

三维模型普适性特征提取与分类

周燕, 柯添*, 罗粤, 刘翔宇, 曾凡智, 周月霞

(佛山科学技术学院电子信息工程学院 佛山 528225)
(2112151081@stu.fosu.edu.cn)

摘 要: 为了解决单一算法特征描述子难以兼顾表达刚性和非刚性三维模型的问题, 提出一种三维模型普适性特征提取方法. 首先提出一种基于三维点云模型的局部面积加权密集化采样算法; 然后针对非刚性铰链结构的变换影响, 利用热核特征的等距等容不变性提出时间尺度序列热核编码方法; 最后提出边缘投影图卷积神经网络, 对编码点云的空间形状及时间尺度序列热核进行特征融合学习, 并应用于三维模型分类任务. 在刚性三维模型数据集 ModelNet40 和非刚性三维模型数据集 SHREC15 上的实验结果表明, 与单一刚性或非刚性三维模型特征提取方法相比, 所提方法能够提取具有普适性且具有显著辨别力的特征描述符, 分类准确率分别达到 92.63% 和 97.71%.

关键词: 普适性特征; 编码点云; 时间尺度; 图卷积神经网络; 三维模型分类
中图法分类号: TP391.41 **DOI:** 10.3724/SP.J.1089.2023.19525

Universal Feature Extraction and Classification for 3D Models

Zhou Yan, Ke Tian*, Luo Yue, Liu Xiangyu, Zeng Fanzhi, and Zhou Yuexia

(School of Electronic Information Engineering, Foshan University, Foshan 528225)

Abstract: In order to solve the problem that a single algorithm feature descriptor is difficult to express both rigid and non-rigid 3D models, this paper propose a universal feature extraction method for 3D models. Firstly, a local area weighted densification sampling method based on 3D point cloud model is proposed. Secondly, aim at the influence of non-rigid hinge structure transformation, a time-scale sequence heat kernel encoding method is proposed by using the equidistant and isometric invariance of heat kernel signature. Finally, an edge-projection graph convolutional neural network which is applied to 3D model classification tasks is designed. This network learns the feature fusion on the spatial shape of the encoded point cloud and the time-scale sequence heat kernel. Experiments on the rigid 3D model dataset ModelNet40 and non-rigid 3D model dataset SHREC15 show that compared with the single rigid or non-rigid 3D model feature extraction methods, the proposed method can extract universal feature descriptors with significant discrimination, and the classification accuracy rates at 92.63% and 97.71%, respectively.

Key words: universal feature; encoded point cloud; time scale; graph convolutional neural network; 3D model classification

收稿日期: 2021-12-06; 修回日期: 2022-05-05. 基金项目: 国家自然科学基金(61972091); 广东省自然科学基金(2022A1515010101, 2021A1515012639); 广东省普通高校重点研究项目(2019KZDXM007, 2020ZDZX3049); 佛山市科技创新项目(2020001003285). 周燕(1979—), 女, 硕士, 教授, 硕士生导师, CCF 会员, 主要研究方向为图像处理、计算机视觉、机器学习; 柯添(1995—), 男, 硕士研究生, 论文通信作者, 主要研究方向为计算机视觉、三维模型检索; 罗粤(1994—), 男, 硕士研究生, 主要研究方向为计算机视觉、三维形状识别、三维目标检测; 刘翔宇(1987—), 女, 博士, 讲师, CCF 会员, 主要研究方向为智能人机交互、机器学习、计算机视觉等; 曾凡智(1965—), 男, 博士, 教授, 硕士生导师, CCF 会员, 主要研究方向为计算机视觉、图像处理、数据挖掘; 周月霞(1978—), 女, 硕士, 讲师, 主要研究方向为图像处理、计算机视觉.

随着三维技术的发展和计算机软硬件性能的大幅提高, 三维模型数据正以几何倍数增长. 如何分类管理庞大的三维模型数据库, 对于家具、服装产品、机械零件等三维模型的复用及设计具有重要意义. 当前, 三维模型分类^[1-3]应用面临的重大难题依然是如何提取具有显著辨别力且具有普适性的特征描述符.

根据是否含有铰链结构, 三维模型可以分为刚性和非刚性三维模型; 早期的刚性、非刚性三维模型提取的特征大多是基于表面形状和几何统计等浅层特征^[4], 无法表达三维模型复杂的内在含义. 基于深度学习的方法采用数据驱动的方式, 能够自主地学习客观对象的更深层抽象特征, 极大地提升模型分类的准确率. 因此, 基于深度学习的特征提取方法已经成为三维计算机视觉领域的研究热点.

目前, 随着三维模型表达方式的多样化, 基于深度学习方法的三维模型分类已经取得了长足的发展. 其中, 基于点云表征的三维模型由于其简单的点空间坐标, 能够蕴含一定的表面形状、空间结构信息, 一直是研究的热点. 基于深度学习的三维点云模型分类方法提取的是点云的空间特征, 忽略了点与点、局部与全局的关联信息, 导致特征描述符表现力不足. 另外, 受网络模型的泛化性能影响, 在同时处理刚性、非刚性三维模型分类任务时, 单一特征刚性模型面临在平移、尺度上的变换, 非刚性模型则面临在铰链结构内部点相对位置上的变换, 这种固有的结构性差异, 导致现有特征描述符不能兼顾刚性、非刚性三维模型的特性, 分类准确率较低.

针对上述问题, 本文提出一种三维模型普适性特征提取方法. 首先提出一种三维点云模型局部面积加权密集化采样算法, 对三维模型进行求质心、平移、缩放等预处理, 提高对三维模型平移、尺度等刚性变换的鲁棒性, 并获取高质量的三维点云模型; 然后利用热核特征的等距等容不变性, 提出时间尺度序列热核编码方法, 缓解热核对时间参数的敏感, 增加点云模型在局部结构特征的表达, 以克服非刚性铰链结构的变换影响, 提高对非刚性变换的鲁棒性; 最后引入注意力误差反馈机制(attentional back-projection edge error feedback mechanism, ABEM), 构造边缘投影图卷积神经网络(edge-projected graph convolutional neural network, EPGCNN), 增强热核在局部结构特征的表达, 并学习编码点云中更精细的空间几何、局部结

构、全局形状以及时间序列热核的融合特征, 提取具有普适性且具有显著辨别力的三维模型特征描述符, 从而提高了刚性、非刚性三维模型分类性能.

1 相关工作

目前, 刚性、非刚性三维模型的表征方式包括点云、视图、体素和网格等. 其中, 基于点云表征的三维模型特征提取方法分为传统的手工特征提取方法和基于深度学习的特征提取方法.

传统的手工特征提取方法包括基于物体表面形状的几何统计特征、物理信号的频谱特征等. Pickup 等^[5]利用模型的表面积作为特征描述符, 具有等距等容变换鲁棒性, 但该方法忽略了模型的局部结构信息; Sun 等^[6]利用曲面曲率计算拉普拉斯-贝尔特拉米算子, 通过各顶点的热量传播获得顶点的热核签名(heat kernel signature, HKS), 该特征对噪声、等距等容变换具有鲁棒性, 且适用于刚性、非刚性三维模型, 但是对于时间、尺度参数敏感, 难以兼顾表达物体的局部结构和全局形状属性; Bronstein 等^[7]以傅里叶变换为基础, 提出尺度不变 HKS(scale-invariant HKS, SIHKS), 消除了尺度变换的影响; Aubry 等^[8]提出波核签名描述符(wave kernel signature, WKS), 基于能量传播方式计算曲面各顶点的能量分布, 该特征表现出比 HKS 特征更强的区分性, 但是波核特征依赖频域的先验知识, 计算相对复杂, 不适用于刚性三维模型.

早期, 传统的手工特征无论是几何统计特征, 还是热核、波核等频谱特征, 都只能表达三维点云模型的浅层语义信息, 而结合基于深度学习的特征提取方法则能够学习更全面的深层语义特征. Charles 等^[9]提出直接处理点云的深度学习框架 PointNet, 利用多层感知机逐层学习顶点的特征, 并通过最大池化技术提取全局形状特征, 但丢失了点与点之间的局部结构信息, 难以描述局部结构多变的非刚性三维模型; Tong 等^[10]将谱特征与 PointNet 相结合, 通过编码 SIHKS 增加模型的局部特征表达, 采用多元投票策略获得模型级特征描述符, 但该特征描述符依然对于时间、尺度参数敏感; Duan 等^[11]提出三维模型的 WKS 和 SIHKS 融合特征, 以增强局部区分力, 通过大边距最近邻学习辨别力更为显著的模型级描述符, 但该方法不适用于刚性三维模型; Quenaya 等^[12]将提取的 HKS, WKS 和谱全局对称不变函数特征作为关键点, 并计算 3 种类型的光谱描述符, 转换成光谱图

像,通过二维网络学习 3 种光谱图像的融合特征,但该方法丢失了三维模型重要的空间结构信息,不适用于刚性三维模型;韩丽等^[13]构造了 HKS 和平均测地距离(average geodesic distance, AGD)联合特征的几何图像表示,并构建局部、全局联合特征的点特征,结合深度学习框架 PointNet^[9]学习具有区分性的深度融合特征,该特征对拓扑变化及局部残缺模型有较好的鲁棒性,但选取最佳 HKS 特征描述时间尺度复杂,不适用于刚性三维模型;Qi 等^[14]改进并提出 PointNet++, 利用最远点采样算法将点云进行邻域球划分,通过局部区域特征学习出更高级的全局特征,但是采样点集疏密不一、计算程度复杂;Wang 等^[15]提出动态图卷积神经网络(dynamic graph convolutional neural network, DGCNN)框架,分层提取局部结构特征,并通过最大池化聚合层级信息,提取模型的全局特征,但是该方法的点云分布直接影响 K 近邻(K -nearest neighbor, K -NN)图特征的学习,忽略了近邻点与远程点的关联信息,难以描述复杂形变的

非刚性三维模型;Xu 等^[16]提出一种基于编码点云的 Grid-GCN 深度学习框架,提高了点云的空间覆盖率,既学习点云模型局部特征,又学习到点组与点组之间的关联特征,是一种快速、可扩展的点云学习方法,但仍然不能克服非刚性铰链结构变换影响,难以描述非刚性三维模型.从整体上说,基于深度学习的方法能够学习更深层、全面的内在特征,具有一定鲁棒性,但仍然面临刚性、非刚性三维模型普适性特征分析的难题.

2 本文方法

基于深度学习的三维模型特征提取方法在分类任务中表现卓越,为解决刚性、非刚性三维模型的普适性特征分析提供了强大的支持.图 1 所示为本文方法框架,该框架同时适用于刚性、非刚性三维模型的特征提取,不仅能够学习模型的空间形状内在特征,而且对模型的刚性和非刚性变换具有鲁棒性,提高了刚性、非刚性三维模型分类准确率.




图 1 本文方法框架

2.1 局部面积加权密集化采样算法

为了采集高质量的三维点云模型,本文在传统密集化采样算法^[17]上进行采样判断机制改进,通过构建均匀分布的面片索引向量,使得密集化的点集在模型表面分布更加均匀;另外,只需在索引的面片中进行密集化采样,避免传统采样算法需要计算任意点到采样集合距离,采样效率更高.

本文提出的局部面积加权密集化采样算法首先根据三维模型总表面积进行 n_{sample} 等间隔划分,构造 $n_{\text{sample}} \times 1$ 维等间隔向量 $\mathbf{B}$. 然后读取模型面片数量 f , 构造 $f \times 1$ 维局部面积加权向量 $\mathbf{U}$, 通

过最小二范数查找 $\mathbf{B}$ 元素到 $\mathbf{U}$ 中元素的最短距离,并获取 U_j 的索引,构造面片索引向量 $\mathbf{F}$, 其元素值为

$$\mathbf{F} = \begin{cases} L_{\text{index}}(\min(d(\mathbf{B}_1, \mathbf{U}_j))) \\ L_{\text{index}}(\min(d(\mathbf{B}_2, \mathbf{U}_j))) \\ \vdots \\ L_{\text{index}}(\min(d(\mathbf{B}_i, \mathbf{U}_j))) \end{cases} \quad (1)$$

取向量 $\mathbf{B}$ 中的元素 $\mathbf{B}_i$, 向量 $\mathbf{U}$ 中的元素 $\mathbf{U}_j$, 对于 $\forall i \in \{1, 2, \dots, n_{\text{sample}}\}$, 总是 $\exists j \in \{1, 2, \dots, f\}$, 使得 d

$(B_i, U_j) = \|B_i - U_j\|_2$ 两者的距离最小, $L_{\text{index}}(\min(d(B_i, U_j)))$ 为满足条件下的索引, 并将索引值填充到面片索引向量 $\mathbf{F}$ 中. 最后通过面片索引顶点 $P(P_1, P_2, P_3)$ 的几何关系函数, 生成均匀分布的采样点 P' , 公式为

$$P' = (1-m-h) \times P_1 + m \times P_2 + h \times P_3 \quad (2)$$

其中, P_1, P_2, P_3 分别表示面片的 3 个顶点;

$$m \in \left\{ m = \frac{i}{M}, i = 0, 1, \dots, M \right\} \quad (3)$$

$$h \in \left\{ h = \frac{j}{H}, j = 0, 1, \dots, H \right\} \quad (4)$$

m 和 h 满足条件 $m, h \geq 0, m+h \leq 1, M$ 和 H 为面片边向量均等分割超参数, 本文均设置为 10.

局部面积加权密集化采样算法步骤如下:

输入. 预处理的三维模型 $D = \{D_1, D_2, \dots, D_t\}$, 采样点集数量 n_{sample} , 模型的总数量 t .

输出. 密集化采样点集 V , 其数据维度为 $n_{\text{sample}} \times 3$.

Step1. 读取三维模型 D_i 三角形网格面片集合, f 为面片数量, 初始化一个 $f \times 1$ 维的面片局部面积加权向量 U , 向量初始元素值设置为 0.

Step2. 遍历模型 D_i 面片集合, 计算各面片面积 S_i , 按照面片索引顺序, 依次累加并填充至 $f \times 1$ 维的局部面积加权向量 U 中, 其元素 $U_k = \sum_{i=1}^k S_i, k = 1, 2, \dots, f$.

Step3. 设置 $n_{\text{sample}} \times 1$ 维等间隔向量 B , 其元素 $B_i = \frac{U_f \times i}{n_{\text{sample}}}, i = 1, 2, \dots, n_{\text{sample}}$.

Step4. 遍历向量 B , 读取元素值 B_i 并代入式(1), 在向量 U 中使用 L_{index} 查找面片索引, 将索引值 j 存储在面片索引向量 $\mathbf{F}$ 中.

Step5. 根据面片索引向量得到对应的顶点 $P(P_1, P_2, P_3)$, 并将其代入式(2), 计算得到新的采样点 P' , 加入采样点集 V .

Step6. 输出模型采样点集 V , 其数据维度为 $n_{\text{sample}} \times 3$.

本文以刚性杯子三维模型和非刚性蚂蚁三维模型为例, 表 1 所示为 2 种模型采样时间对比. 可以看出, 与随机采样、最远点采样以及均匀采样等 3 种算法相比, 本文提出的局部面积加权密集化采样算法的采样效率更高, 对于更复杂、顶点数量更多的模型, 其采样速度有更明显的优势.

图 2 所示为刚性杯子三维模型的采样点集分布图. 可以看出, 图 2b, 图 2c 对杯子的局部和边缘

表 1 2 种模型采样时间对比

三维模型	算法			
	随机采样	最远点采样	均匀采样	本文
杯子(刚性)	0.481	0.703	0.236	0.128
蚂蚁(非刚性)	1.679	1.693	1.751	1.470

区域采样效果较好, 但中间大部分区域信息丢失; 图 2d 的点集整体分布较为均匀, 但在杯口、杯底边缘等局部区域疏密不一; 图 2e 无论是局部边缘还是整体轮廓形状, 其点集更为均匀、完整.




图 2 刚性杯子三维模型采样点集分布图

图 3 所示为非刚性蚂蚁三维模型的采样点集分布图. 可以看出, 图 3b, 图 3d 对蚂蚁边缘局部的采样点集较为稀疏, 局部形状缺失; 图 3c, 图 3e 都有较好的采样效果; 图 3e 的采样点集分布相对更均匀完整, 轮廓形状更明显. 从整体上看, 本文提出的局部面积加权密集化采样算法, 针对刚性和非刚性三维模型都可以保持快速、稳定且高质量的采样效果.




图 3 非刚性蚂蚁三维模型采样点集分布图

2.2 时间尺度序列热核编码

HKS 特征具有等距等容不变性, 当非刚性铰链结构受力形变时, 内部点相对位置发生改变, 各顶点的 HKS 特征值依然保持不变, 因此 HKS 特征能够克服非刚性铰链结构变换影响; 但是, HKS 特征对于时间参数敏感, 可以通过时间尺度参数来

描述模型的局部和全局属性. 当时间 t 很小时, 顶点热量扩散至周围, 此时 HKS 描述模型的局部结构属性; 当时间 t 较大时, 各顶点热量扩散至整个模型, 此时 HKS 描述模型的全局形状属性^[18]. 因此在单一时间下, HKS 难以兼顾表达三维模型的局部、全局属性. 针对这一难题, 本文提出时间尺度序列热核编码方法, 引入多个时间点采样, 在一定程度上缓解时间参数敏感, 且能够克服非刚性铰链结构变换影响.

为了保证模型在同一尺度下提取热核特征, 消除平移、尺度变换敏感, 采用局部面积加权密集化采样算法处理, 获得点云集; 同时, 选取时间序列 HKS 特征编码描述三维模型的局部结构和全局形状属性. 本文选取时间序列 $t = t_1, t_2, \dots, t_m$, 分别计算时间序列下各点的 HKS 特征值, 公式为

$$\text{HKS}_t(V) = \sum_{i=0}^{\infty} e^{-\lambda_i t} \phi_i^2, t = t_1, t_2, \dots, t_m \quad (5)$$

其中, 采样点云集合 V 的维度为 $n \times 3$; n 表示顶点数量. HKS 本质是基于拉普拉斯贝特米的形状描述算子, 而拉普拉斯矩阵与模型本身相关, 可以表示为 $L = A^{-1} \times W$. 其中, A 表示共享顶点面积的稀疏正对角矩阵; W 表示正定权重矩阵, 维度均为 $n \times n$. 将 L 分解为 $L = \Phi \Lambda \Phi^T$; 其中, Λ 表示 $n \times n$ 维的顶点特征值对角矩阵, Φ 表示其对应的特征向量, λ_i , ϕ_i 分别表示 Λ 和 Φ 的第 i 个特征值和特征向量. 另外, 时间 t 的选择需要满足 $[t_{\min}, t_{\max}]$, $t_{\min}$ 和 $t_{\max}$ 的公式为

$$\begin{cases} t_{\min} = 4 \ln 10 / \lambda_k \\ t_{\max} = 4 \ln 10 / \lambda_2 \end{cases} \quad (6)$$

将提取的 $\text{HKS}_t(V)$ 作归一化处理, 并进行特征拼接, 生成热核编码点云集, 归一化公式为

$$\text{HKS}'_t(V) = \frac{\text{HKS}_t(V) - \min(\text{HKS}_t(V))}{\max(\text{HKS}_t(V)) - \min(\text{HKS}_t(V))} \quad (7)$$

图 4 所示为非刚性蚂蚁模型时间序列热核编码可视化效果, 将归一化后 $[0,1]$ 的编码热核特征值映射到 $[0,255]$ 的颜色空间并进行可视化. HKS 特征值与对应的颜色空间分布如图 4f 所示, 当 HKS 特征值为 0 时, 对应蓝色; 当 HKS 特征值为 1 时, 对应黄色. 可以看出, 当 $t=0.1$ 时, 热量刚开始扩散, 图 4b 只能区分蚂蚁的腿和触须, 此时 HKS 值与腿部和触须的高斯曲率直接相关; 当 $t=2.0, 3.5$ 时, 图 4c, 图 4d 能够很好地通过绿色、紫色、黄色来区分蚂蚁的触须、腿、尾巴、身体等部位, 此时 HKS 描述的是蚂蚁的局部特性; 当 $t=9.2$

时, 随着 t 的增大, 热量扩散至全局表面, HKS 描述的是图 4e 所示的蚂蚁的整个表面细节全局属性.




图 4 非刚性蚂蚁模型时间序列热核编码可视化效果

图 5 所示为时间序列 $t = 0.1, 2.0, 3.5, 5.0, 9.2, 200.0$ 时飞机的热核颜色空间分布示例. 可以看出, 如图 5b~图 5d 所示, 当 $t = 0.1, 2.0, 3.5$ 时, HKS 描述的是飞机的局部结构属性, 特别是当 $t = 2.0$ 时, 飞机的机翼呈现绿色、中间部分呈现紫色, 热核局部的空间颜色分布差异性显著, 能够较好地地区分飞机的机翼、机尾、机身部位, 此时 HKS 对于飞机的局部特征表达良好; 如图 5e~图 5g 所示, 当 $t = 5.0, 9.2, 200.0$ 时, 此时 t 足够大, 热量已扩散至全局表面, 各顶点 HKS 特征值大小不变, HKS 描述的是飞机的全局属性. 另外, 如图 4e, 图 5f 所示, 当 t 足够大时, 同类模型的整体热核空间颜色分布相似, 不同类模型的颜色差异显著, 表明不同类的模型都有其固有的热核属性.




图 5 刚性飞机模型时间序列热核编码可视化效果

通过大量的可视化实验, 并对不同模型在不同时间尺度下进行局部特征对比后, 本文选取 $t = 0.1, 2.0, 9.2$ 的时间序列. 后续的消融实验结果表明, 时间序列热核编码在一定程度上弥补了热核特征在单一时间不能表达三维模型局部特性和全局特性的缺陷, 消除了热核时间参数敏感, 且选取的 3 个时间序列热核编码在时间、尺度参数对比中

取得了最佳的分类效果。

2.3 EPGCNN 模型

首先通过构建的局部面积加权密集化采样算法采集高质量的三维点云模型; 然后通过时间尺度的序列热核编码方法克服非刚性铰链结构带来的变换影响, 提高本文方法对非刚性变换的鲁棒性, 构造出局部结构信息丰富的新型编码数据源。传统提取点云特征的深度学习网络, 如 DeepGCN^[19], KPConv^[20]等, 能够学习到点云的空间结构信息, 但在一定程度上忽略了点云模型的内蕴几何信息, 如点云邻域的方向、距离信息等。此外, 随着网络层数的加深, 模型的深度特征逐渐抽象, 丢失了大量模型原始的局部结构、表面细节信息, 与原始特征出现偏差。

针对上述问题, 本文在 DGCNN 的基础上提出 EPGCNN, 引入 ABEM 模块, 增强 HKS 特征在局部结构信息的表达, 并学习编码点云模型中更精细的空间几何、局部结构及全局形状信息。

图 6 所示为 EPGCNN 结构, 输入为三维模型时间序列热核编码点云集 V , $B \times 6 \times N$ 维。其中, N 表示编码点云的数量, B 表示输入批量; 列属性为 $(x, y, z, HKS_{t_1}, HKS_{t_2}, HKS_{t_3})$; 引入 ABEM 模块, 通过 4 层的 ABEM 模块分层提取编码点云图结构边缘特征 R 及图结构边缘校正特征 X ; 拼接并作最大池化操作, 提取 1×1024 维的编码点云深度融合特征; 通过 BN 批量归一化、全连接层、LeakyReLU 激活函数输出模型的分类概率。




图 6 EPGCNN 结构

对于每一层 ABEM 模块, 均构造一层编码点云的 K -NN 图边缘卷积结构以及一层 K -NN 图边缘卷积校正结构.

(1) K -NN 图边缘卷积结构的输入为 $B \times F \times N$, F 为编码点云初始特征, 拼接 K -NN 点云关联特征后的维度为 $B \times 2F \times N \times K$. 通过 Conv_2D Block2 模块提取编码点云边缘特征 R , 通过 Conv_2D Block1 及 Conv_2D Block2 模块提取还原特征; 然后与原始编码点云特征相减作误差反馈, 提取误差特征.

(2) K -NN 图边缘卷积校正结构的输入为 1×1024 维的误差特征, 首先构造误差特征的 K -NN 图结构, 通过 Conv_2D Block1 模块提取 K -NN 图边缘误差特征; 然后累加第 1 层的 K -NN 图边缘特征 R 并作最大池化操作, 提取更为精细的图结构边缘校正特征 X . 其中, Conv_2D Block1 模块由 1×1 卷积、BN 批量归一化层以及 ReLU 激活函数组成; Conv_2D Block2 由 $1 \times K$ 卷积、BN 批量归一化层以及 ReLU 激活函数组成, 通道注意力模块(channel attention module, CAM)的输入、输出维度均为 $B \times A \times M$.

从图 6 可以看出, 每一层的 ABEM 模块均提取到了点云 K -NN 图的局部邻域特征和校正特征. ABEM 模块利用纠错反馈结构的思想全面捕捉点云的局部特征, 提取更为精细的校正特征, 增强了 HKS 特征在非刚性局部结构信息的表达. 另外, 编码的 HKS 特征不仅蕴含点与点在模型表面的距离及曲率关系, 且具有等距等容不变性, 而且在克服非刚性铰链变换的同时, 提高了本文方法对非刚性变换的鲁棒性.

3 实验及结果分析

本文实验平台为 Intel 4.2 GHz CPU, NVIDIA RTX TITAN 24GB 显卡, 16GB 内存的 PC 机. 实验数据集来自公开的刚性三维模型数据集 ModelNet40^[21]和非刚性三维模型数据集 SHREC15^[22], 数据集的基本信息如表 2 所示. 模型的采样阶段, 局部面积加权密集化采样算法中, 取 $n_{\text{sample}} = 1024$, 热核时间序列 $t = 0.1, 2.0, 3.5, 9.2$. 在 ModelNet40 的分类任务中, 设置网络训练参数 batchsize 为 16, 学习率为 0.001, dropout 为 0.5, 正则化权重为 5×10^{-1} , 训练 epoch 为 100; 在 SHREC15 的分类任务中, 设置网络训练参数学习率为 0.01, 学习率衰减率为 0.7, 衰减周期为 20 个 epoch.

表 2 实验选用数据集的基本信息

数据集	模型数量	类的数量	训练集 : 测试集
ModelNet40	12311	40	8 : 2
SHREC15	1200	50	7 : 3

3.1 采样算法对比实验

采用 ModelNet40, 通过 EPGCNN 和 PointNet^[9] 对面积加权密集化采样算法的有效性进行验证. 为保证在同一条件下验证采样算法的有效性, EPGCNN 方法与 PointNet 方法^[9]均采样 1024 个点.

表 3 所示为 2 种采样方法分类准确率对比. 可以看出, 与均匀采样方法相比, 本文方法更具有有效性, 能够采集更高质量的三维点云模型.

表 3 2 种方法分类准确率对比 %

方法	EPGCNN	PointNet ^[9]
均匀采样	90.70	85.89
本文	91.52	86.75

3.2 刚性、非刚性三维模型分类实验

将本文方法与文献[9,13-16,23-32]方法在 ModelNet40 和 SHREC15 上的分类性能进行对比. 首先读取三维模型网格数据, 通过局部面积加权密集化采样算法采集高质量的三维点云模型; 然后进行时间尺度序列热核编码, 通过 EPGCNN 分层提取编码点云 K -NN 的图结构特征、校正特征和时间序列热核的融合特征, 通过拼接以上特征并作最大池化操作, 提取 1×1024 维时间序列热核编码点云深度融合特征. 19 种方法在 2 个数据集上的分类准确率对比如表 4 所示.

其中 PointNet^[9], PointNet++^[14], SpiderCNN^[29]等方法在 SHREC15 上的分类结果来自文献[24]提出的网格卷积(mesh convolution)方法, MVCNN^[30]在 SHREC15 上的分类结果来自于韩丽等^[32]提出的结构感知深度学习的三维模型分类方法. 从表 4 可以看出:

(1) 在相同条件下, EPGCNN 与 PointNet^[9]相比, EPGCNN 在空间结构、内蕴几何特征提取上更具优越性, 原因是 EPGCNN 不仅能够分层提取图结构边缘特征, 保证局部结构信息的提取, 还能够通过图结构边缘卷积校正结构全面捕捉点云的局部特征, 提取更为精细的校正特征, 增强 HKS 特征在非刚性局部结构信息的表达. 当采用空间坐标及 3 个时间序列 HKS 特征组合作为输入时, EPGCNN 在 ModelNet40 和 SHREC15 上分类准确率均明显提高. 可以得出如下结论: a. EPGCNN 提取的时间序

表 4 19 种方法在 2 个数据集上的分类准确率对比 %

方法	输入特征	ModelNet 40	SHREC 15
DeepGM ^[23]	测地线矩内在特征		93.03
MeshWalker ^[24]	网格	92.30	
PFCNN ^[25]	网格		98.80
MAT-Net ^[26]	XYZ 空间坐标		96.42
GeoNet(POF) ^[27]	XYZ 空间坐标		94.67
3D-GCN ^[28]	XYZ 空间坐标		92.10
Grid-GCN ^[16]	XYZ 空间坐标		93.10
PointNet ^[9]	XYZ 空间坐标	89.20	69.40
PointNet ^[9]	XYZ 空间坐标+3 个时间 序列的 HKS 特征	91.17	92.00
PointNet++ ^[14]	XYZ 空间坐标	90.70	60.18
PointNet++ ^[14]	XYZ 空间坐标+HKS, WKS, 高斯曲率特征		94.49
DGCNN ^[15]	XYZ 空间坐标	92.90	82.29
SpiderCNN ^[29]	XYZ 空间坐标	92.40	95.80
MVCNN ^[30]	视图	89.90	96.17
View-GCN ^[31]	视图	97.60	
F-PointCNN ^[13]	视图		96.20
结构感知 CNNs 联合学习模型 ^[32]	视图		97.12
本文 EPGCNN	XYZ 空间坐标	91.52	88.86
本文 EPGCNN (时间序列)	XYZ 空间坐标+3 个时间 序列的 HKS 特征	92.63	97.71

列热核编码点云深度融合特征用于三维模型分类, 具有较好的普适性; b. 在不同时间尺度下, HKS 特征可有效地增加三维模型在局部结构、全局形状信息的表达, 丰富了数据源信息, 从而提高本文方法的整体分类准确率。

(2) 与使用内在特征的模型方法相比, F-PointCNN^[13]需要提取 AGD, HKS 特征, 然后学习联合特征的融合特征; PointNet++^[14]需提取模型的 WKS, HKS 和多尺度高斯曲率特征, 然后进行主成分分析, 生成输入的 64 维内在特征; 结构感知 CNNs^[32]需要提取改进的 HKS 特征作为结构空间特征; DeepGM^[23]提取测地线矩作为内在特征; GeoNet(POF)^[27]需要学习点云高层特征, 然后通过测地线匹配层学习拓扑结构特征; 而 EPGCNN 除了学习三维模型的空间形状信息、提取时间序列热核编码点云的融合特征外, 还通过 K-NN 构造基于图的数据, 能够更好地建模和学习非刚性三维模型的拓扑特征。

(3) 在 SHREC15 的分类对比实验中, 与经典谱特征方法及内在特征编码方法 DeepGM^[23]等相比, EPGCNN 方法在空间坐标及 3 个时间序列的 HKS 特征输入下, 分类效果有显著的提升; 与 Point-

Net++^[14], MAT-Net^[26], GeoNet^[27], 3D-GCN^[28], SpiderCNN^[29]等方法相比, EPGCNN 方法的分类效果较好。显然, 本文方法通过 HKS 特征编码, 在一定程度上克服了非刚性变换影响, 增加了模型的局部特征、全局形状表达, 且充分地考虑了点云之间的关联信息, 学习的特征描述符表现力更强。

(4) 在 ModelNet40 的分类对比实验中, EPGCNN 方法在空间坐标及 3 个时间序列的特征输入下, 性能明显优于经典的网格方法 MeshWalker^[24], 多视图方法 MVCNN^[30]以及点云方法 PointNet^[9], PointNet++^[14]。图 7 和图 8 所示为 EPGCNN 在 ModelNet40 及 SHREC15 上的分类混淆矩阵。

由图 7 可以看出, 刚性课桌模型的分类准确率较低, 容易被分类为桌子模型。课桌与桌子 2 类模型在形状上较为相似, 可区分性较低。另外, 课桌模型的训练数据量较少, 桌子模型的训练数量较多, 桌子的学习特征更为显著。因此, 课桌容易被识别为桌子类别, 导致分类准确率较低。

由图 8 可以看出, EPGCNN 方法在非刚性数据集上的分类性能较好, 时间序列热核编码能够有效地克服非刚性铰链结构的变换影响, 并且能够有效地增强热核特征在局部结构信息的表达, 提高了非刚性三维模型的整体分类准确率。

(5) 当 EPGCNN 在同时面对 2 个数据集时, PointNet^[9], PointNet++^[14], DGCNN^[15]等在 SHREC15 上的分类效果比在 ModelNet40 上差。原因是刚性模型是在角度、位移上的简单方位变换, 而 PointNet++^[14], DGCNN^[15]能够学习到点云的空间信息以及关联信息, 很好地描述模型的局部及全局形状特征, 对刚性变换具有一定的鲁棒性; 非刚性模型具有特殊的铰链结构, 受力前后大小、形状和内部各点的相对位置均会发生改变, 导致非刚性模型形变复杂多样, 同一物体的不同姿态被识别为不同的类别, 从而导致分类结果较差。

本文编码的 HKS 特征是点基于流型表面的热扩散, 从顶点 X 到顶点 Y 热量损失的值仅与 X , Y 这 2 点在流型表面的距离和曲率相关。即使内部点相对空间位置发生改变, 在同一时间各点的 HKS 特征值始终保持不变, 能够很好地克服非刚性铰链结构的变换影响。另外, EPGCNN 引入 ABEM 模块, 能够学习点云的 K-NN 图边缘特征及边缘校正特征, 增强了 HKS 特征在局部结构信息的表达, 从而学习编码点云模型中更精细的空间几何、局部结构及全局形状信息。因此, EPGCNN 框架能够提取具有普适性且具有显著辨别力的三维




图 8 SHREC15 分类混淆矩阵

表 5 本文方法在 2 个数据集上的消融实验

方法	输入特征	ModelNet40	SHREC15
EPGCNN	XYZ 空间坐标	91.52	88.86
	3 个时间序列的 HKS 特征(HKS ₁ , HKS ₂ , HKS ₃) ($t = 0.1, 2.0, 9.2$)	64.42	67.23
EPGCNN(单一时间节点)	XYZ 空间坐标+单一时间节点的 HKS 特征($t = 0.1$)	91.21	93.42
	XYZ 空间坐标+单一时间节点的 HKS 特征($t = 2.0$)	91.73	94.00
	XYZ 空间坐标+单一时间节点的 HKS 特征($t = 3.5$)	91.61	94.29
	XYZ 空间坐标+单一时间节点的 HKS 特征($t = 9.2$)	91.55	92.57
EPGCNN(时间序列)	XYZ 空间坐标+2 个时间序列的 HKS 特征($t = 0.1, 9.2$)	91.86	94.86
	XYZ 空间坐标+2 个时间序列的 HKS 特征($t = 0.1, 3.5$)	91.90	95.14
	XYZ 空间坐标+2 个时间序列的 HKS 特征($t = 2.0, 9.2$)	92.18	95.14
	XYZ 空间坐标+2 个时间序列的 HKS 特征($t = 3.5, 9.2$)	91.94	95.43
	XYZ 空间坐标+3 个时间序列的 HKS 特征($t = 0.1, 3.5, 9.2$)	92.26	97.42
	XYZ 空间坐标+3 个时间序列的 HKS 特征($t = 0.1, 2.0, 9.2$)	92.63	97.71
	XYZ 空间坐标+4 个时间序列的 HKS 特征($t = 0.1, 2.0, 3.5, 9.2$)	90.55	86.86

注: 粗体表示最优值.

比原始的空间坐标输入均有所提高,说明增加的热核特性能很好地补充模型在局部结构或全局形状属性上的特征表达。另外,当 $t=0.1$ 时,三维模型各顶点热量还未扩散,此时 HKS 描述的是模型的初始属性,由三维模型的拉普拉斯矩阵表示可知,初始属性与各顶点组成的面片夹角相关;当 $t=2.0, 3.5$ 时,从图 4 和图 5 的时间序列热核编码视图中可以看出,此时模型各顶点热量扩散至周围, HKS 可以很好地描述刚性、非刚性三维模型的局部特性;当 $t=9.2$ 时,模型各顶点的热量已扩散至整个模型,此时 HKS 描述的是三维模型的全局形状属性,且在单一时间节点的 HKS 特征,由于刚性、非刚性模型表面曲率、结构的不同,热核扩散速度有所差异。因此,分别在 $t=2.0, 3.5$ 时取得了最佳的分类效果,表明模型的局部结构属性比初始属性、全局形状属性是更为有效的特征表达。

(3) 当 XYZ 空间坐标与 2 个时间序列的 HKS 特征作为输入源时,本文选取 $t=0.1, 2.0, 3.5, 9.2$ 不同时间尺度的多种组合,与单一时间节点的 HKS 特征编码实验相比,其分类准确率均有所提高。因此,XYZ 空间坐标及 2 个时间序列 HKS 特征编码能够有效地增加三维模型初始、局部或全局属性表达。

(4) 当 XYZ 空间坐标与 3 个时间序列 HKS 特征作为输入源时,与单一时间节点或者 2 个时间节点的 HKS 特征编码数据源相比,时间尺度序列热核编码方法的分类效果均有所提高。因此,3 个时间序列 HKS 特征能够同时弥补模型的初始、局部结构及全局形状信息表达不充分的缺陷。

(5) 当 XYZ 空间坐标与 4 个时间序列 HKS 特征作为输入源时,在 2 个数据集上的分类准确率均下降。由于 3 个时间节点的序列 HKS 特征编码足够同时描述三维模型的初始、局部及全局属性,从目前实验结果看,选用 4 个时间节点的 HKS 特征编码数据源在 2 个数据集上的分类准确率均有所下降,推测可能是 4 个时间节点数据造成了热核信息冗余所致;另外,由(1)可知,三维模型的 XYZ 空间结构特征相较于 HKS 描述的局部结构或全局形状特征是更为重要的特征表达,4 维的序列 HKS 特征在一定程度上削弱了 XYZ 三维坐标为主的空间结构特征,导致刚性、非刚性三维模型的分类准确率下降,从侧面验证 3 个时间节点的序列 HKS 特征编码能够解决热核对于时间参数敏感、最优时间选取困难的问题。

3.3.2 网络结构消融实验

为了进一步验证 ABEM 模块的有效性,分析

了该模块的层数对刚性数据集 ModelNet40 分类性能的影响。

表 6 所示为 EPGCNN 在 ModelNet40 上的消融实验结果。可以看出,当 ABEM 模块层数不超过 4 时,随着 ABEM 模块层数的增加,EPGCNN 性能逐渐增强;当 ABEM 模块增加至第 4 层时,相对于第 1 层,EPGCNN 的分类准确率提高 2.56 个百分点;当 ABEM 模块为第 5 层和第 6 层时,相对于第 4 层,EPGCNN 的分类准确率分别下降 0.73 个百分点和 1.83 个百分点,EPGCNN 性能逐层下降。

表 6 EPGCNN 在 ModelNet40 上的消融实验 %

ABEM 模块层数	EPGCNN
1	90.07
2	90.88
3	91.65
4	92.63
5	91.90
6	90.80

注:粗体表示最优值。

实验结果表明,ABEM 模块层数对于 EPGCNN 的性能有显著影响。这是由于当采样点数量为 1024 时,采用 4 层的 ABEM 模块足以学习编码点云的局部结构、空间形状及时间序列的融合特征,图结构层数的继续增加反而造成了网络参数的大量冗余,导致分类下降。

4 结 语

本文提出一种三维模型普适性特征提取方法。首先提出一种局部面积加权密集化采样算法,从根本上提高对三维模型平移和尺度等刚性变换的鲁棒性,并采集出高质量的三维点云模型;然后针对非刚性铰链结构变换、点云信息表达不足问题,提出一种基于时间尺度的序列热核编码方法,提高对三维模型非刚性变换的鲁棒性,构造出局部结构信息丰富的新型编码数据源;最后提出了 EPGCNN,引入 ABEM 模块,增强热核在局部结构特征的表达,并学习编码点云更精细的空间形状以及时间序列热核的融合特征,提取的三维模型特征描述符具有普适性。在国际标准公开数据集 ModelNet40 和 SHREC15 上的分类实验结果表明,本文方法提取了时间序列热核编码点云深度融合特征,并且在刚性、非刚性三维模型的分类任

务中都能获得较高的分类性能,是一种既适合刚性,也适合非刚性三维模型的、具有显著辨别力的普适性特征描述符。

在未来工作中,将进一步探索 HKS 特征的时间节点及热核序列数量的最优选取方法,以及 ABEM 模块的最优配置的规律性,获得更具普适性和显著辨别力的三维模型特征描述符,提高分类的准确率。

参考文献(References):

- [1] Tang Lei, Ding Bo, He Yongjun. An efficient 3D model retrieval method based on convolutional neural network[J]. *Acta Electronica Sinica*, 2021, 49(1): 64-71(in Chinese)
(汤磊, 丁博, 何勇军. 基于卷积神经网络的高效三维模型检索方法[J]. *电子学报*, 2021, 49(1): 64-71)
- [2] Zhang Mantun, Yan Mingxiao, Ma Yingshi, *et al.* 3D voxel model retrieval based on octree structure[J]. *Chinese Journal of Computers*, 2021, 44(2): 334-346(in Chinese)
(张满囤, 燕明晓, 马英石, 等. 基于八叉树结构的三维体素模型检索[J]. *计算机学报*, 2021, 44(2): 334-346)
- [3] Bai Jing, Si Qinglong, Qin Feiwei. 3D model classification and retrieval based on CNN voting scheme[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2019, 31(2): 303-314(in Chinese)
(白静, 司庆龙, 秦飞巍. 基于卷积神经网络和投票机制的三维模型分类与检索[J]. *计算机辅助设计与图形学学报*, 2019, 31(2): 303-314)
- [4] Li Haisheng, Sun Li, Wu Xiaoqun, *et al.* Non-rigid 3D shape retrieval based on inner dihedral angle histogram[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2017, 29(6): 1128-1134(in Chinese)
(李海生, 孙莉, 吴晓群, 等. 基于模型内二面角分布直方图的非刚性三维模型检索[J]. *计算机辅助设计与图形学学报*, 2017, 29(6): 1128-1134)
- [5] Pickup D, Sun X, Rosin P L, *et al.* Shape retrieval of non-rigid 3D human models[J]. *International Journal of Computer Vision*, 2016, 120(2): 169-193
- [6] Sun J, Ovsjanikov M, Guibas L. A concise and provably informative multi-scale signature based on heat diffusion[J]. *Computer Graphics Forum*, 2009, 28(5): 1383-1392
- [7] Bronstein M M, Kokkinos I. Scale-invariant heat kernel signatures for non-rigid shape recognition[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2010: 1704-1711
- [8] Aubry M, Schlickewei U, Cremers D. The wave kernel signature: a quantum mechanical approach to shape analysis[C] // *Proceedings of the International Conference on Computer Vision*. Los Alamitos: IEEE Computer Society Press, 2011: 1626-1633
- [9] Charles R Q, Su H, Mo K, *et al.* PointNet: deep learning on point sets for 3D classification and segmentation[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2017: 77-85
- [10] Tong J W, Zhao J B, Jin J Y, *et al.* An improved deep multiple-input and single-output PointNet for 3D model retrieval[C] // *Proceedings of the IEEE International Conference on Networking, Sensing and Control*. Los Alamitos: IEEE Computer Society Press, 2020: 1-6
- [11] Duan C M, Liu M Z. 3D shape descriptor by principal component analysis embedding for non-rigid 3D shape retrieval in a learning framework[C] // *Proceedings of the IEEE Data Driven Control and Learning Systems Conference*. Los Alamitos: IEEE Computer Society Press, 2021: 49-54
- [12] Quenaya J F L, Alamo C J L D. Non-rigid 3D shape classification based on convolutional neural networks[C] // *Proceedings of the IEEE Latin American Conference on Computational Intelligence*. Los Alamitos: IEEE Computer Society Press, 2017: 1-6
- [13] Han Li, Tong Yuning, Piao Jingyu, *et al.* Non rigid 3D shape partial matching based on deep feature fusion[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2021, 33(3): 475-486(in Chinese)
(韩丽, 佟宇宁, 朴京钰, 等. 深度特征融合的非刚性三维形状局部匹配[J]. *计算机辅助设计与图形学学报*, 2021, 33(3): 475-486)
- [14] Qi C R, Yi L, Su H, *et al.* PointNet++: deep hierarchical feature learning on point sets in a metric space[C] // *Proceedings of the Neural Information Processing Systems*. Cambridge: MIT Press, 2017: 5105-5114
- [15] Wang Y, Sun Y B, Liu Z W, *et al.* Dynamic graph CNN for learning on point clouds[J]. *ACM Transactions on Graphics*, 2019, 38(5): Article No.146
- [16] Xu Q G, Sun X D, Wu C Y, *et al.* Grid-GCN for fast and scalable point cloud learning[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2020: 5660-5669
- [17] Zhou Y, Zeng F Z, Qian J C, *et al.* 3D shape classification and retrieval based on polar view[J]. *Information Sciences*, 2019, 474: 205-220
- [18] Zhang Dan, Wu Zhongke, Wang Xingce, *et al.* Survey on shape descriptors based on spectral analysis for non-rigid 3D shape matching[J]. *Journal of Software*, 2019, 30(8): 2545-2568(in Chinese)
(张丹, 武仲科, 王醒策, 等. 非刚性三维形状匹配中基于谱分析的形状描述符综述[J]. *软件学报*, 2019, 30(8): 2545-2568)
- [19] Li G H, Muller M, Qian G C, *et al.* DeepGCNs: making GCNs go as deep as CNNs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(6): 6923-6939
- [20] Thomas H, Qi C R, Deschaud J E, *et al.* KPConv: flexible and deformable convolution for point clouds[C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2019: 6410-6419
- [21] Shilane P, Min P, Kazhdan M, *et al.* The Princeton shape benchmark[C] // *Proceedings of Shape Modeling Applications*. Los Alamitos: IEEE Computer Society Press, 2004: 167-178
- [22] Lian Z, Zhang J, Choi S, *et al.* SHREC'15 track: non-rigid 3D shape retrieval[C] // *Proceedings of the Eurographics Workshop*

- on 3D Object Retrieval. Aire-la-Ville: Eurographics Association Press, 2015: 107-120
- [23] Luciano L, Ben Hamza A. Deep learning with geodesic moments for 3D shape classification[J]. Pattern Recognition Letters, 2018, 105: 182-190
- [24] Lahav A, Tal A. MeshWalker: deep mesh understanding by random walks[J]. ACM Transactions on Graphics, 2020, 39(6): Article No.263
- [25] Yang Y Q, Liu S L, Pan H, *et al.* PFCNN: convolutional neural networks on 3D surfaces using parallel frames[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2020: 13575-13584
- [26] Hu J W, Wang B, Qian L H, *et al.* MAT-net: medial axis transform network for 3D object recognition[C] //Proceedings of the 28th International Joint Conference on Artificial Intelligence. New York: ACM Press, 2019: 774-781
- [27] He T, Huang H B, Yi L, *et al.* GeoNet: deep geodesic networks for point cloud analysis[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2019: 6881-6890
- [28] Lin Z H, Huang S Y, Wang Y C. Convolution in the cloud: learning deformable kernels in 3D graph convolution networks for point cloud analysis[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2020: 1797-1806
- [29] Xu Y F, Fan T Q, Xu M Y, *et al.* SpiderCNN: deep learning on point sets with parameterized convolutional filters[C] //Proceedings of the European Conference on Computer Vision. Heidelberg: Springer, 2018: 90-105
- [30] Su H, Maji S, Kalogerakis E, *et al.* Multi-view convolutional neural networks for 3D shape recognition[C] //Proceedings of the IEEE International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2015: 945-953
- [31] Wei X, Yu R X, Sun J. View-GCN: view-based graph convolutional network for 3D shape analysis[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2020: 1847-1856
- [32] Han Li, Piao Jingyu, Lan Pengyan, *et al.* 3D shape classification method based on shape-aware deep learning[J]. Journal of Computer-Aided Design & Computer Graphics, 2021, 33(1): 29-38(in Chinese)
(韩丽, 朴京钰, 兰鹏燕, 等. 结构感知深度学习的三维形状分类方法[J]. 计算机辅助设计与图形学学报, 2021, 33(1): 29-38)