

多特征融合的非刚性三维模型匹配算法研究

赖 龙^{1,2}, 李海生^{1,2}, 蔡 强^{1,2}, 毛典辉^{1,2}, 曹 健^{1,2}

(1. 北京工商大学 计算机与信息工程学院, 北京 100048;

2. 北京工商大学 食品安全大数据技术北京市重点实验室, 北京 100048)

摘要: 特征描述符是影响非刚性三维模型匹配结果的关键因素,而单一特征只能描述三维模型某一方面的信息.为了克服单一特征在模型匹配时的局限性,进一步提高模型匹配的精确度,通过引入信息论中信息熵的概念,结合各单一特征匹配时的结果,计算得到各特征的权值,对多种特征(如热核特征(HKS)、能量分布特征(WKS)和模型表面积特征等)进行融合,作为非刚性三维模型匹配的特征.最后在 SHREC'2014 提供的标准测试数据集上进行试验,并与单一特征描述符的结果进行对比,验证了多特征融合得到的特征描述符要优于任一单一特征描述符,可以应用于非刚性三维模型检索系统中.

关键词: 非刚性; 信息熵; 多特征

中图分类号: TP 391 **文献标志码:** A

Non-rigid 3D Models Matching with Multi-feature Fusion

LAI Long^{1,2}, LI Haisheng^{1,2}, CAI Qiang^{1,2}, MAO Dianhui^{1,2}, CAO Jian^{1,2}

(1. School of Computer and Information Engineering, Beijing Technology and Business University, Beijing 100048, China;

2. Beijing Key Laboratory of Big Data Technology for Food Safety, Beijing 100048, China)

Abstract: Feature descriptors are the key factors influencing the result of non-rigid 3D model correspondence. But a single feature descriptor only contains one aspect of information of a 3D model. In order to overcome the limitation of single feature and further improve the accuracy of model correspondence, the entropy was introduced to calculate the weight of each single feature according to its correspondence results. The features of HKS(heat kernel signature), WKS(wave kernel signature) and surface area were fused with these weights. The effectiveness of the approach was evaluated by using the SHREC'2014 non-rigid 3D human models benchmark. In addition, the results outperform those of any state-of-the-art single feature descriptor, and can be used for non-rigid 3D model retrieval.

Keywords: non-rigid; entropy; multi-feature

收稿日期: 2014-12-23

基金项目: 国家重点实验室开放基金资助项目(BUAA-VR-14KF-04);北京市自然科学基金资助项目(4162019);北京市重点实验室专项基金资助项目(19008001069);北京市教委科研计划一般项目(201610011010)

第一作者: 赖 龙(1988-),男,硕士研究生.研究方向:三维模型检索. E-mail: lailong@163.com

通信作者: 李海生(1974-),男,教授.研究方向:计算机图形学、科学可视化等. E-mail: lihsh@th. btbu. edu. cn

三维模型是指在计算机中存储的具有三维几何信息的模型数据,一般用网格或点云进行表示.随着各种三维建模软件的广泛使用,三维模型的数量呈指数级增长,获取三维模型的方式也越来越多.如何提高现有的三维模型的复用率,帮助设计者在海量的三维模型中找到需要的三维模型,是一项非常有挑战的任务.目前比较著名的三维模型检索系统有美国普林斯顿大学的形状检索与分析实验室研发的3D Model Search Engine,中国台湾大学实现的基于光场描述符的3D Model检索系统等.

三维模型主要分为刚性三维模型和非刚性三维模型.在理论上,若模型在发生形变时保持等距不变性、拉伸不变性、关节变形不变性、拓扑不变性等(如人手模型姿态的变化^[1]),该模型可被视为非刚性三维模型.常见的检索系统大多针对刚性三维模型,刚性三维模型的处理分析方法更多关注平移、旋转及缩放的不变性^[2-3],不适用于非刚性的模型.目前已经有一些学者提出了处理非刚性三维模型的方法,常见的有谱分解方法^[4-5]和基于几何特征的方法^[6]等.其中,热核特征(heat kernel signature, HKS)^[7]和能量分布特征(wave kernel signature, WKS)^[8]是谱分解方法中效果较好的特征.测地距离^[9-10]和模型表面积属于模型几何特征^[6],但是每种特征都存在一定的缺点,如HKS只能保留模型低频部分的信息,而导致模型高频部分信息的缺失.WKS和模型表面积特征侧重于模型宏观上的整体信息;同时,在谱分解方法中,当得到的特征值非常接近时,各特征值对应的特征向量会对最终的特征描述符造成一定的影响.

传统的单一特征描述符难以全面描述模型信息,Ortega等^[11]证明对多种单一特征,通过加权融合后再进行检索可以得到更好的结果.国内已有学者尝试使用多特征融合去提高三维模型检索的效率^[12],但是他们的算法中特征融合的权值是基于用户反馈的,算法流程相对复杂.本文提出的多特征融合的非刚性三维模型匹配算法,根据单一特征匹配的结果以及已知的分类信息分别计算每种算法的熵值,根据熵值得到该算法对应的权值.最后在单一特征匹配结果的基础上,得到最终的多特征融合的匹配结果.

1 非刚性三维模型特征提取方法

通过综合分析各种非刚性三维模型特征的特

点,本文将对HKS, WKS和模型表面积特征进行融合.

1.1 HKS特征提取

热核特征反映了热量在模型表面传递的过程,通过对不同时刻下,模型表面的热量分布状况来描述模型的表面及特征.热核具有等距等容不变性的特点,非常适合作为非刚性三维模型的特征描述符.对于一般的黎曼流形,构造其Laplace-Beltrami算子是求得模型热核的关键.在图形图像领域,通常用余切法去构造Laplace-Beltrami算子.本文将采用Belkin等^[13]提出的一种对余切法的改进方法去近似表示该算子,这种方法可以克服原始的余切法在一般情况下不收敛的缺点.

对于一个有 n 个顶点的模型,其Laplace-Beltrami算子可以近似地表示为 $L = A^{-1}W$.其中: A 是对角线上的元素分别为各个顶点的邻域三角面片面积的 $n \times n$ 对角矩阵; W 是基于余切定理的权值矩阵.对于有邻接关系的两个顶点 i 和 j ,它们之间的权值为 $w_{ij} = \frac{1}{2}(\cot \alpha + \cot \beta)$,如图1所示,点 a 和 b 之间的权值为 $\frac{1}{2}(\cot \alpha + \cot \beta)$,无邻接关系的顶点之间的权值设为0. W 的非对角线元素确定之后,确定 W 的对角线元素,对角线元素将被设置为 $w_{ii} = -\sum_{l=1, l \neq i}^n w_{il}$.最后对 L 进行特征分解求其特征值 λ_i 和相应的特征向量 ϕ_i .通常只保留最小的100~300个特征值及其对应的特征向量.




图1 x_i 和 x_j 之间的权值的确定

Fig.1 Determination of the weight between x_i and x_j

基于Laplace-Beltrami算子的特性,Sun等^[7]提出了HKS特征的定义.对于模型上的任一点 x 在 t 时刻的HKS被定义为

$$h_t(x, x) = \sum_{i=1}^n e^{-\lambda_i t} \phi_i^2(x) \quad (1)$$

在得到Laplace-Beltrami算子的特征值和特征向量之后,将这些值代入到热核公式(1)中,得到的 $h_t(x, x)$ 便是要求的各个顶点在一定时间序列

下的 HKS 特征.

1.2 WKS 特征提取

WKS 特征反映了模型上各顶点在被作为不同能量等级的量子粒子情况下的概率分布. 由于粒子的能量与其频率有关, WKS 可以被视为是在一定时间条件下, 模型上各点的频率信息. 模型表面各顶点关于时间的能量函数是 Schrödinger 方程的解, 如式 (2) 所示.

$$\frac{\partial u}{\partial t}(x, t) = i\Delta u(x, t) \quad (2)$$

与 HKS 特征提取类似, 根据模型的顶点信息使用改进的余切法构造其 Laplace - Beltrami 算子 L . 对 L 进行特征分解, 并只保留其最小的 100~300 个特征值及其对应的特征向量. 与 HKS 特征提取不同的是, 对于 $t=0$ 的时刻, 模型将被设置一个初始能量 E . 根据一定规则, 可以得到一个基于模型顶点能量的期望为 E 的概率分布. 假设 L 的特征值不重复, 能量函数可以表示为

$$\Psi_E(x, t) = \sum_{k=0}^n e^{iE_k t} \phi_k(x) f_E(E_k) \quad (3)$$

WKS 作为平均的概率值, 被定义为

$$WKS(E, x) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T |\Psi_E(x, t)|^2 \quad (4)$$

由于 $e^{iE_k t}$ 是正交的, WKS 可以进一步改写为

$$WKS(E, x) = \sum_{k=0}^{\infty} \phi_k(x)^2 f_E(E_k)^2 \quad (5)$$

从式 (5) 中可以看到, 与 HKS 相比, 这里不再有时间参数, 而有一个与初始能量 E 有关的函数, 初始能量 E 又与 L 的特征值有关, 这样便避免了人为设置的时间 t 对模型特征的影响.

根据上面对于 WKS 的理论分析, 在实际的实验中, 模型上各点的 WKS 值被定义为

$$WKS(x, \zeta) = C_{\zeta} \sum_k \phi_k(x)^2 e^{\frac{-(\zeta - \log E_k)^2}{2\sigma^2}} \quad (6)$$

式中: $\phi_k(x)$ 为 L 的特征向量; E 为模型的初始能量, 在这里是 k 维向量, 设 $E_{\min}$ 和 $E_{\max}$ 分别是向量 E 的最小值和最大值; ζ 为区间 $[E_{\min}, E_{\max}/\mu]$ 等分成 N 个间隔之后的 N 维向量; μ 为预设的近似为 1 的参数; $C_{\zeta} = \left(\sum_k e^{\frac{-(\zeta - \log E_k)^2}{2\sigma^2}} \right)^{-1}$; $E_k = E_{\max}$; $\sigma = (\zeta_2 - \zeta_1)\tau$, τ 为人为预设的非负的参数.

$WKS(x, \zeta)$ 便是该模型的各点对应的 WKS 特征.

1.3 模型表面积特征提取

在各种基于几何特征的方法中, 基于模型表面

积的特征提取是简单高效的特征提取算法之一. 模型表面积特征就是直接计算模型的表面积作为该模型的特征. 这种方法虽然对模型的尺度敏感, 且会忽略模型的局部细节, 但便于计算, 对于存在非刚性形变的三维模型有很好的效果. Pickup 等^[6]的实验结果表明, 这种算法的效果在一定程度上比某些复杂的算法 (如 HKS 特征提取) 更优秀.

2 非刚性三维模型多特征融合匹配算法实现

2.1 基于信息熵的多特征权值分配

为了弥补单一特征在描述三维模型时的局限性, 本文引入了多特征融合的方法. 通过多个特征进行融合可以更加全面地描述模型, 根据所处理的模型库的特点, 实现各个特征之间的取长补短, 使各特征的优势最大化.

由于各种特征描述符对模型的描述能力不同, 在进行特征融合时, 特征的权值是关键参数. 最简单的处理方式是给各种特征赋相同的权值, 但这种权值设定下进行的实验结果很不理想. 为了优化权值分配, 本文将信息论中信息熵的思想引入进来, 通过计算每种特征的信息熵去进一步确定该特征对应的权值.

对于有 n 个模型的数据集 D , 将 f_1, f_2 和 f_3 这 3 种算法进行融合, 其权值分配方法如下:

a. 从 D 中随机选择 m 个模型作为训练集, 记为 B , B 中模型已分类; 余下 $n-m$ 个模型作为测试集, 记为 T , T 中模型未分类. 随机选取一个模型 $q (q \in T)$, 计算其与 B 中各模型基于不同特征的相似度, 并按照相似度大小从高到低排序 (越靠前, 表明与 q 越相似), 取前 k 个结果构成集合, 记为 $R_{qk}^i (i=1, 2, 3)$.

b. 对 R_{qk}^i 中模型进行分类, 各类中模型数量记为 R_{qkj}^i , 其中 j 为分类的类标. 计算每个类别的概率分布, N 为类别数目, 即

$$P(R_{qk}^i) = \{p_1, p_2, \dots, p_j, \dots, p_N\} \quad (7)$$

$$p_j = \frac{R_{qkj}^i}{R_{qk}^i} \quad (8)$$

c. 根据信息熵的定义, 特征 f_i 对应的信息熵可表示为

$$I(R_{qk}^i) = - \sum_{j=1}^N p_j \log_2 p_j \quad (9)$$

进而, 计算出各特征的权值为

$$F_i = \frac{1 - I(R_{qk}^i)}{n - \sum I(R_{qk}^i)}, i = 1, 2, 3 \quad (10)$$

F_1, F_2 和 F_3 分别是 f_1, f_2 和 f_3 的权值.

2.2 多特征融合匹配算法实现流程

在得到各特征对应的权值之后,可以对 f_1, f_2 和 f_3 这 3 种算法进行融合,提高匹配的精确度,其流程如下:

a. 提取 D 数据集中各个模型的 f_1 特征、 f_2 特征和 f_3 特征. 根据 f_1, f_2 和 f_3 的特点,分别计算 D 数据集内各模型之间特征的欧氏距离作为相似度(数值越大表示模型越不相似),并构建相似度矩阵,记为 $\{M_b^1, M_b^2, M_b^3\}$. M_b^1, M_b^2 和 M_b^3 都是 $n \times n$ 的矩阵,其中 (i, j) 位置的元素对应的是第 i 个模型和第 j 个模型之间的相似度.

b. 模型间相似度进行归一化. 设当前处理模型为 l , 根据 $\{M_b^1, M_b^2, M_b^3\}$ 构成模型 l 与其余模型的相似度集合 $\{s_{l1}^i, s_{l2}^i, \dots, s_{ln}^i\}$ (i 表示对应的特征为 f_i). 归一化集合 $\{s_{l1}^i, s_{l2}^i, \dots, s_{ln}^i\}$ 中各元素的计算公式为

$$s_{lj}^{i'} = \frac{s_{lj}^i}{s_{\max}}, j = 1, 2, \dots, n \quad (11)$$

其中, $s_{\max}$ 表示模型库中各模型与模型 l 相似度的最大值, 经过归一化的新集合可以表示为 $\{s_{l1}^{i'}, s_{l2}^{i'}, \dots, s_{ln}^{i'}\}$.

c. 模型 l 与其余模型在不同特征条件下计算的相似度进行融合, 如计算模型 l 与模型 j 在多特征融合后的相似度为

$$Sim = \sum_{i=1}^3 s_{lj}^{i'} F_i \quad (12)$$

Sim 是最终的相似度. 通过该相似度, 可以组成相似度矩阵, 其中记录了所处理的数据集中任两个模型之间的相似度, 对该矩阵中内容进行评估可以量化当前匹配算法的优劣.

3 实验

3.1 实验数据集

三维模型检索竞赛 (3D SHape REtrieval Contest, 简称 SHREC)^[14] 是 Eurographics 举办的每年一届的三维模型检索大赛, 几乎每届 SHREC 竞赛都会提出新的非刚性三维模型的数据集, 本文采用 SHREC'2014 提供的非刚性三维模型数据集^[6]进行试验. SHREC'2014 非刚性三维模型的数据集共有两个子集, Real 数据集和 Synthetic 数据集.

Real 数据集中的模型是直接扫描真实的人体构建的, 该数据集共包含 400 个姿态各异的模型. 其中, 每个模型的顶点数范围为 14 996~15 000, 面片数范围为 29 968~29 996. Synthetic 数据集中的模型则是用三维模型建模软件生成的, 该数据集的模型数量为 300 个, 其中每个模型的顶点数范围为 60 086~60 277, 面片数范围为 120 080~120 451. 图 2 是 SHREC'2014 提供的 2 个非刚性数据集示例.




图 2 SHREC'2014 非刚性三维模型数据集示例

Fig.2 Example of the SHREC'2014 non-rigid 3D model dataset

3.2 性能评估标准

评估标准为国际上通用的由普林斯顿大学提出的评估标准^[15], 该标准主要评估基于某种特征的相似度矩阵, 包括最近邻方法 (nearest neighbor, 简称 NN)、第一层级 (first-tier, 简称 1-T) 和第二层级 (second-tier, 简称 2-T)、E-度量 (E-Measure, 简称 2-M)、折扣的累积结果 (discounted cumulative gain, 简称 DCG).

a. 最近邻方法: 表示与待查询模型同属于一类的模型所占返回的检索结果的比例, 比例越低, 则说明检索出的相似结果越少.

b. 第一层级和第二层级: 对于返回结果保存最相似的前 K 个模型 (K 的大小与待查询模型所在类的规模有关), 第一层级和第二层级表示出现在前 K 个模型中, 与输入模型属于同一类的模型所占的比例, 该比例越低, 说明检索出的相似结果越少. 对于待查询模型的类别, 可定义该类别包含模型数 G , 则对于第一层级来说, $K = G$, 对于第二层级, $K = 2G$.

c. E-度量: 是一种改进的 Precision-Recall 评价标准. 对于检索结果, 用户更感兴趣的应该是前面页面的检索结果而不是后面页面的检索结果, 因此 E-Measure 只考虑前 32 个检索结果并计算 Precision-Recall. 其最大值为 1.0, 数值越大则检索结果越好.

d. 折扣的累积结果: 加权的正确结果的列表, 其中越靠前权重越大.

3.3 实验流程

本文实验是在内存为 2 GB, CPU 为 Intel 2.6 GHz 双核的 PC 机和 Windows 8 环境下完成的。

本文融合的特征有 HKS, WKS 和模型表面积特征. 通过使用相应的特征提取算法提取 Real 数据集和 Synthetic 数据集中所有模型的特征, 并计算 2 个数据集基于不同特征得到的模型间相似度矩阵 $\{M_{RL}^H, M_{RL}^W, M_{RL}^A\}$ 和 $\{M_{ST}^H, M_{ST}^W, M_{ST}^A\}$, RL 表示 Real 数据集, ST 表示 Synthetic 数据集, H, W 和 A 分别表示 HKS, WKS 和模型表面积特征。

每个数据集中随机取总模型数的 1/10 个模型 (Real 数据集选取 40 个模型, Synthetic 数据集选取 30 个模型) 作为已分类的训练集. 依照上文介绍的试验方法, 计算每种特征的权值, 再对相似度矩阵 $\{M_{RL}^H, M_{RL}^W, M_{RL}^A\}$ 和 $\{M_{ST}^H, M_{ST}^W, M_{ST}^A\}$ 分别进行归一化之后, 结合式(12)得到最终的 2 个数据集的相似度矩阵 M_{RL}^{mix} 和 M_{ST}^{mix} 。

3.4 实验结果及分析

本文使用普林斯顿大学提出的评估标准对多特征融合的结果 M_{RL}^{mix} 和 M_{ST}^{mix} 进行评估. 为了进行对比, 同时对 HKS, WKS 和模型表面积特征这 3 种特征的效果进行了评估。

实验对比结果如表 1 和表 2 所示。

表 1 Real 数据集实验结果性能评估

Tab.1 Evaluation of the Real dataset's correspondence

项目	NN	1-T	2-T	2-M	DCG
多特征	0.522 5	0.481 9	0.697 2	0.382 8	0.715 2
热核特征	0.245 0	0.259 2	0.460 8	0.313 5	0.547 9
能量分布特征	0.327 5	0.321 7	0.558 6	0.346 6	0.604 9
模型表面积特征	0.287 5	0.298 1	0.491 4	0.299 8	0.562 5

表 2 Synthetic 数据集实验结果性能评估

Tab.2 Evaluation of the Synthetic dataset's correspondence

项目	NN	1-T	2-T	2-M	DCG
多特征	0.866 7	0.712 8	0.981 2	0.683 0	0.903 4
热核特征	0.466 7	0.475 6	0.743 3	0.503 9	0.729 1
能量分布特征	0.810 0	0.726 0	0.938 9	0.666 5	0.885 9
模型表面积特征	0.720 0	0.681 6	0.973 0	0.670 3	0.562 5

同时, 本文也将几种单一特征描述符与多特征描述符的结果进行了可视化对比, 如图 3 所示. 纵坐标表示各特征描述符采用 5 种不同的评估标准进行评估时所对应的结果, 最大值为 1。

从图 3 中的直方图可以明显看到, 无论是针对 Real 数据集还是 Synthetic 数据集, 在单一特征条件下, 使用 WKS 特征和 Surface 特征的评估得分更高. 而多特征融合的表现要明显优于单特征, 在对 Real 数据集进行处理时, 多特征融合比效果最好的单一特征(WKS)提高了 10%. 对于在单特征条件下评分已经很高的 Synthetic 数据集, 多特征融合的评价依然高于任一单特征。




图 3 算法评估结果对比图

Fig.3 Evaluation results comparison between algorithms

为了直观地观察多特征融合之后的效果, 本文分别随机选取了 Real 数据集和 Synthetic 数据集中的 1 个模型作为输入, 计算它们与相应数据集中的其余模型之间的相似度, 对最相似的 10 个模型进行可视化输出, 位置越靠左表示相似程度越高, 结果如图 4 所示 (见下页). 模型①为 Real 数据集中的模型, 模型②为 Synthetic 数据集中的模型, 虚线框标示的是错误的检索结果. 从图 4 中的两组结果可以看到, 本文实验中所实现的 4 种方法, 使用了多特征融合的检索效果最好。




图4 输入模型查询示例

Fig.4 Retrieval example of input models

4 结论与展望

HKS, WKS等谱分解方法提取的特征是当前针对非刚性三维模型的一类优秀的特征.但是单一特征有一定的局限性,恰当地融合不同的形状特征可使它们优势互补,更好地描述非刚性三维模型.本文提出了一种多特征融合的非刚性三维模型匹配算法,先计算待融合特征的信息熵,将该信息熵转化成权值,对单一特征下的模型间相似度进行加权融合,得到的相似度作为新的模型间相似度.通过使用普林斯顿大学的评估标准进行评估以及进行了模拟三维模型检索的可视化展示可以看到,使用多特征融合可以在一定程度上提高模型匹配的效果.

在以后工作中,将继续探索新的非刚性三维模型的特征描述符,并尝试将本文中算法引入到实际的应用中.

参考文献:

- [1] 刘敏娟,崔建昆.手指可达工作空间的三维建模[J].上海理工大学学报,2006,28(1):95-98.
- [2] Li B, Lu Y J, Godil A, et al. A comparison of methods

for sketch-based 3D shape retrieval[J]. Computer Vision and Image Understanding, 2014, 119: 57-80.

- [3] Yang Y B, Lin H, Zhang Y. Content-based 3D model retrieval; a survey[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, 2007, 37(6): 1081-1098.
- [4] Li C Y, Hamza A B. Spatially aggregating spectral descriptors for nonrigid 3D shape retrieval; a comparative survey[J]. Multimedia Systems, 2014, 20(3): 253-281.
- [5] Litman R, Bronstein A M. Learning spectral descriptors for deformable shape correspondence[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(1): 171-180.
- [6] Pickup D, Sun X F, Rosin P L, et al. SHREC'14 track: shape retrieval of non-rigid 3D human models[C]// Eurographics Workshop on 3D Object Retrieval. Strasbourg: The Eurographics Association, 2014: 101-110.
- [7] 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.
- [8] Aubry M, Schlickewei U, Cremers D. The wave kernel signature: a quantum mechanical approach to shape analysis [C]// Proceedings of IEEE International Conference on Computer Vision Workshops (ICCV Workshops). Barcelona: IEEE, 2011: 1626-1633.
- [9] Xin S Q, Wang G J. Improving Chen and Han's algorithm on the discrete geodesic problem[J]. ACM Transactions on Graphics (TOG), 2009, 28(4): 104.
- [10] Raviv D, Bronstein A M, Bronstein M M, et al. Affine-invariant geodesic geometry of deformable 3D shapes [J]. Computers & Graphics, 2011, 35(3): 692-697.
- [11] Ortega M, Rui Y, Chakrabarti K, et al. Supporting similarity queries in MARS[C]// Proceedings of the Fifth ACM International Conference on Multimedia. New York: ACM, 1997: 403-413.
- [12] 杨萌. 基于多特征和相关反馈的三维模型检索系统研究与实现[D]. 西安: 西北大学, 2009.
- [13] Belkin M, Sun J, Wang Y S. Discrete Laplace operator on meshed surfaces[C]// Proceedings of the Twenty-Fourth Annual Symposium on Computational Geometry. New York: ACM, 2008: 278-287.
- [14] Vandeborre J P, Tabia H. The seventh Eurographics workshop on 3D object retrieval[DB/OL]. [2014-04-06]. <http://3dor2014.ensea.fr/People.html>.
- [15] Shilane P, Min P, Kazhdan M, et al. The Princeton shape benchmark [C]// Proceedings of Shape Modeling Applications. New York: IEEE, 2004: 167-178.

(编辑: 丁红艺)