

DOI: 10.19344/j.cnki.issn1671-5276.2026.01.029

基于深度学习的点云语义分割方法综述

陈诚^{1,2}, 杨剑³, 黄和炜², 方立²

(1. 福州大学 先进制造学院, 福建 泉州 362200;

2. 中国科学院海西研究院 泉州装备制造研究中心, 福建 泉州 362216

3. 信息工程大学 地理空间信息学院, 河南 郑州 450052)

摘要:点云是一种3D数据结构,为我们理解现实世界中各种问题提供了支持。点云语义分割是指在复杂点云场景中,将属于不同物体的点区分开来。通常点云语义分割需要构建复杂的计算模型,而神经网络因其强大的特征学习与泛化能力,成为当前点云语义分割的首要选择。全面回顾不同点云数据处理方法下所对应的深度学习网络的发展脉络,详细阐述各种方法及网络的原理、优势与局限性。通过对这些内容的系统梳理,为广大读者提供关于点云语义分割的全面认识,并为相关研究提供数据参考。

关键词:点云;语义分割;深度学习

中图分类号:TP391 **文献标志码:**A **文章编号:**1671-5276(2026)01-0155-06

Review of Point Cloud Semantic Segmentation Methods Based on Deep Learning

CHEN Cheng^{1,2}, YANG Jian³, HUANG Hewei², FANG Li²

(1. Advanced Manufacturing Academy, Fuzhou University, Quanzhou 362200, China;

2. Quanzhou Institute of Equipment Manufacturing, Chinese Academy of Sciences, Quanzhou 362216, China;

3. School of Geospatial Information, Information Engineering University, Zhengzhou 450052, China)

Abstract: Point cloud is a 3D data structure that provides support for our understanding of various problems in the real world, while point cloud semantic segmentation refers to distinguishing the points belonging to different objects in complex point cloud scenes, which usually needs to construct complex computational models. The neural network, however, is becoming the primary choice for point cloud semantic segmentation due to its powerful feature learning and generalization capabilities. This paper comprehensively reviews the development trajectory of deep learning networks corresponding to different point cloud data processing methods, and elaborates the principles, advantages, and limitations of various methods and networks in detail. The systematic collation of this content provides readers with a comprehensive understanding of point cloud semantic segmentation methods and offers data references for relevant research.

Keywords: point cloud; semantic segmentation; deep learning

0 引言

随着激光雷达、深度相机等设备的广泛应用,点云成为一种常用的数据形式,其每个点通常包含三个坐标值(x, y, z),表示其在三维空间中的位置,也可以附加其他属性信息,如颜色、强度等。点云语义分割是指将点云中的每个点分配到一个语义类别。通过点云语义分割,可以了解场景中各部分的意义及空间关系,进而帮助机器进行决

策,例如机器人导航、自动驾驶等。

传统的点云语义分割方法包括边缘检测、区域增长、属性聚类以及模型拟合等。这些方法往往高度依赖先验知识和手工设计的特征,在处理复杂物体时,难以实现精准分割。深度学习能够自动从大量数据中学习有效的特征表示,使得将深度学习方法扩展到点云领域具有很大的潜力。为此,众多研究者开展了广泛而深入的研究工作。

基金项目:国家重点研发计划项目(2017YFB0503500);国家自然科学基金项目(41901335);智慧地球重点实验室基金项目(KF2023ZD04-02)

第一作者简介:陈诚(2000—),男,河南南阳人,硕士研究生,研究方向为计算机视觉、GeoAI, 2459154791@qq.com。

通信作者简介:杨剑(1985—),男,广东高州人,讲师,博士研究生,研究方向为地理空间智能、众源地理信息服务、机器地图, jian.yang@tum.de。

为了帮助研究者清楚了解基于深度学习的点云语义分割技术及发展路径,本文回顾了该领域的典型工作,包括其工作的基本原理、问题的提出及解决方案,总结不同方法的优缺点及性能表现,结合现有工作对基于深度学习的点云语义分割方法所面向的主要问题及未来发展趋势进行了展望。

1 基于深度学习的点云语义分割方法

基于深度学习的点云语义分割技术的发展总体呈现出从二维到三维、从侧重于数据转换到直接处理点云的趋势。本文把基于深度学习的点云语义分割方法划分为四类:基于投影的方法、基于体素的方法、基于点的方法以及基于混合的方法。

1.1 基于投影的方法

基于投影的方法首先将三维点云投影到一个或多个二维平面或视图上,然后使用 2D 分割技术进行处理。其主要分为多视图投影、球形投影和鸟瞰图投影。

多视图投影是指从多个不同的视角对三维物体或场景进行投影,生成一组二维图像。BOULCH 等^[1]提出的 SnapNet 设计了一个通用框架,将点云数据转化为多个视角的 RGB 和深度图像对,使用全卷积神经网络对每对二维快照进行逐像素分类,将标签预测投影到 3D 空间中,从而获得每个 3D 点的语义标签。多视图投影对视点的选择和遮挡敏感,也会因多对一映射而产生信息丢失和模糊效应。

球形投影是将三维空间中的物体或场景投影到一个球面上,然后将球面展开为二维平面。WU 等^[2]提出的 SqueezeSeg 采用球面投影将稀疏、不规则分布的 3D 点云转换为密集的 2D 网格表示,通过一个轻量级的卷积神经网络(convolutional neural networks, CNN)实现实时推理并结合条件随机场来平滑分割标签,确保相邻区域的一致性,提高了分割的准确性。由于感知范围限制、激光镜面反射或入射角抖动会导致点云数据缺失。在 SqueezeSeg 的基础上,WU 等^[3]提出的 SqueezeSegV2 通过上下文聚合模块从更大的感受野中聚合上下文信息,减少了缺失点噪声对模型性能的影响,并通过域适应策略对齐真实数据和合成数据的信息。球面投影带有强烈的结构先验信息,导致特征分布在不同空间位置上变化剧烈,XU 等^[4]提出的 SqueezeSegV3 在不同位置采用不同的滤波器,从

而适应特征分布变化。为了减少球形投影中 2D 图像坐标输入和笛卡儿坐标输出之间的不一致性,WANG 等^[5]提出的 Meta-RangeSeg 利用 Meta-Kernel 算子动态学习相对笛卡儿坐标和范围值的权重来提取元特征,使得从球面投影获得的图像可以有效地捕捉局部几何结构。

鸟瞰图投影模拟从高处垂直向下俯视物体的视角,但从鸟瞰图看点云数据时点云呈现出不同半径的环状分布特征,影响细粒度语义类别的分割性能。ZHANG 等^[6]提出的 PolarNet 使用极坐标网格划分数据,使点云在网格单元中分布更均匀。尽管 PolarNet 解决了点云密度不均的问题,但其基于最大池化操作会导致详细的几何特征信息丢失。SONG 等^[7]提出的 DGPolarNet 使用最远点采样和 K 近邻方法采样感知兴趣点,避免了随机采样的不稳定性,同时保留了重要的几何结构信息。

1.2 基于体素的方法

基于体素的方法将点云离散化为小立方体,在这些立方体上进行计算和处理。MATURANA 等^[8]提出的 VoxNet 结合 3D CNN 进行高效的体素特征提取和分类。针对 3D 语义分割中存在粗粒度预测和全局一致性不足的问题,TCHAPMI 等^[9]提出的 SEGCloud 先使用 3D CNN 生成体素标签,通过三线性插值将体素级别的预测映射回原始 3D 点云,利用一个可微分的循环神经网络强制全局一致性,在点级别提供细粒度的语义标签。对于点云稀疏性导致的空间计算冗余与内存效率瓶颈,RIEGLER 等^[10]提出的 OctNet 通过不平衡八叉树对 3D 空间进行分层划分,动态分配计算和内存资源。CHOY 等^[11]提出的 MinkowskiNet 通过广义稀疏卷积对非空位置及其邻域进行计算,避免了全空间卷积的计算开销。MENG 等^[12]提出的 VV-Net 将每个体素进一步划分为子体素,并使用径向基函数对稀疏分布的点进行插值,为模型提供了更有效的输入。考虑到点云密度不均匀导致特征提取的不一致性,ZHOU 等^[13]提出的 Cylinder3D 根据点云密度随距离变化的特点构建了一个圆柱卷积框架。YANG 等^[14]提出的 V-SIAM 通过体素切片机制增强特征之间的交互,补偿因密度分布不均导致的邻域特征缺失,并通过特征重新校准机制强化低置信度特征。

1.3 基于点的方法

基于点的方法直接处理点云数据。CHARLES

等^[15]提出的 PointNet 是首个端到端处理无序点云数据的方法,它通过多层感知机(multilayer perceptron, MLP)处理每个点并利用对称函数处理各点间关系,实现对整个点云的分割或分类,为后续基于点的方法奠定了基础。为解决 PointNet 对局部结构建模不足的问题, QI 等^[16]提出的 PointNet++ 通过距离度量将点集划分为重叠的局部区域,从小区域中捕捉局部特征,局部特征被进一步分组到更大的单元中以产生更高级别的特征,这个过程重复进行,直到获得整个点集的特征。在处理大规模点云时,上述网络存在计算复杂度高的问题,难以满足实时性需求, HU 等^[17]提出的 RandLA-Net 采用随机采样的策略降低计算复杂度,并通过逐步扩大感受野尺寸保留关键特征。对于场景中物体的尺寸差异, ZHAN 等^[18]提出的 FA-ResNet 网络构建多层残差 MLP 块并逐步扩大感受野,使得网络能够同时捕获局部细节和全局语义信息,从而解决尺寸差异问题。

基于卷积的方法主要关注如何适应点云的非规则性。典型的工作是 THOMAS 等^[19]提出的 KPConv, 该网络通过可学习核点在局部邻域内构建动态卷积核,并在训练中通过几何约束优化空间位置,实现对不规则点云分布的拓扑适配。另一种方法是图卷积,此类方法的优势在于其能够聚合目标结构特征,同时在三维空间中保持平移不变性,挑战在于如何构建合适的点对点关系,代表性工作是 KVGCN^[20], SGSLNet^[21]等。

基于 Transformer 的方法可以有效捕获数据中的长依赖信息,已成为当前点云语义分割的热点。ZHAO 等^[22]提出的 Point Transformer 首次为点云设计了自注意力层,有效提升了模型的分割性能。WU 等^[23]提出的 Point TransformerV2 通过分组向量注意力、改进的位置编码机制和基于分区的池化策略,进一步提升了模型的性能。Point Transformer V3 放弃用 KNN 查询为每个点找到最近邻,通过序列化的方式将点云的邻域信息映射到规则的表示空间中,减小了计算开销^[24]。ZHANG 等^[25]提出的 AF-GCN 在浅层采用图卷积来聚合局部特征,在深层通过自注意力模块捕捉全局特征。CHEN 等^[26]提出的 PointMM 首先进行多空间特征编码,然后通过注意力池化聚合多空间和属性特征,解决了最大池化和平均池化丢失详细特征的问题。

1.4 混合方法

通过混合不同的输入数据形式,可以适应不同场景的分割任务。XU 等^[27]提出的 RPVNet 以点作为中间载体,利用可微坐标映射矩阵将通过三线性插值的体素特征和深度投影的像素特征双向迁移至点云空间,通过点域自适应门控机制进行体素与像素特征的权重分配,实现跨模态特征交互。AKWENSI 等^[28]将知识蒸馏应用于点云语义分割,该网络首先从教师模型中分别提取点级和体素级的输出特征,并将这些特征作为知识传递给学生模型,将整个点云划分为多个超体素,在这些超体素上进行点间和体素间的亲和力蒸馏,帮助学生模型更好地捕捉周围环境的结构信息。HOU 等^[29]考虑到不同尺度的上下文信息,提出了结合 IoSL 稀疏 3D 卷积和多尺度特征融合交叉门控的新方法,通过减少特征冗余和提高多尺度特征融合精度来提升分割性能。

2 结果对比与分析

2.1 数据集

高质量三维数据集是评估语义分割算法性能的核心基准。针对点云语义分割的模型评估,当前存在多个具有领域代表性的基准数据集,本文仅在 ScanNet^[30]、S3DIS^[31]、Semantic3D^[32]、SemanticKITTI^[33]、nuScenes^[34]这几个常用的数据集上进行模型性能的对比如。

2.2 评价指标

平均交并比(mIoU)是当前点云语义分割最常见的的评价指标,计算公式为

$$M_{\text{mIoU}} = \frac{1}{C} \sum_{i=1}^C \frac{T_{P,i}}{T_{P,i} + F_{P,i} + F_{N,i}} \quad (1)$$

式中: $T_{P,i}$ 表示第*i*个类的点被正确分类的点数; $F_{P,i}$ 表示其他类的点被分为第*i*个类的点数; $F_{N,i}$ 表示第*i*个类的点被分为其他类的点数; C 为类别数。

表1列出了不同模型的性能表现。从表1可以看出,Point TransformerV3 取得了最好的分割性能。从数据处理的角度来看,基于点云的方法完整保留了点云的初始信息。从模型构建上看,Transformer 的自注意力机制可以捕捉点云中任意两点之间的关系,而不仅仅是局部邻域内的关系,这对于复杂场景下的点云理解非常重要。

表 1 基于深度学习的点云语义分割网络效果对比

单位: %

方法类别	网络(年份)	ScanNet	S3DIS	SemanticKITTI	Semantic3D	nuScenes
基于投影	SnapNet(2018)	—	—	—	59.1	—
	SqueezeSeg(2018)	—	—	29.5	—	—
	SqueezeSegv2(2019)	—	—	39.7	—	—
	SqueezeSegV3(2020)	—	—	55.9	—	—
	MetaRangeSeg(2022)	—	—	61.0	—	—
	PolarNet(2020)	—	—	54.3	—	—
	DGPolarNet(2022)	—	—	56.5	—	—
基于体素	SEGCloud(2017)	—	48.9	36.8	61.3	—
	MinkowskiNet(2019)	72.1	65.3	—	—	—
	VV-Net(2019)	—	78.2	—	—	—
	Cylinder3D(2020)	—	—	67.8	—	76.1
	V-SIAM(2024)	—	—	73.7	—	—
基于点	PointNet(2017)	14.7	43.6	14.6	—	—
	PointNet++(2017)	34.3	54.5	20.1	—	—
	RandLA-Net(2020)	—	70.0	53.9	—	—
	FA-ResNet(2023)	—	71.7	55.7	—	—
	KPConv(2019)	68.4	67.1	—	73.1	—
	KVGCN(2021)	40.4	60.9	—	—	—
	SGSLNet(2025)	—	74.9	—	—	—
	PointTransformer(2021)	74.2	65.4	—	—	—
	PointTransformerV2(2022)	77.9	73.5	74.2	—	80.2
	Point TransformerV3(2024)	79.4	80.8	75.5	—	83.0
	AF-GCN(2023)	—	78.4	—	—	—
PointMM(2024)	—	70.7	—	—	—	
混合方法	RPVNet(2021)	—	—	70.3	—	77.6
	Hou et al(2022)	—	—	71.2	—	76.0
	Bi et al(2025)	—	—	65.6	—	73.0

3 结语

本文梳理了当前基于深度学习的点云语义分割现状,为相关研究提供了理论及数据参考。通过进一步的梳理,发现点云语义分割主要围绕以下几个问题进行模型构建及优化。

1)局部特征与全局特征的提取与融合。局部特征保留了细粒度的几何细节,全局特征适合理解物体的整体结构。通过融合局部和全局特征,可以同时利用两者的优势,提升分割精度和鲁棒性。

2)点云的稀疏性和密度不均匀性。稀疏点云会导致信息丢失、特征提取困难和分割精度下降。密度不均匀会导致特征提取不一致和计算资源浪费。

3)模型的轻量化设计。模型的轻量化能够满足自动驾驶、机器人导航等场景的实时性决策需求。

参考图像分割领域的深度学习技术发展现状及现有的一些工作,点云语义分割技术还应向以下几个方面发展。

1)域适应问题。点云数据通常由不同的传感

器采集,不同传感器的分辨率、视角、扫描范围和噪声水平可能导致数据分布差异,域适应可以帮助模型适应动态环境的变化。

2) 无监督训练。点云数据通常数据量较大,使用人工标注需要的成本较高。无监督训练可以缓解标注数据不足的问题,同时降低数据标注的成本。

参考文献:

- [1] BOULCH A, GUERRY J, LE SAUX B, et al. SnapNet: 3D point cloud semantic labeling with 2D deep segmentation networks [J]. *Computers & Graphics*, 2018, 71:189-198.
- [2] WU B C, WAN A, YUE X Y, 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). Brisbane, QLD, Australia: IEEE, 2018:1887-1893.
- [3] WU B C, ZHOU X Y, ZHAO S C, 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). Montreal, QC, Canada: IEEE, 2019:4376-4382.
- [4] XU C F, WU B C, WANG Z N, et al. SqueezeSegV3: spatially-adaptive convolution for efficient point-cloud segmentation [M]//Computer Vision - ECCV 2020. Cham: Springer International Publishing, 2020:1-19.
- [5] WANG S, ZHU J K, ZHANG R X. Meta-RangeSeg: LiDAR sequence semantic segmentation using multiple feature aggregation [J]. *IEEE Robotics and Automation Letters*, 2022, 7(4):9739-9746.
- [6] ZHANG Y, ZHOU Z X, DAVID P, et al. PolarNet: an improved grid representation for online LiDAR point clouds semantic segmentation [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020:9601-9610.
- [7] SONG W, LIU Z, GUO Y, et al. DGPolarNet: dynamic graph convolution network for LiDAR point cloud semantic segmentation on polar BEV [J]. *Remote Sensing*, 2022, 14(15):3825.
- [8] MATURANA D, SCHERER S. VoxNet: a 3D convolutional neural network for real-time object recognition [C]//2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Hamburg, Germany: IEEE, 2015:922-928.
- [9] TCHAPMI L, CHOY C, ARMENI I, et al. SEGCloud: semantic segmentation of 3D point clouds [C]//2017 International Conference on 3D Vision (3DV). Qingdao, China: IEEE, 2017:537-547.
- [10] RIEGLER G, ULUSOY A O, GEIGER A. OctNet: learning deep 3D representations at high resolutions [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017:6620-6629.
- [11] CHOY C, GWAK J, SAVARESE S. 4D spatio-temporal ConvNets: Minkowski convolutional neural networks [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA: IEEE, 2019:3070-3079.
- [12] MENG H Y, GAO L, LAI Y K, et al. VV-net: Voxel VAE net with group convolutions for point cloud segmentation [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South): IEEE, 2019:8500-8508.
- [13] ZHOU H, ZHU X G, SONG X, et al. Cylinder3D: an effective 3D framework for driving-scene LiDAR semantic segmentation [EB/OL]. 2020:2008.01550. [2025-09-15] <https://arxiv.org/abs/2008.01550v1>.
- [14] YANG J R, WANG J, HUANG K X, et al. MsVFE and V-SIAM: attention-based multi-scale feature interaction and fusion for outdoor LiDAR semantic segmentation [J]. *Neurocomputing*, 2024, 584:127576.
- [15] CHARLES R Q, HAO S, MO K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017:77-85.
- [16] QI C R, YI L, SU H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [EB/OL]. 2017:1706.02413. [2025-09-15] <https://arxiv.org/abs/1706.02413v1>.
- [17] HU Q Y, YANG B, XIE L H, et al. RandLA-net: efficient semantic segmentation of large-scale point clouds [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020:11108-11117.
- [18] ZHAN L X, LI W, MIN W D. FA-ResNet: feature affine residual network for large-scale point cloud segmentation [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 118:103259.
- [19] THOMAS H, QI C R, DESCHAUD J E, et al. KPConv: flexible and deformable convolution for point clouds [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South): IEEE, 2019:6411-6420.
- [20] LUO N, YU H Q, HUO Z F, et al. KVGCN: a KNN

- searching and VLAD combined graph convolutional network for point cloud segmentation [J]. Remote Sensing, 2021, 13(5): 1003.
- [21] ZHAO X, WANG X H, CONG B G. SGSLNet: stratified contextual graph pooling for point cloud segmentation with graph structural learning [J]. The Journal of Supercomputing, 2024, 81(1): 176.
- [22] ZHAO H S, JIANG L, JIA J Y, et al. Point transformer [C] // 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, QC, Canada: IEEE, 2021: 16239-16248.
- [23] WU X, LAO Y, JIANG L, et al. Point transformer v2: grouped vector attention and partition - based pooling [J]. Advances in Neural Information Processing Systems, 2022, 35: 33330-33342.
- [24] WU X Y, JIANG L, WANG P S, et al. Point transformer V3: simpler, faster, stronger [C] // 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2024: 4840-4851.
- [25] ZHANG N, PAN Z Y, LI T H, et al. Improving graph representation for point cloud segmentation via attentive filtering [C] // 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, BC, Canada: IEEE, 2023: 1244-1254.
- [26] CHEN R X, WU J, LUO Y, et al. pointMM: point cloud semantic segmentation CNN under multi-spatial feature encoding and multi-head attention pooling [J]. Remote Sensing, 2024, 16(7): 1246.
- [27] XU J Y, ZHANG R X, DOU J, et al. RPVNet: a deep and efficient range - point - voxel fusion network for LiDAR point cloud segmentation [C] // 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, QC, Canada: IEEE, 2021: 16004-16013.
- [28] AKWENSI P H, WANG R S, GUO B. PReFormer: a memory-efficient transformer for point cloud semantic segmentation [J]. International Journal of Applied Earth Observation and Geoinformation, 2024, 128: 103730.
- [29] HOU Y N, ZHU X G, MA Y X, et al. Point-to-voxel knowledge distillation for LiDAR semantic segmentation [C] // 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, USA: IEEE, 2022: 8469-8478.
- [30] DAI A, CHANG A X, SAVVA M, et al. ScanNet: richly-annotated 3D reconstructions of indoor scenes [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 2432-2443.
- [31] ARMENI I, SENER O, ZAMIR A R, et al. 3D semantic parsing of large-scale indoor spaces [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 1534-1543.
- [32] HACKEL T, SAVINOV N, LADICKY L, et al. Semantic3D. net: a new large - scale point cloud classification benchmark [EB/OL]. 2017: 1704.03847. [2025-09-15] <https://arxiv.org/abs/1704.03847v1>.
- [33] BEHLEY J, GARBADE M, MILIOTO A, et al. SemanticKITTI: a dataset for semantic scene understanding of LiDAR sequences [C] // 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South): IEEE, 2019: 9296-9306.
- [34] CAESAR H, BANKITI V, LANG A H, et al. nuScenes: a multimodal dataset for autonomous driving [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 11621-11631.

收稿日期: 2025 - 04 - 13

（上接第 120 页）

- [14] ZHENG X Q, SUN Z Z, KAWAKUBO T, et al. Stability improvement of a turbocharger centrifugal compressor by a nonaxisymmetric vaned diffuser [J]. Journal of Turbomachinery, 2018, 140(4): 041007.
- [15] NAYLOR E M J, DUEÑAS C O, MILLER R J, et al. Optimization of nonaxisymmetric endwalls in compressor S-shaped ducts [J]. Journal of Turbomachinery, 2010, 132: 011011.
- [16] 韩阳, 李家军, 辛亚楠, 等. 大径向落差长度比中介机匣非轴对称端壁造型方法数值模拟研究 [C] // 中国航天第三专业信息网第三十八届技术交流会暨第二届空天动力联合会议论文集: 发动机内流气动技术. 大连: 2017: 87-96.
- [17] 赵伟光, 王英杰. 中介机匣非轴对称端壁优化及影响研究 [J]. 航空精密制造技术, 2025, 61(2): 39-41, 44.

收稿日期: 2023 - 12 - 20