

利用网格卷积特征的三维形变目标分类

史聪伟¹, 赵杰煜^{1,2}, 陈瑜¹

(1. 宁波大学信息科学与工程学院, 浙江宁波 315211; 2. 浙江省移动网络应用技术重点实验室, 浙江宁波 315211)

摘要: 三维目标的形状变化给目标识别带来很大挑战, 同时三维网格模型的不规则数据结构难以直接应用卷积运算提取三维目标特征. 对此, 本文提出了一种高效的三维形变目标的网格卷积特征表示方法, 准确提取形状信息并进行分类. 首先通过网格卷积运算获得形变目标中典型局部曲面形状分布, 其次通过马尔科夫链对曲面形状的空间共现关系建模, 从而形成三维模型的全局特征描述, 最后采用支持向量机实现形变目标分类. 该方法将连续多项式函数作为卷积模板, 实现针对不规则数据结构的网格卷积运算, 并且给出了卷积模板参数的无监督学习方法. 在标准非刚性三维模型数据集 SHREC10 与 SHREC15 上的实验结果表明本文方法能有效提取三维网格模型的形状信息, 分类准确率分别达到了 92.88% 与 96.54%.

关键词: 三维形变模型; 网格卷积; 三维形状特征; 支持向量机

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2020)04-0648-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.04.005

3D Non-rigid Object Classification with Mesh Convolution Features

SHI Cong-wei¹, ZHAO Jie-yu^{1,2}, CHEN yu¹

(1. Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo, Zhejiang 315211, China;

2. Mobile Network Application Technology Key Laboratory of Zhejiang Province, Ningbo, Zhejiang 315211, China)

Abstract: 3D object recognition with shape changes is a challenging task. The irregular data structure of the mesh model prevents the operation of the conventional convolution, which brings difficulties to feature extraction of the 3D non-rigid objects. In this paper, we propose a method of mesh convolution for 3D non-rigid objects to extract shape features and use them for classification. Firstly, we obtain the distribution of typical patch shapes by the mesh convolution. Then, we model the spatial co-occurrence relationship by Markov chains to complete the global feature description. Finally, we use the support vector machine to classify the 3D objects. Our method adopts the continuous polynomial function as the convolution kernel for the irregular data structure, and learn the kernel by an unsupervised learning method. Experimental results on the standard non-rigid 3D model datasets show our method can effectively extract the features and achieve classification accuracy of 92.88% on SHREC10 and 96.54% on SHREC15, respectively.

Key words: non-rigid 3D model; mesh convolution; 3D shape feature; support vector machine

1 引言

近年来二维图像处理中的卷积运算结合机器学习方法在图像识别领域取得了巨大成功^[1]. 三维图像数据与二维数据相比包含的信息更为丰富, 具有更好的光照不变性和姿态不变性. 在目标分类任务中采用三维图像可以排除环境光照和目标姿态变化带来的严重影响, 具有更高的可靠性和分类正确率. 因此如何利用卷积运算更加有效地提取三维信息提高目标分类准确

率成为了研究热点^[2,3].

目标分类任务中, 三维目标形状变化带来了很大挑战. 三维目标模型分为刚性模型和非刚性模型^[4]. 非刚性三维模型也称为可形变模型, 其变换种类多样、形式复杂, 特征提取的难度更高, 但也更接近现实世界中物体, 逐渐成为三维模型识别领域的研究重心, 目前针对刚性模型的特征提取算法在非刚性模型上很难取得同样有效的结果.

现有三维非刚性模型特征提取方法可分为基于几

何信息分布的方法、基于谱分析的方法、基于局部特征的码本学习方法. 基于模型几何信息分布的特征提取方法有: Mahmoudi 等人^[5]定义了测地距离等几何信息并以其分布直方图作为模型特征描述符进行分析, 由于对各顶点间计算最短路径, 计算复杂度高, 为 $O(n^3)$; Sipiran 等人^[6]引入 Harris 算子进行显著点采样来提取特征描述符, 缩短了计算时间. 基于谱分析的方法将非刚性三维模型定义为流形函数, 利用流形函数的特征值和特征向量描述模型, 如 ShapeDNA 方法^[7]、GPS (Global Point Signature) 方法^[8]. Sun J^[9]模拟表面热扩散提出热核特征描述 (Heat Kernel Signature, HKS), Bronsterin^[10]改进 HKS 方法使其具有尺度变换不变性; Aubry^[11]基于波动方程提出了更有优势的波核特征 (Wave Kernel Signature, WKS). 这些方法能准确获取模型内蕴特征, 对形变具有鲁棒性, 但对三维网格模型质量要求苛刻. 在局部特征描述方法的基础上, 有学者采用视觉码本模型实现三维目标分类, 但缺失了低层特征间空间关系信息. 对此 Han^[12]提出一种空间上下文相关性模型 (Bag of Spatial Context Correlations, BoSCCs), 通过马尔科夫链对低层特征的空间共现关系建模形成高层特征, 提升码本模型的效果. 综上所述, 基于几何信息分布的全局特征直观易理解但计算量大且可能会忽视重要的局部信息; 基于谱分析的局部特征具有姿态、形状不变性, 但计算复杂且受网格模型质量的影响.

卷积具有提取局部特征的能力, 计算方便灵活. 因此学者们将三维网格模型体素化实现对三维目标的卷积特征提取^[3]. 三维体素模型的不足在于存储效率与计算效率低, 易丢失复杂形状的细节信息. 现有卷积模板是局部空间中权重的离散分布表示, 在运算过程中要求图像具有规则的数据结构, 难以直接对不规则数据进行卷积运算.

本文提出一种三维形变目标的网格卷积特征提取及分类方法. 首先通过三维网格卷积运算获取局部网格曲面形状分布信息, 然后结合局部形状在模型中的空间共现关系形成三维形变目标的全局特征表示, 最后采用支持向量机对三维形变目标分类. 本文方法中针对网格模型数据采用高阶多项式作为网格卷积模板表示, 使卷积运算能够提取网格模型的局部特征, 并利用无监督学习方法学习模板参数. 本文算法总体框架如图 1 所示.

2 三维形变目标网格卷积特征提取

三维网格卷积运算针对三维网格模型数据结构特点, 采用多项式作为局部曲面形状的表达, 并定义局部曲面之间的形状差异度量. 对给定的输入三维形变目

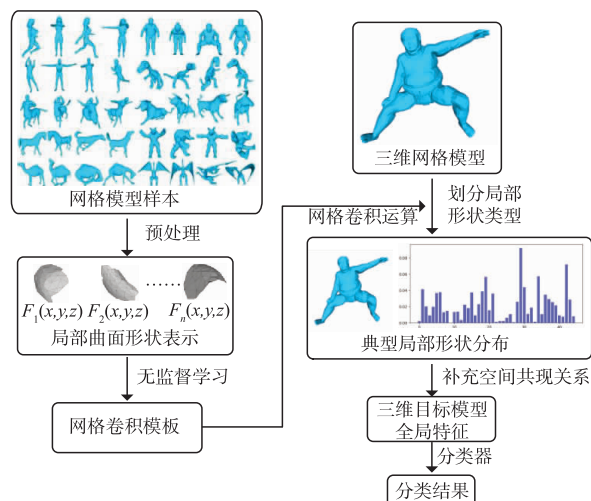


图 1 三维形变目标网格卷积特征提取与分类算法框架

标网格模型, 通过三维网格卷积运算计算可以获得典型局部曲面形状的在目标模型中的分布.

2.1 局部曲面形状描述及差异度量

给定一个三维形变目标的网格模型 M^s , 该三维网格模型的局部曲面窗口定义为: 以网格模型顶点 v_i 为窗口中心, 采用广度优先搜索获取其前 $K-1$ 个邻域顶点, 选中的顶点和顶点间的边所构成连通的局部网格曲面即局部曲面窗口.

为避免刚性变换以及非刚性变换的影响, 窗口中需要建立局部坐标系并将窗口内顶点的绝对坐标转换为局部坐标系内的坐标表示. 窗口内局部坐标系以窗口中心顶点 v_i 为原点, 所有顶点的平均法向量 \mathbf{n} 的方向为局部坐标系的 z 轴方向. 对窗口内顶点在 XOY 平面内的投影采用 PCA 方法计算投影点的主方向 \mathbf{a} 并将其作为局部坐标系的 x 轴方向, 以单位向量 $\mathbf{n}, \mathbf{a}, \mathbf{n} \times \mathbf{a}$ 为基底建立窗口局部坐标系. 窗口内局部曲面较为简单, 因此在窗口局部坐标系下采用高阶多项式方程 $F(\mathbf{v}^c | \boldsymbol{\theta}) = 0$ 对其形状进行描述, 其中 $F(\mathbf{v}^c | \boldsymbol{\theta})$ 为局部曲面的连续函数表示, \mathbf{v}^c 为窗口内顶点的相对坐标, $\boldsymbol{\theta}$ 为表达式的参数. 实验过程中发现, 窗口大小 K 过小时曲面形状趋于一致难以区分, 而当 K 变大时窗口内曲面较复杂, 因此在拟合中结合顶点相对窗口中心点的近似测地距离 d 来进行更好的描述. 最终取 $\mathbf{v}^c = (x, y, z, d)$, 窗口曲面拟合函数如下

$$F(\mathbf{v}^c | \boldsymbol{\theta}) = z - (\theta_0 + \theta_1 x + \theta_2 y + \theta_3 d + \theta_4 x^2 + \theta_5 y^2 + \theta_6 d^2 + \theta_7 xy + \theta_8 xd + \theta_9 yd) \quad (1)$$

其中参数 $\boldsymbol{\theta} = (\theta_0, \theta_1, \dots, \theta_9)$ 采用最小二乘法求解计算. 给定两个不同顶点 v_q 与 v_r , 以它们为中心的局部网格曲面 M_q 与 M_r 对应曲面函数表示分别为 $F_q(\mathbf{v}^c | \boldsymbol{\theta}_q)$ 与 $F_r(\mathbf{v}^c | \boldsymbol{\theta}_r)$, 定义网格曲面 M_q 到网格曲面 M_r 的单向形状差异距离为

$$\text{Diff}(M_Q, M_T) = \sum_{v_i^c \in M_Q} F_T^2(v_i^c | \theta_T) \quad (2)$$

同时为了减少拟合带来的误差,定义两个曲面之间的双向形状差异距离为

$$\langle M_Q, M_T \rangle = \frac{1}{2} [\text{Diff}(M_Q, M_T) + \text{Diff}(M_T, M_Q)] \quad (3)$$

在曲面形状差异度量基础上,给定一类典型的局部曲面形状,其连续曲面表示函数为 $F_\mu(v^c | \theta_\mu)$,假设该类局部曲面形状在三维网格模型数据集中的分布服从高斯分布,其分布方差为 σ ,那么在给定三维网格模型中局部曲面 M_X 的形状属于该类典型局部曲面形状的概率为

$$P(M_X | \theta_\mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{\sum_{v_i^c \in M_X} F_\mu^2(v_i^c | \theta_\mu)}{2\sigma^2}\right) \quad (4)$$

2.2 三维网格卷积运算

二维图像处理领域中,常见的卷积运算时卷积模板移过图像并对区域内像素进行操作的处理,其中卷积模板由一个图像邻域窗口和对该窗口内的图像像素的预定义操作组成.2.1节中给出了三维网格模型上局部曲面窗口的定义,下面给出对窗口内模型顶点执行的操作定义,以此组成三维网格卷积运算.在简单曲面间的差异度量基础上,可以计算某一曲面形状与给定曲面形状的相似程度,对式(4)求对数可得

$$\ln P(M_X | \theta_\mu, \sigma) = C_1 + \sum_{v_i^c \in M_X} 1 \times C_2 F_\mu^2(v_i^c | \theta_\mu) \quad (5)$$

由上式看出,以顶点 v_n 为中心的局部曲面 M_{X_n} 的形状属于给定的典型形状类型的概率可以表示为卷积式

$$g(v_n) = f(v_i) * h(v_n - v_i) = \mathbf{W}\mathbf{X} + b \quad (6)$$

其中, \mathbf{X} 为特征向量 (x_1, x_2, \dots, x_k) , $x_i = f(v_i)$ 表示顶点 v_i 具有的属性,其基本属性就是以 $\{0, 1\}$ 表示顶点 v_i 是否在局部窗口中; \mathbf{W} 为权重向量 (w_1, w_2, \dots, w_k) , w_i 如下:

$$w_i = \frac{-1}{2\sigma^2} \times F_\mu^2(v_i^c | \theta_\mu) \quad (7)$$

$$b = -\ln \sqrt{2\pi\sigma^2} \quad (8)$$

其中 θ_μ 与 σ^2 为网格卷积模板的参数,表达典型形状的多项式函数 F_μ 可视网格卷积模板函数,因此可以根据卷积窗口内各顶点相对坐标 v_i^c 可以计算其相应的权重 w_i 从而对三维网格模型进行卷积运算计算.

假设在一个三维模型数据集中存在 N 种典型局部曲面形状,均用高阶多项式进行表示.给定模型内一顶点 v_n ,以其为中心的窗口曲面 S ,对其进行网格卷积运算,计算结果表示 S 与卷积模板对应的典型形状的差异

程度,其值越大越相似.因此可以根据卷积值将每个顶点标记为以其为中心的窗口曲面所属的典型形状类型.

$$\text{idx}_{v_n} = \text{argmax}_T (g_T(v_n)) \quad (9)$$

基于上述卷积运算,可以得到三维形变模型中典型局部曲面形状的分布作为目标的特征表示.具有 n 个顶点的三维模型样本,卷积窗口大小为 K ,取 N 个不同的卷积模板进行网格卷积运算,其中 $n \gg K$, N 取值范围在 20 到 70 之间.本文算法对该模型样本提取特征的时间消耗可以表示为 $T_{\text{neighbor}} + T_{\text{conv}}$, T_{neighbor} 为卷积窗口建立时间, T_{conv} 为网格卷积运算时间,整体时间复杂度为 $O(n \cdot (K + K_c) + n \cdot K \cdot N)$,其中 K_c 为卷积窗口内边的数目.

2.3 卷积模板函数参数学习

2.2节中定义了三维网格模型上的卷积运算,其中卷积模板由传统的离散表示变为连续函数 F 表示, θ 与 σ^2 为需要通过数据样本学习的卷积模板参数.

假设在三维模型数据集中存在 N 种典型局部曲面形状类型,对应 N 个卷积模板函数.本文采用谱聚类算法对数据样本进行无监督学习获得 N 类典型局部曲面形状.首先在数据样本集中选取每类三维模型的部分样本,以大小为 K 的窗口获取样本的局部曲面,构成局部曲面集合 S ;然后根据式(3)计算 S 中局部曲面之间的双向形状差异距离,构建相似矩阵,通过谱聚类得到聚类结果.

聚类结果的中心为同类曲面形状的“均值”,难以用具体曲面进行表示.因此本文方法采用高阶多项式 F^* 作为聚类中心 M^* 的形状表示.在前述聚类结果基础上,对每一个典型曲面形状类型 S_{C_n} ,其类中心为 M_n^* ,形状表示为 F_n^* ,以划分为 S_{C_n} 类的局部网格曲面作为拟合数据,采用最小二乘法求解参数 θ_n ,按式(10)计算参数 σ_n^2 .

$$\sigma_n^2 = \frac{1}{m_n - 1} \sum_i^{m_n} \text{Diff}(M_{X_i}, M_n^*) \quad M_{X_i} \in S_{C_n} \quad (10)$$

其中 m_n 表示聚类结果中归为形状类型 S_{C_n} 的曲面数量.

3 卷积特征空间相关性与目标分类

3.1 卷积特征空间相关性提取

上述网格卷积运算可以得到形变目标三维网格模型中典型局部曲面形状的分布,但该分布表示缺失了三维目标中局部曲面之间的关联信息.马尔科夫平稳特征^[13,14]作为对分布直方图特征的扩展,基于马尔科夫链模型能够有效获取低层特征在图像中的空间共现关系,形成中高层特征.因此本文方法采用同质化感知马尔科夫平稳特征(homogeneity-aware Markov Stationary Feature, hMSF)^[14]进一步补充形变目标中典型形状的空间相关性信息.

形状的空间共现矩阵 $\mathbf{C} = (c_{ij})_{N \times N}$ 是构建三维模型

对应马尔科夫链的基础. 矩阵 C 中元素 c_{ij} 表示相隔一定距离 D 的两个连通顶点 v_a, v_b 为中心的窗口曲面形状分别属于第 i 类和第 j 类典型曲面形状的共现频次, 如下:

$$c_{ij} = \text{sum} \{ \text{idx}_{v_a} = i, \text{idx}_{v_b} = j \mid \text{edges}(v_a, v_b) = D \} \quad (11)$$

其中 sum 为满足集合中条件的点对数量, $\text{edges}(v_a, v_b)$ 为令两个顶点连通的边的最小数量 D . 矩阵 C 是非负对称矩阵且可以从非刚性三维网格模型直接计算得到, 避免了模型刚体变换的影响. hMSF 由三维模型对应的马尔科夫链的初始状态分布 π 和平稳状态分布 τ 构成. 向量 π 和向量 τ 均为 N 维向量, 向量元素根据空间共现矩阵 C 分别由式(12)和式(13)计算得出.

$$\pi(n) = \frac{c_{nn}}{\sum_{k=1}^N c_{kk}} \quad (12)$$

$$\tau(n) = \frac{\sum_{l \neq n} c_{nl}}{\sum_{n=1}^N \sum_{l \neq n} c_{nl}} \quad (13)$$

向量 (π, τ) 表达了非刚性三维网格模型内同类典型局部曲面形状以及不同类型形状之间的空间信息. 最终将向量 (π, τ) 与前述典型局部形状分布结合起来作为非刚性三维网格模型的形状信息特征描述 h .

3.2 目标分类

本文采用支持向量机 (Support Vector Machine, SVM) 进行有监督学习, 实现对三维形变目标的分类. SVM 具有很高的分类准确率, 而且广泛应用于图像识别相关研究. 本算法中选取使用线性核函数的 SVM, 三维网格模型 M_i^s 的特征描述 h_i 作为分类器输入, 则对三维模型 M_i^s 分类的分类函数为 $\text{Score}(h_i) = t\phi(h_i) + s$, 其中 t 和 s 分别是由训练学习到的相关系数和偏置系数, $\phi(\cdot)$ 为线性核函数. 在训练过程中采用“one vs all”方法构造多分类器, 对 m 个类别的三维模型分类问题构造 m 个 SVM 分类器, 第 i 个 SVM 分类器使用第 i 类三维模型样本作为正例, 其他类别样本作为负例进行训练. 在对未知类别的三维模型样本 M_j^s 分类时, 其分类结果为 $\text{Score}(h_j)$ 值最大的一类.

4 实验及结果分析

为验证本文方法的有效性, 我们在标准三维形变网格模型数据集 SHREC10 和 SHREC15 上进行实验验证. 实验所用计算机配置为 Intel(R) Xeon(R) 处理器 64GB 内存, 分类器采用 scikit-learn 包中的 SVM.

4.1 SHREC10

SHREC10 数据集包括 10 个类别 200 个非刚性三维网格模型. 每类均有 20 个模型且同类模型均有刚体变换和非刚体变换. 另外该数据集中, 每个三维模型网格大小较为均匀. 训练分类器时在每类中随机取 14 个

三维模型作为训练样本, 其余作为测试样本. 网格卷积过程中取卷积窗口大小 $K = 256$, 在预处理过程中对窗口内曲面缩放, 令窗口内顶点相对坐标值大小范围为 $[-0.5, 0.5]$. 为了降低聚类过程的计算量, 实验中对每一类模型随机抽取一个模型样本并取 10% 数量的顶点选取邻域, 作为学习卷积模板参数的数据样本集. 实验中取聚类数 $N = 30$, 即 30 类典型的局部曲面形状, 取空间共现距离 $D = 20$. 对于窗口大小 K 、聚类数 N 和距离 D 的选取在 4.3 节中进行讨论分析.

通过多组实验, 将本文方法与 Shape-DNA^[7]、cShape-DNA^[15]、GPS-embedding^[8]、BoW^[12] 和 BoSCCs^[12] 方法进行比较, 如表 1 所示. 其中 GPS-embedding、Shape-DNA 方法中保留前 10 个特征值, cShape-DNA 方法中根据文献[15]取特征维度为 33, BoW 中取字典大小 $K_L = 100$, BoSCC 中低层字典大小取 $K_L = 100$, 高层字典大小取 $K_H = 70$. 从表中可以看出, 对形变目标的网格卷积特征提取方法能够有效提取形状特征并且相比其他方法有一定优势.

表 1 各算法在 SHREC10 上的平均准确率比较

算法	平均准确率/%	算法	平均准确率/%
本文方法	92.88	GPS-embedding ^[8]	87.17
Shape-DNA ^[7]	82.67	BoW ^[12]	65.94
cShape-DNA ^[15]	78.50	BoSCCs ^[12]	85.99

4.2 SHREC15

为进一步验证本文方法在更多类别的三维模型数据集上的效果, 使用 SHREC15 数据集进行实验. SHREC15 数据集包括 50 个类别 1200 个三维网格模型, 每类 24 个模型, 每类模型均有刚体变换和非刚体变换. 训练分类器时在每类中随机抽取 17 个三维模型作为训练样本, 其余作为测试样本. 由于该数据集网格密度比 SHREC10 稀疏, 取卷积窗口大小 $K = 152$, 聚类数 $N = 45$, 其余实验参数与 SHREC10 数据集实验一致.

将本文方法与 Shape-DNA^[7]、GPS-embedding^[8]、cShape-DNA^[15]、HKS^[10] 与 WKS^[11] 方法进行对比, 分类结果如表 2. 其中 Shape-DNA、GPS-embedding 方法中保留前 10 个特征值, cShape-DNA 方法中根据文献[15]取特征维度为 33. 表 2 结果表明网格卷积特征提取及分类方法明显优于其他方法, 表 3 结果表明在类别数目增大的情况下仍然具有很好的性能.

表 2 各算法在 SHREC15 上的平均准确率比较



算法	平均准确率/%	算法	平均准确率/%
本文方法	96.54	GPS-embedding ^[8]	75.13
Shape-DNA ^[7]	64.55	SVM + HKS ^[10]	56.90
cShape-DNA ^[15]	76.21	SVM + WKS ^[11]	87.50

表3 本文算法在 SHREC15 类别数量不同情况下的平均准确率


模型类别数	10	20	30	40	50
平均准确率/%	97.63	97.75	98.10	97.75	96.54

4.3 影响因素分析

非刚性三维模型上卷积窗口中局部曲面块包含三维模型的局部形状信息,影响模型形状特征提取;网格卷积模板作为模型数据集中典型形状表示,太少会减弱对目标的描述能力,反之会产生冗余的信息.因此需要考虑窗口大小 K 和网格卷积模板个数 N 的选取.如图2、图3所示,在不补充空间共现关系时,通过实验对比窗口大小 K 和卷积模板数 N 产生的影响.在 SHREC10 上取 $K = 256, N = 30$ 时达到最优准确率,在 SHREC15 上取 $K = 152, N = 45$ 时最佳.进一步分析发现,最佳局部曲面窗口大小 K 与三维网格模型的网格密度成正相关.

图2 SHREC10在不同窗口大小 K 及卷积模板数 N 下的平均准确率图3 SHREC15在不同窗口大小 K 及卷积模板数 N 下的平均准确率

对模型内顶点空间信息进行编码的 hMSF 受形状共现矩阵计算中顶点间距离 D 的影响.距离过小令两个局部曲面重叠过多,减弱对空间信息的描述能力;而距离过大时顶点间的空间关系变得十分复杂.实验结果表明空间共现关系有助于提高准确率且当距离 D 取

图4 不同共现距离 D 下的平均准确率

值为 20 时能够达到最优平均准确率,如图4所示.可以看出,当距离 D 过小时由于卷积窗口曲面有较大的重叠区,反而使最终的平均分类准确率降低.

5 总结

本文结合三维网格模型数据特点和图像卷积运算定义,提出一种三维形变网格模型卷积特征提取方法,获取三维模型局部几何形状信息并以此进行分类.通过对样本集中局部曲面形状进行无监督学习计算卷积模板参数.本文方法能够有效提取非刚性三维网格模型的特征,并且可根据模型网格密度灵活调整网格卷积窗口大小,对三维均匀网格模型具有普适性.与现有特征提取方法相比,本文方法在分类性能上有一定的优势.目前标准三维图像数据样本集数量较少,难以支持复杂的三维卷积神经网络的参数学习,因此结合网格卷积与神经网络进行特征提取是今后可以研究的方向.

参考文献

- [1] GU Jiu-xiang, WANG Zhen-hua, JASON K, et al. Recent advances in convolutional neural networks[J]. Pattern Recognition, 2018, 77: 354 - 377.
- [2] BRONSTEIN M M, BRUNA J, LECUN Y, et al. Geometric deep learning, going beyond Euclidean data[J]. IEEE Signal Processing Magazine, 2017, 34(4): 18 - 42.
- [3] WU Zhi-rong, SONG Shu-ran, KHOSLA A, et al. 3D shapeNets: A deep representation for volumetric shapes [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. NJ: IEEE, 2015. 1912 - 1920.
- [4] 李海生, 孙莉, 武玉娟, 等. 非刚性三维模型检索特征提取技术研究[J]. 软件学报, 2018, 29(2): 483 - 505.
LI Hai-sheng, SUN Li, WU Yu-juan, et al. Survey on feature extraction techniques for non-rigid 3D shape retrieval [J]. Journal of Software, 2018, 29(2): 483 - 505. (in Chinese)
- [5] MAHMOUDI M, SAPIRO G. Three-dimensional point cloud recognition via distributions of geometric distances [J]. Graphical Models, 2009, 71(1): 22 - 31.
- [6] SIPIRAN I, BUSTOS B. Harris 3D: a robust extension of the Harris operator for interest point detection on 3D meshes[J]. The Visual Computer, 2011, 27(11): 963 - 976.
- [7] REUTER M, WOLTER F E, PEINECKE N. Laplace-Beltrami spectra as 'Shape-DNA' of surfaces and solids[J]. Computer-Aided Design, 2006, 38(4): 342 - 366.
- [8] RUSTAMOV R M. Laplace-Beltrami eigenfunctions for deformation invariant shape representation [A]. Proceedings of the 5th Eurographics Symposium on Geometry Processing [C]. Switzerland: Eurographics Association, 2007. 225

- 233.
- [9] SUN J, OVSJANIKOV M, GUIBAS L J, et al. A concise and provably informative multi-scale signature based on heat diffusion[A]. Proceedings of the Symposium on Geometry Processing[C]. Switzerland: Eurographics Association, 2009. 1383 - 1392.
- [10] BRONSTEIN M M, KOKKINOS I. Scale-invariant heat kernel signatures for non-rigid shape recognition[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. NJ: IEEE, 2010. 1704 - 1711.
- [11] AUBRY M, SCHLICKWEI U, CREMERS D, et al. The wave kernel signature: A quantum mechanical approach to shape analysis [A]. IEEE International Conference on Computer Vision[C]. NJ: IEEE, 2011. 1626 - 1633.
- [12] HAN Zhi-zhong, LIU Zhen-bao, VONG Chi-man, et al. BoSCC: Bag of spatial context correlations for spatially enhanced 3D shape representation[J]. IEEE Trans on Image Processing, 2017, 26(8): 3707 - 3720.
- [13] LI Jian-guo, WU Wei-xin, WANG Tao, et al. One step beyond histograms: Image representation using Markov stationary features[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. NJ: IEEE, 2008. 1 - 8.
- [14] NI Bing-bing, YAN Shui-cheng, KASSIM A A, et al. Contextualizing histogram[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. NJ: IEEE, 2009. 1682 - 1689.
- [15] GAO Z, YU Z, PANG X. A compact shape descriptor for triangular surface meshes [J]. Computer-Aided Design, 2014, 53: 62 - 69.

作者简介



史聪伟 男, 1992 年出生, 浙江宁波人. 宁波大学信息科学与工程学院硕士研究生, 主要从事三维图形处理、模式识别相关研究.
E-mail: scw_vv@126.com



赵杰焯(通讯作者) 男, 1965 年出生, 浙江宁波人. 现为宁波大学信息科学与工程学院教授, 博士生导师. 主要从事计算智能、模式识别、人机自然交互等相关研究.
E-mail: zhao_jieyu@nbu.edu.cn



陈瑜 女, 1992 年出生, 河南安阳人. 现为宁波大学信息科学与工程学院博士研究生, 主要从事图形图像、深度学习等相关研究.
E-mail: chen_yu_eyey@126.com