点云语义分割算法，即BCA-Net算法，并详细地介绍了算法的架构。为了验证BCA-Net算法的有效性，从评价指标、混淆矩阵、可视化结果以及消融实验四个方面进行全面验证[4]。实验结果显示，BCA-Net算法的分割性能显著优于现有的点云语义分割算法。

针对两种不同规模的桥梁空间特性，本文采取两种高效的点云数据采集方案。对于小型桥梁，采用地面式三维激光扫描系统进行多站数据采集[5]；而对于中大型桥梁，则融合地面式与机载式三维激光扫描系统进行数据采集[6]。在数据处理流程中，对采集的数据进行统计滤波以剔除异常点，基于球形标靶和显著几何特征点进行点云粗配准，并利用迭代最近点(iterative closest point，ICP)算法进行精配准，从而构建桥梁点云模型。针对桥梁点云模型的语义信息缺失问题，本文基于深度学习技术，自动获取桥梁点云模型的语义信息[7]。首先，通过对桥梁点云模型进行语义标注，构建桥梁点云数据集，并选取PointNet++、DGCNN与CurveNet三种具有代表性的算法，在桥梁点云数据集上进行训练与测试。通过分割性能对比，得出CurveNet的分割性能最佳，但仍存在一定的缺陷。

针对现有算法的不足，本文提出基于曲线特征与注意力机制的桥梁点云语义分割算法BCA-Net，重新设计局部特征提取器，加入混合池化与注意力机制，以增强局部特征的表达能力[8]。此外，改进曲线特征模块与跳跃连接注意力模块中的特征聚合方法。CurveNet虽在长距离特征捕捉上有优势，但对小尺度部件(如栏杆)的分割仍存在误分割问题，且对几何相似部件的区分能力有限。BCA-Net通过曲线特征模块增强长距离依赖建模，并利用注意力机制强化局部特征表达，直接针对这些缺陷进行优化。实验结果表明，BCA-Net在桥梁点云数据集上的分割性能显著优于现有的算法。

1 基于曲线特征与注意力机制的BCA-Net算法

PointNet++、DGCNN与CurveNet是当前点云语义分割的代表性算法，在桥梁工程领域都具有显著的潜力，尤其是CurveNet的长距离曲线特征为桥梁复杂结构提供了强大且丰富的特征表示能力。然而，在小尺度部件的分割性能上仍有待进一步提升，且面对几何相似的部件以及背景之间易产生误分割问题。因此，本节提出了基于曲线特征与注意力机制的桥梁点云语义分割算法BCA-Net[9]。

1.1 算法架构概述

BCA-Net是一种基于U-Net框架的网络，采用编码器-解码器的结构，仅需要原始桥梁点云作为输入，其整体架构如图1所示。给定一个输入点云，定义为$P=\{p_1, p_2, p_3, \cdots, p_i\}\in \boldsymbol{R}^{N\times 3}$，其中$p_i$是第$i$个点的三维坐标$(x, y, z)$，$i=1, 2, 3, \cdots, N$，$N$表示点云中的点数。在输入编码器前，点云首先通过全连接(fully connected，FC)层来获得每个点的初始特征$F=\{f_1, f_2, f_3, \cdots, f_i\}\in \boldsymbol{R}^{N\times d}$，$f_i$是第$i$个点的特征，$d$为特征维度。所采集的磁序列数据格式如下：

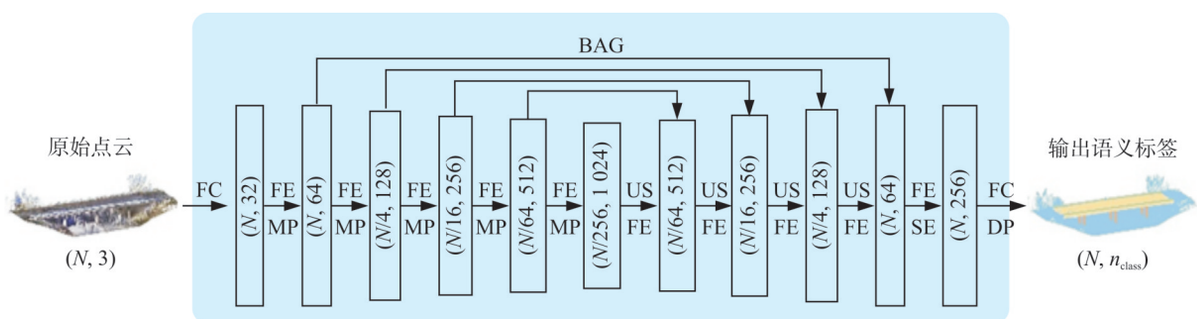


图1 BCA-Net算法架构

Fig. 1 The Algorithm Architecture of BCA-Net

在编码器阶段,BCA-Net通过堆叠五个特征提取(feature extraction,FE)层来逐步扩大感受野,降低点的数量,同时增加点的特征维度[10]。这个过程能够捕获不同分辨率的局部特征,为后续的点云语义分割任务提供丰富的特征表示。FE层包括:桥梁局部特征提取(bridge local feature extraction,BLFE)负责从桥梁点云数据中提取每个点的局部邻域特征。曲线分组引入CurveNet的CG模块,专门用于分析桥梁点云的形状曲线,编码具有独特几何信息的长距离曲线特征,从而有效提升点特征的多样性,进一步丰富局部特征表示[11]。桥梁特征聚合(bridge feature aggregation,BFA)负责将桥梁的局部特征与曲线特征进行有效融合。其中,CG与BFA模块仅在网络浅层阶段使用,即前两个FE层。如图2所示,在编码器中,每个FE层的结构由多个BLFE模块、CG模块与BFA模块组成。在每个FE层之后,本文利用最大池化(max-pooling,MP)层对点云进行下采样,与RandLA-Net相同,将点的数量减少至上一层的25%。

在解码器阶段,BCA-Net利用四个解码层将编码器提取的高维特征映射转换为目标输出。在此过程中,本文采用PointNet++中的线性插值方法作为上采样(up-sampling,US)模块,逐步恢复点云至原始输入的尺寸[12]。

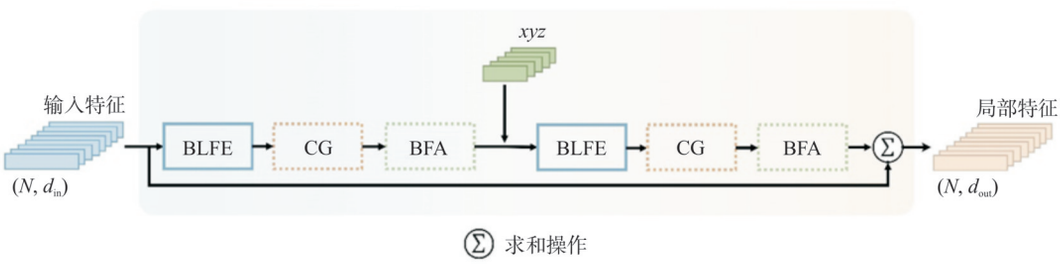


图2　FE层结构示意图

Fig. 2　Structure Diagram of the Feature Extraction Layer

1.2　桥梁局部特征提取

BLFE模块是BCA-Net中的核心组件,为网络的后续处理阶段提供了坚实的基础。这一模块专门设计用于捕捉桥梁点云的局部空间特征与点特征,从而增强网络对点云的理解与分析能力[13]。在设计理念上,借鉴了RandLA-Net与PnP-3D的思想,但BLFE模块特别强调其在获取更加有用的局部特征方面的能力。如图3所示,该模块由局部特征编码和局部特征聚合两个部分组成。

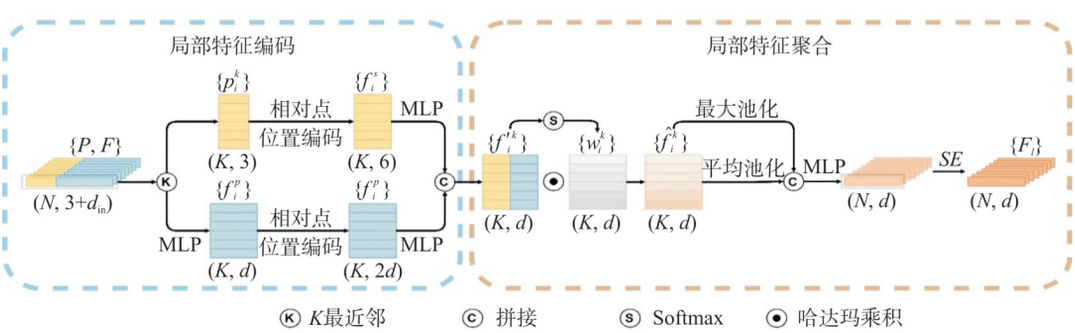


图3　BLFE模块结构

Fig. 3　The Module Structure of Bridge Local Feature Extraction

局部特征编码单元从点云中获取局部邻域信息,并将其转换为可被网络进一步处理的表示。在显式3D空间分支,采用中心点及其邻近点的坐标差值来捕捉它们之间的相对空间关系,随后按照式(1)进行编码,得到局部空间特征f_i^s。

$$f_i^s = \mathrm{MLP}\left(p_i \oplus \left(p_i^k - p_i\right)\right) \tag{1}$$

式中,p_i与p_i^k分别代表第i个中心点与其邻近点的坐标;⊕代表拼接操作。在隐式特征空间分支,输入特征首先通过一个瓶颈MLP进行降维处理,优化内存使用效率。降维后,进一步对每个点的特征与相应邻近点的特征进行差分操作,以获取它们之间的相对特征差异。随后将相对特征差异按照式(2)进行编码,得到局部点特征f_i^p。

$$f_i^p = \mathrm{MLP}\left(f_i \oplus \left(f_i^k - f_i\right)\right) \tag{2}$$

式中，f_i与f_i^k分别代表第i个中心点与其邻近点经过降维后的特征。接着，将显式3D空间分支中提取的局部空间特征f_i^s与隐式特征空间分支中提取的局部点特征f_i^p进行拼接，得到邻域特征$f_i'^k$。这里采用拼接策略可以较好地保留两个分支输出的特征信息。最后，局部特征编码单元为每个点生成邻域特征集$F_i^k=\{f_i'^1,f_i'^2,f_i'^3,\cdots,f_i'^k\}$。

局部特征聚合单元的目标在于有效整合局部邻域特征集。传统的聚合方法，如最大池化或平均池化，通常以简单的方式来处理特征信息，这可能导致有用信息的丢失。为了避免这一问题，本文在局部特征聚合前引入了注意力机制，通过式(3)计算每个局部邻域特征的注意力权重w_i^k，并根据式(4)对每个局部邻域特征$f_i'^k$进行加权，从而突出那些更为重要的局部邻域特征。

$$w_i^k=\mathrm{Softmax}\left(\mathrm{MLP}\left(f_i'^k\right)\right) \tag{3}$$

$$\hat{f}_i^k=f_i'^k\cdot w_i^k \tag{4}$$

式中，$\hat{f}_i^k$代表加权后的邻域特征。在局部特征聚合过程中，单一使用最大池化或平均池化仍可能造成部分信息丢失。受到SE-PseudoGrid[7]的启发，本文采用混合池化策略来解决这一问题。具体来说，应用最大池化与平均池化操作同时对$\hat{f}_i^k$进行处理，随后将这两种池化操作的输出拼接起来，并通过一个MLP进行进一步的处理，以获得混合池化的特征表示。

为了使网络更加聚焦于与分割任务高度相关的局部特征，注意力机制是一种有效的选择。本文引入轻量化的SE注意力机制[14]，其能够显式地对特征通道之间的依赖关系进行建模，从而使网络能够自适应地调整各通道的特征响应，有效抑制不相关或冗余的信息。如图4所示，SE注意力机制由压缩与激励两个单元组成，其中压缩单元通过全局平均池化操作，将输入特征的空间维度进行缩减，获得每个通道的全局特征；而激励单元则利用两个FC层进行映射，并最终通过Sigmoid函数生成各通道的注意力权重，这些权重随后与输入特征进行加权融合。最终，局部特征聚合单元生成局部特征$F_l=\{f_1',f_2',f_3',\cdots,f_i'\}$。

1.3 桥梁特征聚合

BFA模块旨在实现局部特征F_l与曲线特征F_c的有效融合，从而为桥梁点云的局部特征提供更为精细地描述。因此，本文对CurveNet中的CA模块进行了改进，将其用于BFA模块。如图5所示，对于

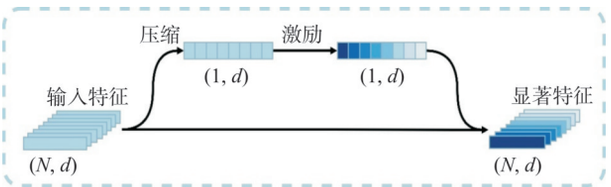


图4 SE注意力机制

Fig. 4 SE Attention Mechanism

CA模块获得的两个细粒度特征向量f''_{intra}和f''_{inter}，首先通过激活函数$g(\cdot)$对f''_{inter}进行非线性映射，随后将其与f''_{intra}进行逐元素相乘，并通过两个MLP进行进一步处理。

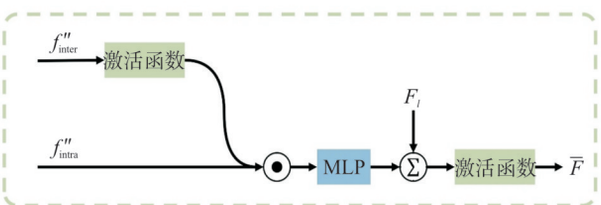


图5 非线性逐元素乘法算子

Fig. 5 Nonlinear Element-Wise Multiplication Operator

接着，与F_l进行残差相加，并通过激活函数$h(\cdot)$进行最终处理，从而得到聚合曲线特征后的局部特征$\bar{F}$，其具体的计算公式如下：

$$\bar{F}=g\left(F_l+\mathrm{MLP}\left(h\left(f''_{\mathrm{inter}}\right)\times f''_{\mathrm{intra}}\right)\right) \tag{5}$$

如图6所示，首先将编码器输出的局部特征和包含上下文信息的插值特征分别进行线性映射，以确保它们处于相同的维度空间。与AG模块不同的是，本文采用拼接的方式将这两种特征融合在一起，并通过非线性激活函数进行变换。随后，利用gMLP生成注意力权重，这些权重用于对局部特征进行加权，从而突出关键区域并抑制那些不相关特征的响应，有效减少跳跃连接过程中不必要的信息干扰。

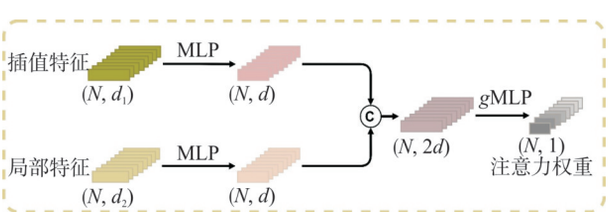


图6 BAG模块结构

Fig. 6 The Modular Structure of BAG

2 现有算法的桥梁点云语义分割性能对比

桥梁点云数据集与诸如ShapeNet等[4]当前点云语义分割常用的数据集存在显著差异，主要体现在桥梁结构的复杂性，其包含多种几何形状和拓扑关

系,使得现有点云语义分割算法在桥梁点云数据集上的表现仍需进一步验证。因此,本节选取了PointNet++、DGCNN和CurveNet三种具有代表性的算法,将其应用于桥梁点云数据集(数据集详细内容参考§3),通过分割性能的对比与分析,评估三种算法在处理桥梁复杂结构时的适应性与有效性[16]。

2.1　模型训练

在实验环境配置方面,硬件配置选用三张16 GB显存的NVIDIA Tesla T4显卡以及Intel Xeon Gold 6230 CPU。软件环境包含CentOS Linux 7操作系统、Python 3.10.9编程语言,并基于CUDA 11.3并行计算架构搭建深度学习平台,主要依赖库版本为PyTorch 1.12.1与torchvision 0.13.1。

模型训练超参数的设置在确保原始网络架构不变的前提下,对各模型的超参数进行调整,以实现最佳的分割性能。具体的训练超参数设置如表1所示,其中PointNet++、DGCNN和CurveNet在训练轮次、Batch_size、输入点数、权重衰减系数上均保持一致的设置。在优化器的选择上,PointNet++使用Adam优化器,而DGCNN与CurveNet则选用带有动量的随机梯度下降优化算法,并针对初始学习率与动量都进行了相应的调整。关于学习率调度策略,三个模型各有不同:PointNet++采用StepLR策略,每20个训练轮次将学习率衰减为一半[17]。DGCNN则采用余弦退火策略;CurveNet则沿用原模型的MultiStepLR策略,仅在训练的第140轮与第180轮对学习率执行跃阶式衰减。

表1　各模型训练超参数配置

Tab.1 Training Hyperparameter Configurations for each Model

超参数	PointNet++	DGCNN	CurveNet
训练轮次	200	200	200
Batch_Size	32	32	32
输入点数	2 048	2 048	2 048
优化器	Adam	带动量的SGD	带动量的SGD
初始学习率	0.1	0.001	0.01
动量	0.9	0.9	0.5
权重衰减系数	0.000 1	0.000 1	0.000 1
学习率调度器	StepLR	CosineAnnealingLR	MultiStepLR
学习率衰减系数	0.5	—	0.1
学习率衰减步长	20	—	—
学习率衰减轮次	—	—	140, 180

2.2　点云语义分割结果与分析

在模型测试阶段,以MIoU评价指标为依据,选取训练过程中较好的模型,并在独立的测试集上对其进行全面评估。在此基础上,通过对比与分析,深入探索各模型在语义分割任务中所呈现的性能差异[18]。

表2展示了PointNet++、DGCNN及CurveNet在测试集上的量化评估结果,其中各部件类别的分割性能通过MIoU评价指标衡量[19]。实验数据表明,CurveNet在桥梁点云测试集上的综合分割结果显著优于PointNet++与DGCNN,其整体MIoU值分别提升了4.7%和3.7%,OA值相较PointNet++提升了1.3%。

表2　各模型的语义分割评价指标值/%

Tab.2　Semantic Segmentation Evaluation Metrics for each Model/%

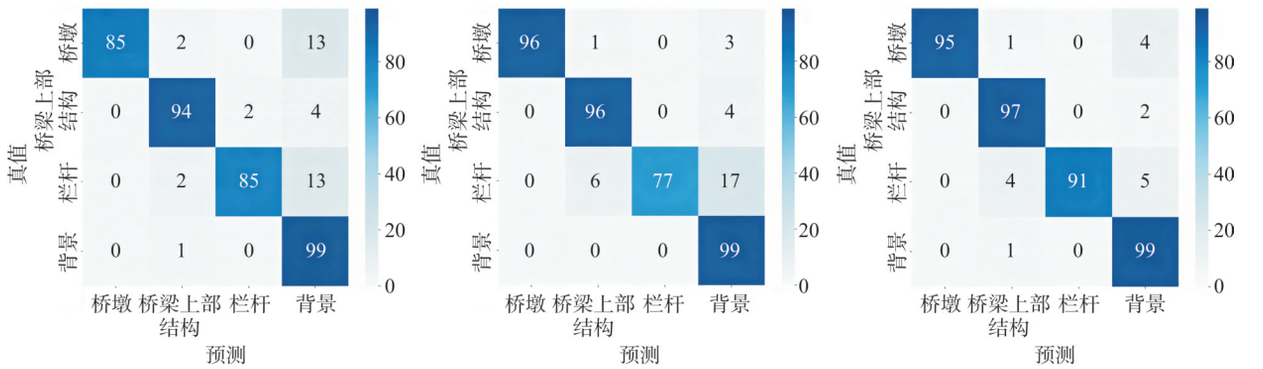
模型	MIoU	OA	上部结构	桥墩	栏杆	背景
PointNet++	88.4	96.4	89.8	93.9	73.8	94.9
DGCNN	89.4	97.7	90.2	96.6	74.5	96.4
CurveNet	93.1	97.7	93.9	97.1	84.7	96.6

本文所探讨的桥梁点云语义分割任务包含四个类别,与之对应的混淆矩阵为4×4矩阵,矩阵中的各元素的数值以比例形式呈现。为了能够直观地展示每个类别的误分割情况,混淆矩阵按行计算比例,矩阵中的每个元素代表真实类别被预测为各类别的比例,这一比例实际上反映的是召回率,有助于深入分析模型在不同类别上的敏感度与误分割倾向。

如图7(a)所示,经过PointNet++的预测,桥墩和栏杆两个类别的召回率较低,仅有85%的点被正确分割,且模型对这两类与背景的区分能力偏弱,各有13%的点被错误地分割至背景类别。如图7(b)所示,在桥墩类别,DGCNN模型相较于PointNet++展现出显著的性能改进,其召回率从85%跃升至96%,增幅达到11%,极大地减少了与背景之间的混淆。图7(c)显示,与DGCNN相比,CurveNet在栏杆类别带来突破性的提升,其正确分割的比例达到91%,增幅为14%,有效改善了栏杆与背景之间的混淆问题,误分割为背景的比例由17%降低至5%。在桥墩与桥梁上部结构。综上所述,三种模型在桥梁语义分割任务中,主要的误分割问题集中体现在桥梁部件与背景之间。

图8与图9展示了6号与9号桥梁点云模型的标注真值及三种模型的预测结果,通过可视化结果能够进一步观察模型对桥梁点云模型各部件的处理能力。PointNet++在桥梁上部结构的处理上表现出一定局限性。具体来说,上部结构两端与背景的边界区域存在大面积的误分割现象,主要表现为上部结构点被错误地分割为背景点。

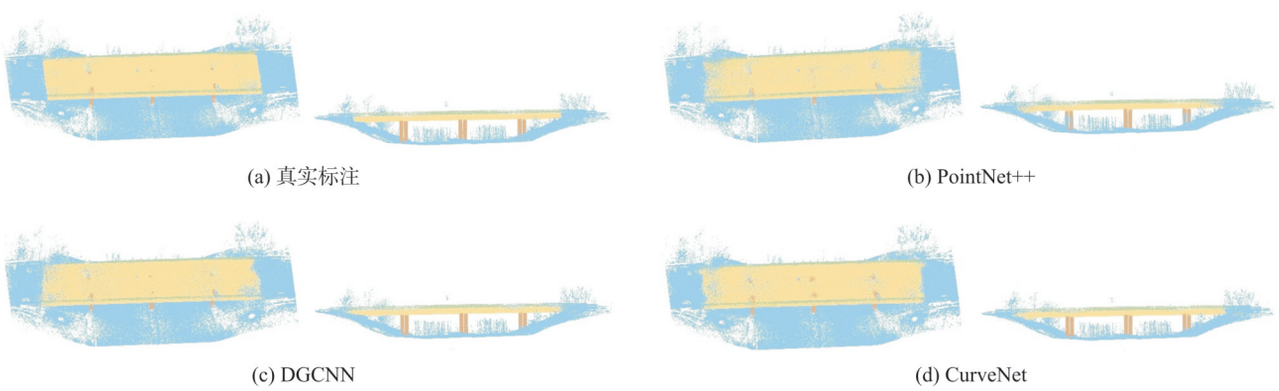
PointNet++在9号桥的桥梁上部结构的分割



(a) PointNet++ (b) DGCNN (c) CurveNet

图 7 各模型的混淆矩阵

Fig. 7 Confusion Matrices of each Model



(a) 真实标注 (b) PointNet++

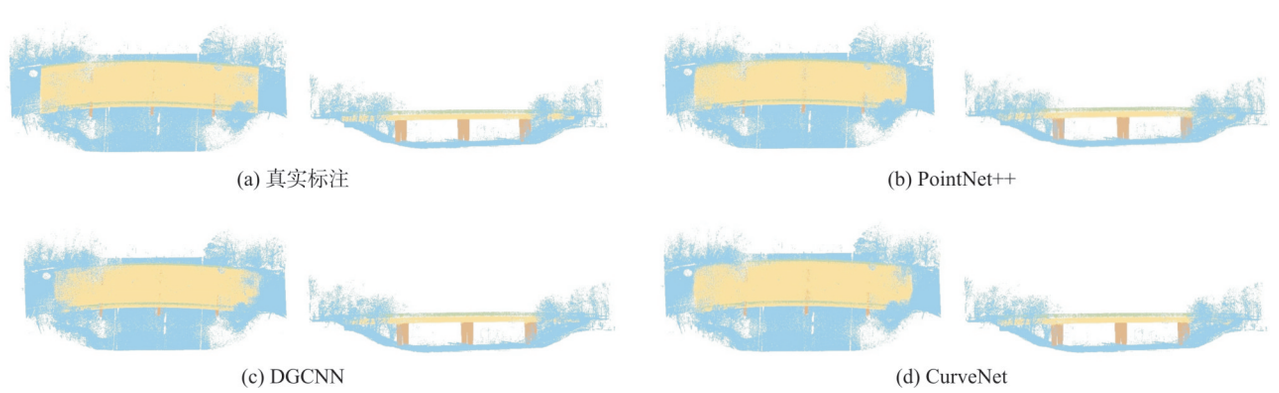
(c) DGCNN (d) CurveNet

图 8 各模型在 6 号桥梁的预测结果

Fig. 8 Prediction Results of Each Model for the No. 6 Bridge

任务中存在一定的局限性。具体而言，上部结构与背景的边界处存在误分割区域，且背景中的树枝等干扰物导致上部结构和栏杆在此范围内出现较多误分割点。相较于 PointNet++，DGCNN 在分割性能上表现出了一定的改进，其显著改善了桥墩与背景之间的误分割情况，但背景中地面点被误分割为桥墩的点有所增加。

同时，DGCNN 基本消除上部结构与底部背景点之间的错误预测区域。然而，上部结构两端与背景之间存在的错误预测区域更加明显。在栏杆中，其与背景以及上部结构之间的误分割情况与 PointNet++大致相同。相较于 DGCNN，CurveNet 进一步提升了分割性能。具体而言，CurveNet 改善了上部结构与背景以及栏杆之间的预测结果，有效减小了误分割区域。然而，在上部结构与桥墩之间的分割上，CurveNet 的表现稍逊于 DGCNN，且上部结构与底部背景点之间的错误预测区域明显增加。在桥墩中，其与背景之间的分割准确性略有提升，且背景中地面点被误分割为桥墩点的情况得到一定的缓解。



(a) 真实标注 (b) PointNet++

(c) DGCNN (d) CurveNet

图 9 各模型在 9 号桥梁的预测结果

Fig. 9 The Prediction Results of Each Model for the No. 9 Bridge

3　桥梁点云数据集构建与模型训练

3.1　桥梁点云数据集构建

本文选用Lu等[3]发布的开源桥梁点云数据作为原始数据集,其数据由FARO Focus 3D X330地面激光扫描仪获取,涵盖了十座英国钢筋混凝土箱梁桥的点云模型,完整记录了桥梁本体及周边环境的三维空间坐标(x,y,z)与RGB颜色信息[20]。通过对原始数据集内的桥梁结构进行分析,发现其结构类型与我国及其他多数国家现行公路桥梁的典型构造呈现高度相似性。因此,本文所采用的数据具备良好的研究适用性[21]。

在桥梁点云数据集的构建过程中,首先利用CloudCompare软件的分割工具对原始点云数据进行人工语义标注,将其精准划分为四大类别,即桥梁上部结构、桥墩、栏杆以及背景。经过语义标注后,桥梁点云数据集的统计数据如表3所示。值得注意的是,桥梁点云数据集内单桥点云规模均达千万数量级,直接输入深度学习网络将会导致计算资源过度消耗并显著降低训练效率[22]。为解决大规模点云数据与有限计算资源的矛盾,本文采用子空间划分的方法进行处理,具体划分方式如图10所示。首先对点云进行空间坐标归一化处理,继而沿着桥梁主跨度的延伸方向采用滑动窗口机制生成连续子空间序列,并对每个子空间执行随机降采样操作以消除冗余数据。经过实验验证,最终确定子空间长度为0.5 m,相邻子空间重叠率为75%[23]。这种方法通过重叠的子空间有效维护了结构特征的连续性,在确保原始几何特征完整性的前提下,显著压缩了单桥数据规模,降低了计算资源的消耗,并提高了训练效率。

经过人工标注与子空间划分后,数据集将划分为训练集、验证集及测试集。1、3、4、5、7和8号桥梁的数据作为训练集,用于模型参数训练;2和10号桥梁的数据作为验证集,用于在训练过程中对模型进行评估和调优;6号和9号桥梁的数据作为测试集,用于评估模型在未知数据上的泛化能力。

3.2　模型训练

BCA-Net的训练环境与CurveNet保持一致,其具体的训练超参数配置如表4所示。在训练过程中,BCA-Net在桥梁点云数据集上进行200个轮次的训练,并采用早停策略以避免过拟合[24]。每个训练轮次中,以Batch_Size为32遍历整个训练集。在优化器与学习率调度器的选择上,BCA-Net沿用了CurveNet的设置,即使用带动量的SGD优化器和MultiStepLR学习率调度器,初始学习率设置为0.01,动量设置为0.5,并在第140轮次与第180轮次对学习率进行0.1倍的衰减。

表3　桥梁点云数据总量统计

Tab. 3　Statistics of Total Point Cloud D·ata for Bridges

桥梁	上部结构	桥墩	栏杆	背景	总点数
1号桥梁	5 952 563	1 186 500	802 789	18 293 457	26 235 309
2号桥梁	2 449 216	740 921	299 843	8 361 791	11 851 771
3号桥梁	3 289 421	779 895	493 160	7 721 505	12 283 981
4号桥梁	2 607 380	843 512	80 692	9 123 483	12 655 067
5号桥梁	2 817 527	601 300	246 388	6 491 922	10 157 137
6号桥梁	31 175 186	2 482 974	1 093 927	45 035 182	79 787 269
7号桥梁	20 627 200	990 156	1 479 072	30 612 047	53 708 475
8号桥梁	36 835 380	4 063 061	1 496 116	39 216 318	81 610 875
9号桥梁	35 830 739	4 022 608	1 258 494	39 787 727	80 899 568
10号桥梁	31 950 256	796 055	3 402 646	41 539 284	77 688 241

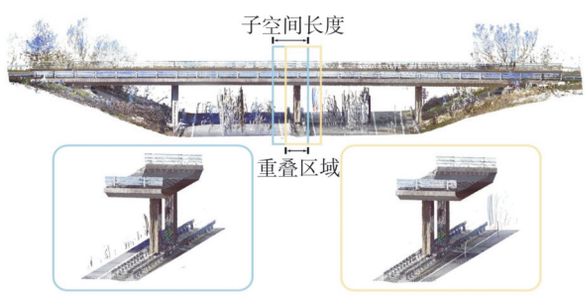


图10　子空间划分方法示意图

Fig. 10　Schematic Diagram of Subspace Partitioning Method

表4　BCA-Net训练超参数配置

Tab. 4　Training Hyperparameter Configurations for BCA-Net

超参数	BCA-Net
训练轮次	200
Batch_Size	32
输入点数	2 048
优化器	带动量的SGD
初始学习率	0.01
动量	0.5
权重衰减系数	0.000 1
学习率调度器	MultiStepLR
学习率衰减系数	0.1
学习率衰减轮次	140, 180

4　实验结果与分析

本节依据MIoU评价指标,从BCA-Net在模型训练过程中的多个模型中,选取表现较为优异的模型,将其应用于桥梁点云测试集上进行语义分割任务,以全面评估BCA-Net的分割性能。

4.1 评价指标量化分析

如表5所示，BCA-Net在MIoU值、OA值以及各部件的MIoU值上均显著优于其他模型。从整体性能指标来看，BCA-Net在测试集上的MIoU值达到95.5%，相较于基准模型CurveNet提升了2.4%，相较于目前在同等数据集下表现优异的RandLA-BridgeNet则提升了4.4%。同时，BCA-Net的OA值高达98.7%，分别比CurveNet和RandLA-BridgeNet提升了1%和1.6%。

表5 各算法的分割性能对比/%

Tab.5 Comparison of Segmentation Performance Across Different Algorithms/%

模型	MIoU	OA	上部结构	桥墩	栏杆	背景
PointNet++	88.4	96.4	89.8	93.9	73.8	94.9
DGCNN	89.4	97.7	90.2	96.6	74.5	96.4
RandLA-BridgeNet	91.1	97.1	94.6	88.5	86.3	94.9
CurveNet	93.1	97.7	93.9	97.1	84.7	96.6
BCA-Net	95.5	98.7	95.9	97.9	90.2	98.0

从各个部件的分割性能来看，BCA-Net对背景的分割性能最佳，MIoU值达到98%，分别比CurveNet与RandLA-BridgeNet提升了1.4%和3.1%。其次，BCA-Net对桥墩的分割性能也相当出色，MIoU值为97.9%，相较于CurveNet和RandLA-BridgeNet分别提升了0.8%和9.4%。在上部结构的分割性能方面，BCA-Net同样展现出了卓越的表现，MIoU值为95.9%，分别比CurveNet与RandLA-BridgeNet提升了2%和1.3%。尽管在五种模型中，栏杆的分割结果均为各类别中最低的，但BCA-Net对栏杆的分割性能仍具有明显的优势，MIoU值达到90.2%，分别比CurveNet与RandLA-BridgeNet提升了5.5%和3.9%。

4.2 混淆矩阵分析

相较于CurveNet，BCA-Net在桥梁上部结构方面取得了显著提升，将正确分割比例从97%提高至99%，涨幅为2%，有效减少了桥梁上部结构与背景之间的误分割（见图11(a)）。同时，BCA-Net将栏杆的正确分割比例由91%提升至93%，降低了栏杆与桥梁上部结构之间的误分割比。对于其余两个类别，BCA-Net的召回率与CurveNet一致。

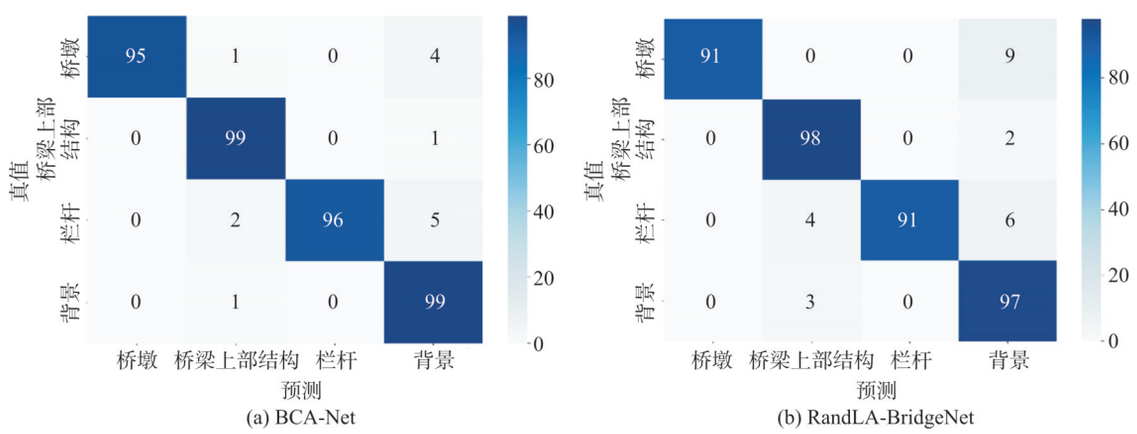


图11 BCA-Net与RandLA-BridgeNet的混淆矩阵

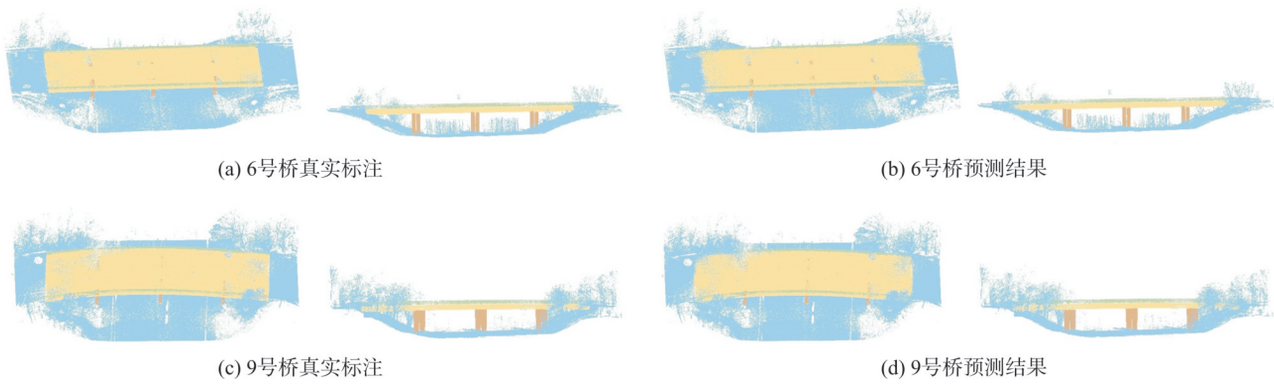
Fig.11 Confusion Matrix of BCA-Net and RandLA-BridgeNet

如图11(b)所示，与RandLA-BridgeNet相比，BCA-Net在桥墩的分割上展现出了明显优势，将桥墩的正确分割比例从91%提高至95%，有效减少了桥墩与背景点之间的误分割。在桥梁上部结构中，BCA-Net取得了略微提升，其召回率提高了1%，降低了上部结构与背景之间的误分割比例。在栏杆中，其正确分割比例从91%提升至93%，不仅降低了栏杆与上部结构之间的误分割比例，也减少了栏杆与背景之间的误分割。在背景中，BCA-Net也将其正确分割比例从97%提高至99%，有效减少了背景与上部结构之间的误分割比例。

4.3 可视化结果分析

图12展示了测试集桥梁点云模型的标记真值与BCA-Net分割结果。6号桥，BCA-Net显著改善了PointNet++、DGCNN以及CurveNet在桥梁上部结构点分割中存在的将其误分割为背景的问题。同时，桥面与背景之间的边界分割结果与标注真值趋于一致，尽管在边界周边仍存在少量误分割的点。此外，上部结构与底部背景之间的分割准确率也有所提升，并且有效解决了上部结构与桥墩顶部之间的边界误分割情况。对于栏杆的分割，相较于CurveNet，BCA-Net能够更准确地处理栏杆与上部结构的边界，同时栏杆与背景的连接处的预测结果也

得到了略微提升[25]。另外,桥墩与背景地面点之间的误分割情况也得到了一定的缓解。



(a) 6号桥真实标注　(b) 6号桥预测结果

(c) 9号桥真实标注　(d) 9号桥预测结果

图 12　BCA-Net的预测结果

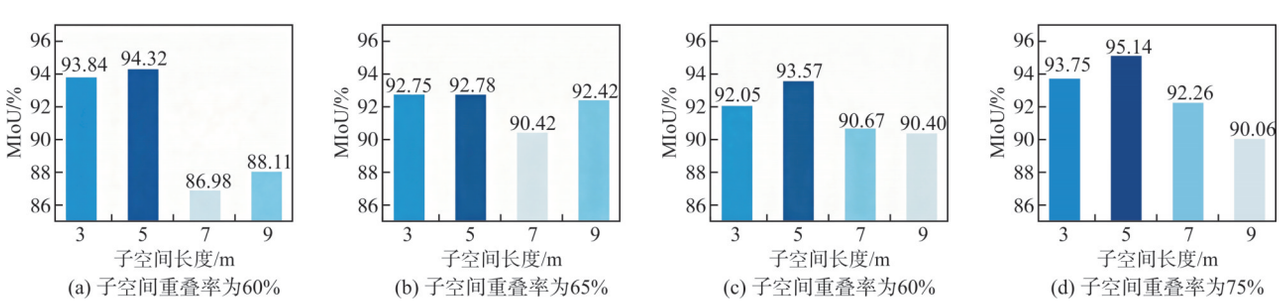
Fig. 12　The Prediction Results of BCA-Net

9号桥的BCA-Net明显提升了PointNet++、DGCNN以及CurveNet三种模型对于上部结构的分割结果,使得上部结构两端与背景的边界更加清晰。然而,桥梁周边密集的树枝等物体仍对上部结构及栏杆的分割结果造成一定的干扰。相较于CurveNet,BCA-Net有效减少了上部结构与底部背景之间的误分割区域,并改善了上部结构与桥墩顶部之间的分割准确率。同时,BCA-Net进一步优化了栏杆与背景及上部结构之间的分割边界。此外,BCA-Net也改善了桥墩与背景之间的误分割问题,但仍存在桥墩点被误分割为背景点的情况。

4.4　消融实验分析

探讨BCA-Net中的关键参数对桥梁点云语义分割性能的具体影响,同时详细分析算法中各模块对整体分割性能的贡献程度。

1)子空间长度与重叠率。同时,引入反向匹配机制,如图13所示,对长度相同的序列进行正向和反向匹配,取相似度最高的一次作为结果,确保机器人双向行驶时磁序列的成功识别,提高匹配的鲁棒性和准确性[26]。为了探究不同子空间长度对桥梁语义分割性能的影响,本文根据桥梁点云数据集的特性,设置了四种子空间长度,分别为3 m,5 m,7 m和9 m。为了确保实验结果的稳健性和可靠性,排除偶然因素的干扰,分别设计了四组实验,每组实验都对应一个特定的子空间重叠率,具体为60%、65%、70%和75%,而其他实验参数均保持一致,以确保实验的可比性。通过对比不同子空间重叠率条件下子空间长度对分割性能的影响,旨在揭示子空间长度与桥梁语义分割性能之间的内在关联规律。实验结果如图13所示。子空间重叠率的设置旨在缓解由于子空间划分而导致的特征信息丢失问题,从而确保桥梁语义分割性能不会受到信息割裂的影响[27]。为了深入探究子空间重叠率对分割性能的具体影响,本文在5 m的最优子空间长度基础上,设计了八组不同的子空间重叠率实验,分别为50%、60%、65%、70%、75%、80%、85%和90%。实验结果如图14所示。



(a) 子空间重叠率为60%　(b) 子空间重叠率为65%　(c) 子空间重叠率为60%　(d) 子空间重叠率为75%

图 13　四种子空间长度的MIoU值

Fig. 13　The MIoU Values for the Four Subspace Lengths

2)曲线数量与长度。CG模块中的每条曲线负责从不同的方向或区域编码远距离点的关系,其数量决定着模型捕捉特征的丰富程度。为了深入研究曲线数量对桥梁点云语义分割性能的影响,本文设计了四组对比实验,曲线数量分别设置为25、50、75以及100,同时确保每组实验的曲线长度统一为20,其他参数均保持一致。实验结果如图15所示。

在本文中,曲线长度定义为每条曲线所包含的

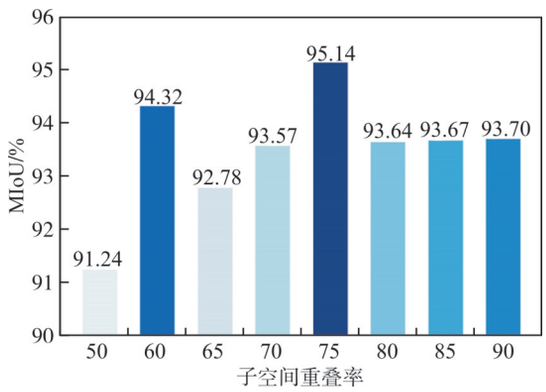


图 14　八种子空间重叠率的 MIoU 值

Fig. 14　MIoU Values for the Eight Subspace Overlap Ratios

点数，它直接决定每条曲线的感受野大小。较长的曲线能够跨越更大的范围，捕获更长距离的依赖关系，而较短的曲线则更加聚焦于局部细节。因此，如何合理权衡曲线长度以实现最佳的桥梁点云语义分割性能，成为一个值得深入研究的问题[28-30]。在已确定的最佳曲线数量基础上，本文设置四组不同的曲线长度进行对比实验，具体为 10、20、30 以及 40。实验结果如图 16 所示。

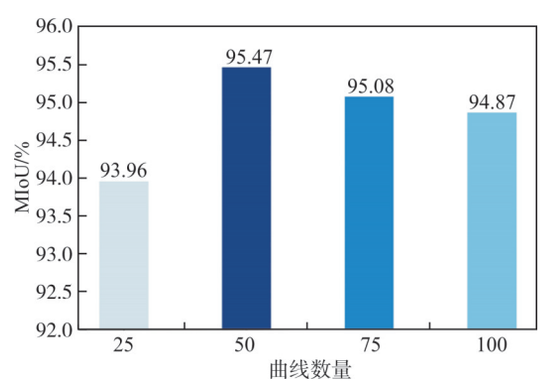


图 15　四种曲线数量的 MIoU 值

Fig. 15　The MIoU Values for the Four Curve Counts

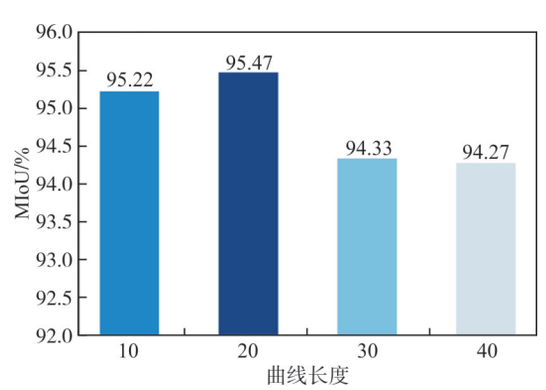


图 16　四种曲线长度的 MIoU 值

Fig. 16　The MIoU Values for the Four Curve Lengths

3）模块研究。为了进一步评估 BCA-Net 中每个模块对桥梁点云语义分割性能的具体贡献程度，本文对 BCA-Net 进行了一系列的修改，通过逐步替换或移除 BCA-Net 中的每个模块，根据相应的分割性能评估各个模块的贡献程度。如表 6 所示，首先将 BCA-Net 算法中 BAG 模块替换为 AG 模块，实验结果显示，相较于 AG 模块，BAG 模块带来了 0.7% 的性能增益。接着，将 BFA 模块替换为 CA 模块进行分割性能对比，验证了 BFA 模块实现略微提升，将 MIoU 值从 94.7% 提高至 94.8%。随后，利用 LPFA 模块替换 BCA-Net 中的 BLFE 模块，实验表明 BLFE 模块能够实现较大的分割性能提升，提升了 1.5%。最后，进一步移除 CG 模块，即在浅层网络阶段不使用曲线特征来丰富局部特征，实验结果表明，CG 模块带来的性能增益为 1.3%。

表 6　BCA-Net 各模块的贡献程度/%

Tab. 6　Contribution of each Module in BCA-Net/%

模型	MIoU
BCA-Net	95.5
BAG→AG	94.8
BFA→CA	94.7
BLFE→LPFA	93.1
移除 CG	91.8

5　结束语

本文基于 10 座开源的桥梁点云模型，利用 CloudCompare 软件对其进行语义标注，将其分为桥梁上部结构、栏杆、桥墩以及背景四个类别。由于桥梁点云数据的规模过大，本文采用滑动窗口方法，将桥梁划分为若干个具有重叠的子空间，其中：子空间长度为 5 m，子空间重叠率为 75%。在此基础上，本文选取 PointNet++、DGCNN 与 CurveNet 三种具有代表性的点云语义分割算法，在桥梁点云数据集上进行训练与测试，通过分割性能的对比，得出 CurveNet 的各项指标均优于其他两种算法，整体 MIoU 值为 93.1%，OA 值为 97.7%，并分析得出 CurveNet 在小尺度部件的分割能力有所欠缺，且特征提取能力仍有待提高。针对现有算法的局限性，本文在 CurveNet 算法的基础上进行改进，提出了 BCA-Net 算法，重新设计了局部特征提取模块，加入了混合池化与 SE 注意力机制，以增强局部特征的表达能力。此外，本文设计了非线性的逐元素乘法操作，以替换 CA 模块中的拼接方法。同时，在跳跃连接部分，本文加入了采取拼接方式的门控注意力机制。基于桥梁点云数据集，对改进后的算法进行训练与测试，实验结果表明，BCA-Net 的 MIoU 值达到 95.5%，OA 值达到 98.7%，显著优于基准算法 CurveNet，分别提升了 2.4% 和 1%，并与目前在同等数据集下表现

较为优异的RandLA-BridgeNet相比,BCA-Net的MIoU值与OA值分别提升4.4%和1.6%,进一步验证了BCA-Net的卓越性能。

参考文献

[1] 涂伟,李清泉,高文武,等. 基于机器视觉的桥梁挠度实时精密测量方法[J]. 测绘地理信息,2020,45(6):80-87

[2] 杨李东,钱志坚. 基于物联网与GIS的城市桥梁健康监测系统设计[J]. 测绘地理信息,2019,44(4):19-22

[3] Lu Ruodan, Brilakis I, Middleton C R. Detection of Structural Components in Point Clouds of Existing RC Bridges[J]. Computer-Aided Civil and Infrastructure Engineering, 2019, 34(3): 191-212

[4] Chang A X, Funkhouser T, Guibas L, et al. ShapeNet: An Information-Rich 3D Model Repository[PP/OL]. 2015: arXiv: 1512.03012. https://arxiv.org/abs/1512.03012

[5] 徐进军,郭鑫伟,张洪波. 基于三维激光扫描技术的桥塔挠度测量[J]. 测绘地理信息,2017,42(2):67-70

[6] Qiu Shi, Anwar S, Barnes N. PNP-3D: A Plug-and-Play for 3D Point Clouds[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(1): 1 312-1 319

[7] Yin Chao, Cheng J C P, Wang Boyu, et al. Automated Classification of Piping Components from 3D LiDAR Point Clouds Using SE-PseudoGrid[J]. Automation in Construction, 2022, 139: 104300

[8] Ma Xu, Dai Xiyang, Bai Yue, et al. Rewrite the Stars[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 16-22, 2024, Seattle, WA, USA. New York: IEEE Press, 2024: 5 694-5 703

[9] 吴志刚,徐畅,殷亮,等. 基于三维点云的桥梁预制钢箱梁制造质量评估[J]. 重庆交通大学学报(自然科学版),2025,44(9):26-33

[10] 李银岗,邹志强,冯武. 三维激光扫描和BIM逆向建模技术在既有建筑数字化中的应用[J]. 四川水泥,2025(9):30-32

[11] 白圻业,邱福祥,付景,等. 基于三维激光扫描技术的钢网架施工卸载过程数值分析[J]. 施工技术(中英文),2025,54(17):69-73

[12] 汪洪. 基于BIM的装配式建筑质量检测模型研究[J]. 绿色建造与智能建筑,2025(9):90-92

[13] 吴壮壮,于明旭. 三维激光扫描技术在城市部件普查中的应用研究[J]. 科学技术创新,2025(17):75-78

[14] 罗乃永. 三维激光点云技术在钢管拱桥拼装中的应用[J]. 江西建材,2025(8):149-151

[15] 张光勇. 工程测量中三维激光扫描优化技术[J]. 中国科技信息,2025(20):45-47

[16] 陈凡,汪魁,石一超,等. 基于三维激光扫描技术的输水管道材料腐蚀行为精细化表征[J]. 建筑材料学报,2026,29(4):480-486

[17] 王威,朱斌,钱时利,等. 三维激光扫描技术在电梯检验检测中的应用研究[J]. 特种设备安全技术,2025(5):45-47

[18] 袁超. 一种扫描仪/IMU/DMI数据融合三维激光扫描一体化检测方法[J]. 工程勘察,2025,53(10):83-87

[19] 刘阳,杨笑笑,胡广. 基于三维扫描技术的轨道行业机器人定位系统研究[J]. 机电产品开发与创新,2025,38(5):10-13

[20] Oktay O, Schlemper J, Le Folgoc L, et al. Attention U-Net: Learning Where to Look for the Pancreas[PP/OL]. 2018: arXiv: 1804.03999. https://arxiv.org/abs/1804.03999

[21] 邢欢,齐庆会,赵中华. 多源数据融合的校园三维精细化建模方法研究[J]. 测绘与空间地理信息,2025,48(10):135-137

[22] 刘军廷,张力文,周琦. 基于三维激光扫描的铁路轨道线形测量应用研究[J]. 测绘与空间地理信息,2025,48(10):195-198

[23] 黄云娥. 基于车载激光点云的道路边界提取方法研究[J]. 测绘与空间地理信息,2025,48(10):217-220

[24] 黎雷. 基于三维激光扫描技术的建筑工程测量实践[J]. 中国建筑金属结构,2025,24(16):40-42

[25] 熊峰,李宗春,付永健,等. 联合虚拟格网和LPD-DBSCAN算法的建筑物立面点云提取方法[J]. 测绘科学技术学报,2025,41(6):612-618

[26] 罗亚荣,卢文韬,郭迟,等. GNSS/INS组合导航左手对称性等变滤波模型及算法[J]. 测绘学报,2025,54(8):1 389-1 403

[27] 程青,汪博轩,张洪艳. DRformer:一种渐进式耦合多尺度CNN与浓缩注意力Transformer的高光谱图像超分辨率方法[J]. 测绘学报,2025,54(7):1 230-1 242

[28] 万杰,谢忠,徐永洋,等. 面向城市道路场景的车载LiDAR点云语义分割U形图卷积网络方法[J]. 测绘学报,2025,54(7):1 280-1 293

[29] 张蕊,李广云,王力,等. 车载LiDAR点云混合索引新方法[J]. 武汉大学学报(信息科学版),2018,43(7):993-999

[30] 项学泳,李广云,王力,等. 利用局部几何特征与空洞邻域的点云语义分割[J]. 武汉大学学报(信息科学版),2023,48(4):534-541

修回日期:2026-06-29

第一作者:周宝定,副教授,研究方向室内定位和建图和智能交通。E-mail:bdzhou@szu.edu.cn

通信作者:雷磊,高级工程师,主要从事铁路桥梁设计和桥隧智能运维技术研究工作。E-mail:104509125@qq.com