

文章编号: 2095-2163(2023)09-0134-07

中图分类号: TP 391.41

文献标志码: A

# 结合 Nyström 方法的三维网格模型分割方法

朱天晓

(上海工程技术大学 电子电气工程学院, 上海 201620)

**摘要:** 针对谱聚类三维网格模型分割方法耗时长、占用内存大的问题, 本文提出了一种结合 Nyström 方法的三维网格模型分割方法。首先, 对模型面心进行采样, 计算采样点和所有面心的亲和力数值, 使用 Nyström 方法估计亲和力矩阵的主特征向量, 避免了计算亲和力矩阵的巨大开销; 其次, 使用 K-Means 算法对主特征向量聚类, 实现对模型的分割; 最后, 使用自适应邻域滤波算法对分割结果进行优化, 去除估计误差。在细分后的普林斯顿数据集上进行实验, 并同 5 种分割方法进行定量比较, 结果表明本文方法可以有效降低谱聚类方法的时间、空间开销, 并且兰德分数比其余方法平均高 0.21, 可以得到更高精度的分割结果。

**关键词:** 网格模型分割; Nyström 方法; 谱聚类; 自适应邻域滤波

## 3D mesh segmentation method combined with Nyström method

ZHU Tianxiao

(School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

**[Abstract]** Aiming at the massive time and space overhead of the spectral clustering mesh segmentation method, a mesh segmentation method combined with the Nyström method is proposed. Firstly, sample the model face centers, then calculate the affinity values between the sampled points and all face centers. Using the Nyström method to estimate the principal eigenvectors of the affinity matrix avoids the massive overhead of computing the affinity matrix. Secondly, use the K-Means algorithm to cluster the principal eigenvectors, implementing the segmentation of the model. Finally, the segmentation results are optimized using the adaptive neighborhood filtering algorithm to remove the estimation errors. Experiments on the subdivided Princeton dataset are conducted, and five general segmentation methods are compared. The results show that the proposed method can effectively reduce the time and space overhead of the spectral clustering method. The Rand score is 0.21 higher than the other methods on average, which shows that the proposed method can get more meaningful segmentation results.

**[Key words]** mesh model segmentation; nyström method; spectral clustering; adaptive neighborhood filtering

## 0 引言

随着计算机视觉、三维扫描等技术的发展, 三维网格模型被广泛应用于虚拟现实、影视动画等领域。三维网格模型分割是计算机图形学的重要研究点, 也是互联网上模型检索、模型生成等技术的基础。三维模型精度越来越高, 数据量不断增长, 大大增加了分割难度。

三维网格模型分割(简称网格分割)是根据一定分割规则, 将连通的网格模型分解为一组数目有限的面片集的过程。网格分割按照不同的标准有不同的分类。按照分割结果的不同, Rodrigues 等<sup>[1]</sup>将网格分割方法分为面片分割和部件分割, 前者将网格分割成若干几何属性一致的面片集, 后者将网格

分割为符合人类视觉划分效果的若干部件。按照分割方式的不同, 龚思洁等<sup>[2]</sup>将现今主流的分割方法分为 3 类: 第一类是根据模型几何特征将模型表面具有相关性的面片合并为一类, 如聚类分析法; 第二类是基于最小值原则, 在模型表面构建分割线, 将模型拆分为多个部分; 第三类是深度学习方法, 通过构建深度学习网络, 进行有监督学习。深度学习方法通常对机器性能有很高的要求, 此外获取优质数据集也是一个难题, 因此很多研究集中在前两种方法上, 计算量相对较小。龚思洁等<sup>[2]</sup>提出能量和区分度两种模型特征用于寻找分割点, 并使用腐蚀算法、最小能量原则构造分割线, 得到了精度较高的分割结果, 但算法耗时较长; 赵云成等<sup>[3]</sup>提出了结合曲率约束的网格模型快速分割方法, 根据高斯曲率和

作者简介: 朱天晓(1998-), 男, 硕士研究生, 主要研究方向: 计算机图形学。

收稿日期: 2022-09-27

哈尔滨工业大学主办 ◆ 专题设计与应用

平均曲率筛选出模型的凹区域,依据最小负曲率阈值原则构造出闭合分割线,实现对网格模型的分割;这两种方法都属于基于最小值原则、构建分割线的分割方法。对于基于聚类分析的网格分割方法,梁楚萍等<sup>[4]</sup>根据聚类过程中簇划分方式的区别,将其划分为 5 类:区域生长算法、多源区域生长算法、层次聚类算法、迭代聚类算法和谱聚类算法,前 4 种算法都以网格属性直接作为分类依据,而谱聚类算法核心在于对网格模型生成的亲和力矩阵的划分,该算法可以得到较高准确率。

Liu 等<sup>[5]</sup>将谱聚类引入到网格分割问题中,使用基于测地线距离和余弦距离构造的核函数计算亲和力矩阵,可以有效利用模型的几何特征进行分割,但是构建亲和力矩阵耗时较长;Jiao 等<sup>[6]</sup>在谱聚类算法框架下,使用网格显著指数和网格离散曲率构建亲和力矩阵并完成网格分割,没有解决构建亲和力矩阵时间、空间开销大的问题;万燕<sup>[7]</sup>等使用谱聚类算法将模型过分割为弱凸区域,对弱凸区域按照可见度进行排序,根据相互可见性和形状直径函数进行区域合并,最终得到分割结果,但没有解决谱聚类算法耗时长、内存消耗大的问题;Tong 等<sup>[8]</sup>对亲和力矩阵计算费德勒(Fiedler)向量,通过分析费德勒向量,将网格分割问题转化为梯度极小化问题;Li 等<sup>[9]</sup>通过分析费德勒向量、计算费德勒残差,对模型进行递归分割。仅使用费德勒向量降低了后续的计算成本,但是构建亲和力矩阵的时间、空间开销没有降低。

针对谱聚类构建亲和力矩阵耗时长、内存消耗大、难以分割面片数较多的模型的问题,本文提出了一种结合 Nyström 方法的三维网格模型分割方法,能够避免构建亲和力矩阵的巨大内存开销,有效降低谱聚类算法进行网格分割所需的时间,可以获得符合人类视觉划分效果的分割结果。

## 1 相关技术背景

### 1.1 Nyström 方法

Nyström 方法是一种用于大规模数据聚类的有效方法,其最初目的是为了求解积分方程。Williams 等<sup>[10]</sup>将其引入核方法,用于加速矩阵特征分解,而准确率并没有明显下降。近年来随着研究的深入,Nyström 方法也被用于图片分割、点云分割。

Nyström 方法适用于对称矩阵,其基本思想是通过采样获得少量样本点,使用样本点与非样本点之间的相似性来估计目标矩阵或其特征向量,采样方法有随机采样、基于 K-Means 算法采样、基于最远

策略采样等。

### 1.2 谱聚类算法

谱聚类是一种基于谱图理论的聚类算法,能在任意簇形的样本空间上达到良好的聚类效果。该算法核心在于构建亲和力矩阵,其形式类似于图邻接矩阵。

Ng 等<sup>[11]</sup>提出了一种二维数据谱聚类算法,使用径向基函数核(Radial Basis Function kernel, RBF kernel)计算二维数据中每两点的欧氏距离,用于构建亲和力矩阵,并对亲和力矩阵的特征向量进行 K-Means 聚类,实现对原始数据的聚类;Liu 等<sup>[5]</sup>在其工作基础上提出了一种谱聚类三维网格模型分割算法,将测地线距离和余弦距离引入 RBF 核函数来构造亲和力矩阵,该算法在网格分割方面得到了较高的准确率。

## 2 本文算法流程

传统的谱聚类算法使用核函数构建亲和力矩阵,时间、空间复杂度一般为  $O(n^2)$ 。对于面片数较多的模型,往往难以使用谱聚类算法对模型进行分割。

本文将 Nyström 方法与谱聚类算法结合,提出了一种有效降低构建亲和力矩阵时间、空间开销的网格模型分割方法。首先,使用 K-Means++ 算法对模型面心进行聚类,将距离聚类中心最近的面心作为采样点;其次,使用基于测地线距离和余弦距离的核函数计算采样点和所有面心的亲和力数值,并使用 Nyström 方法估计亲和力矩阵的主特征向量;将主特征向量拼接为矩阵,对矩阵每行元素使用 K-Means 算法聚类,实现对模型的分割;最后,使用自适应邻域滤波算法对分割结果进行处理,得到优化后的模型分割结果。本文方法流程如图 1 所示。

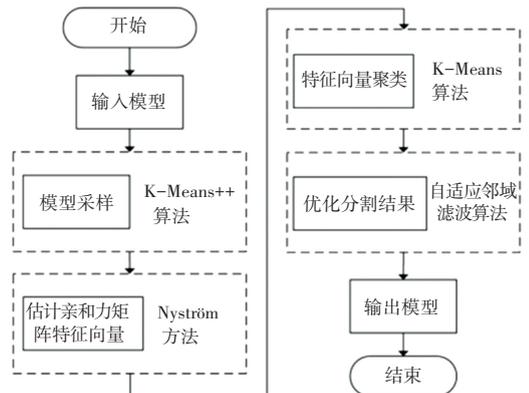


图 1 本文方法流程图

Fig. 1 Flow chart of the proposed method

## 2.1 特征向量估计

使用谱聚类算法分割模型时,若模型的面片数为 $N$ ,则需要计算大小为 $N \times N$ 的亲合力矩阵,计算量较大、耗时较长。因此,可以使用Nyström方法对矩阵或其特征向量进行估计近似,提升谱聚类算法运行速度。

Oglic等<sup>[12]</sup>证明了K-Means++算法作为Nyström方法中的采样方法具有可行性,并且误差较小。K-Means++算法是K-Means算法的改进,其初始聚类中心点的选择是基于最远策略的,即选择相互间距离尽可能远的初始聚类中心点。本文将聚类数目设置为采样点数,对模型面片的面心进行K-Means++聚类,并选择距离聚类中心点最近的面心作为采样点。

设模型的面片数为 $N$ ,从中使用K-Means++采样获得 $m$ 个面心作为样本点( $m \ll N$ ),则非样本点数目为 $n = N - m$ 。

亲合力矩阵 $W$ 可以表示为式(1):

$$W = \begin{bmatrix} A & B \\ B^T & C \end{bmatrix} \quad (1)$$

其中, $A \in \mathbb{R}^{m \times m}$ , $B \in \mathbb{R}^{n \times m}$ , $C \in \mathbb{R}^{n \times n}$ ,矩阵 $A$ 表示采样的 $m$ 个样本点之间的亲合力矩阵;矩阵 $B$ 表示采样的 $m$ 个样本点和剩余 $n$ 个非样本点之间的亲合力矩阵;因为 $m \ll N$ ,所以矩阵 $C$ 的大小几乎和矩阵 $W$ 相同。

本文使用Nyström方法对矩阵 $W$ 的主特征向量进行估计,方法流程如图2所示。

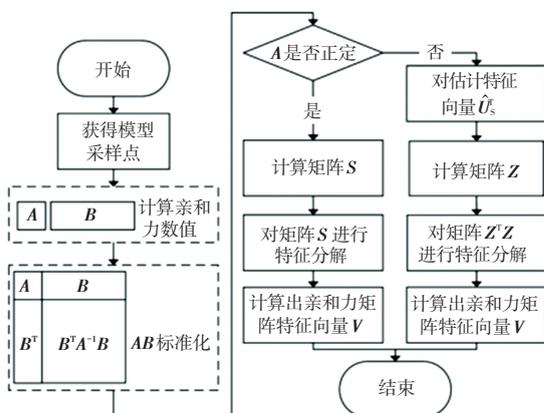


图2 Nyström方法流程图

Fig. 2 Flow chart of the Nyström method

首先,将矩阵 $A$ 特征分解,即 $A = U\Lambda U^T$ ;  $A$ 为对角矩阵,其中非零元素为矩阵 $A$ 的特征值。亲合力矩阵 $W$ 的近似特征向量为式(2):

$$\hat{U} = \begin{bmatrix} U \\ B^T U \Lambda^{-1} \end{bmatrix} \quad (2)$$

由式(1)、式(2)有亲合力矩阵 $W$ 可近似为式(3):

$$\hat{W} = \hat{U}\Lambda\hat{U}^T = \begin{bmatrix} U\Lambda U^T & B \\ B^T & B^T \Lambda^{-1} B \end{bmatrix} = \begin{bmatrix} A & B \\ B^T & B^T \Lambda^{-1} B \end{bmatrix} \quad (3)$$

由式(3)可知,矩阵 $C$ 的近似值为 $B^T \Lambda^{-1} B$ 。

其次,对 $A$ 、 $B$ 进行标准化。因为在谱聚类算法中,使用标准化的亲合力矩阵。对估计矩阵 $\hat{W}$ 求行和,式(4):

$$\hat{d} = \hat{W}1 = \begin{bmatrix} A 1_m + B 1_n \\ B^T 1_n + B^T \Lambda^{-1} B 1_m \end{bmatrix} = \begin{bmatrix} a_r + b_r \\ b_c + B^T \Lambda^{-1} b_r \end{bmatrix} \quad (4)$$

其中, $a_r, b_r \in \mathbb{R}^{m \times 1}$ ,分别表示矩阵 $A$ 、 $B$ 的行和; $b_c \in \mathbb{R}^{n \times 1}$ 表示矩阵 $B$ 的列和;1表示元素均为1的列向量。

$\hat{d} \in \mathbb{R}^{N \times 1}$ 使用式(4)对矩阵 $A$ 和 $B$ 进行归一化,式(5)和式(6):

$$A_{ij} = \frac{A_{ij}}{\sqrt{\hat{d}_i \hat{d}_j}}, \quad i, j = 1, \dots, n \quad (5)$$

$$B_{ij} = \frac{B_{ij}}{\sqrt{\hat{d}_i \hat{d}_j}}, \quad i = 1, \dots, n, j = 1, \dots, m \quad (6)$$

最后,求解矩阵 $\hat{W}$ 的主特征向量。

若矩阵 $A$ 正定,令 $A^{1/2}$ 表示 $A$ 的正定平方根。定义 $S = A + A^{-1/2} B B^T A^{-1/2}$ ,并将其特征分解为 $S = U_s \Lambda_s U_s^T$ 。可一步估算出矩阵 $\hat{W}$ 的正交主特征向量式(7):

$$V = \begin{bmatrix} A \\ B^T \end{bmatrix} A^{-1/2} U_s \Lambda_s^{-1/2} \quad (7)$$

若矩阵 $A$ 非正定,矩阵 $\hat{W}$ 的估计特征向量为 $\hat{U}_s^T = [U^T \quad A^{-1} U^T B]$ 。定义 $Z = \hat{U}_s A^{-1/2}$ ,有 $\hat{W} = Z Z^T$ ,对 $Z^T Z$ 特征分解,有 $Z^T Z = F \Sigma F^T$ 。最后估算出矩阵 $\hat{W}$ 的正交主特征向量,式(8):

$$V = Z F \Sigma^{-1/2} \quad (8)$$

Nyström方法中数据量最大的是式(3)的亲

力矩阵  $\hat{W} \in \mathbb{R}^{N \times N}$ , 但是不必真正计算该矩阵, 谱聚类算法需要的是亲和力矩阵的主特征向量。因为  $\hat{W}$  是由矩阵  $A$ 、 $B$  计算拼接出的, 而在式(4)进行标准化时, 可以直接使用矩阵  $A$ 、 $B$  标准化, 而无需计算  $\hat{W}$ 。

可见, 最大的矩阵为  $V \in \mathbb{R}^{N \times m}$ , 相比与传统谱聚类算法需要计算  $W \in \mathbb{R}^{N \times N}$ , 本文使用 Nyström 方法对亲和力矩阵主特征向量进行估计近似, 大大降低了时间、空间开销。

## 2.2 网格模型分割

本文计算面片  $i$  到相邻面片  $j$  的测地线距离, 式(9):

$$dist^G(i, j) = l_i + l_j \quad (9)$$

其中,  $l_i$ 、 $l_j$  分别为面片  $i$ 、 $j$  的交线中点  $p_i$  到对应面片质心  $p_i$ 、 $p_j$  的欧式距离。

本文定义面片  $i$  到相邻面片  $j$  的余弦距离为式(10):

$$dist^C(i, j) = 1 - \cos(\mathbf{n}_i, \mathbf{n}_j) \quad (10)$$

其中,  $\mathbf{n}_i$  为面片  $i$  的法向量,  $\mathbf{n}_j$  为面片  $j$  的法向量。

使用式(9)、式(10)构造的加权距离公式为式(11):

$$dist(i, j) = \frac{n \cdot \delta \cdot dist^G(i, j)}{\sum_{i, j \in [1, n]} dist^G} + \frac{n \cdot (1 - \delta) \cdot \eta \cdot dist^C(i, j)}{\sum_{i, j \in [1, n]} dist^C} \quad (11)$$

其中,  $n$  为面片数;  $\delta$  为衡量测地线距离与余弦距离重要性的参数;  $\eta$  为调整余弦距离的参数。

本文设置  $\delta = 0.03$ ,  $\eta = 0.15$ 。

使用式(11)构造的亲和力数值计算式(12):

$$W(i, j) = e^{-\frac{dist(i, j)}{2\sigma^2}} \quad (12)$$

其中,  $\sigma = \frac{\sum_{i, j \in [1, n]} dist(i, j)}{n^2}$ ,  $i \neq j$ ,  $W(i, i) = 0$ 。

本文提出的结合 Nyström 方法的谱聚类算法流程如下:

(1) 对面片集  $M = \{m_1, \dots, m_n\}$ , 使用 K-Means++ 算法确定  $m$  个采样点;

(2) 使用式(12)计算  $m$  个采样点与自身以及与剩余  $n$  个非样本点之间的亲和力矩阵;

(3) 使用 Nyström 方法估计亲和力矩阵  $\hat{W}$  的  $m$

个主特征向量, 并按列排放, 组成矩阵  $V = [e_1, e_2, \dots, e_m]$ ;

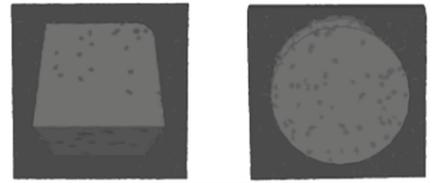
(4) 对矩阵  $V$  每行元素进行单位化, 得到矩阵  $V'$ ;

(5) 将矩阵  $V'$  中每行元素视为映射到  $m$  维空间的特征点, 并对其进行 K-Means 聚类, 聚类数目为  $m$ 。

最后, 如果矩阵  $V'$  的  $i$  行分配给簇  $j$  时, 将原始面片  $m_i$  分配给簇  $j$ 。

## 2.3 分割误差优化

Nyström 方法获得的亲和力矩阵特征向量是近似计算得出的, 因此在分割时会出现一定的误差, 分割模型误差俯视图如图3所示。



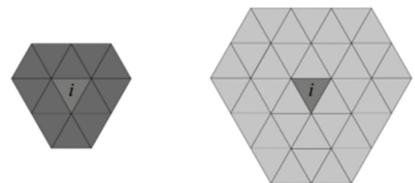
(a) 几何 A 模型 (b) 几何 B 模型

图3 分割模型误差俯视图

Fig. 3 Top view of segmentation error

可见, 分割误差类似于二维图像中的椒盐噪声, 椒盐噪声的消除方式一般是使用中值滤波方法。

二维图像中使用像素邻域滤波, 在三维网格中可以使用面片邻域进行滤波。面片  $i$  的一阶邻域、二阶邻域如图4所示。



(a) 一阶邻域 (b) 二阶邻域

图4 面片  $i$  邻域示意图

Fig. 4 Diagram of the neighborhood of surface  $i$

参考目前去噪效果较好的自适应中值滤波算法, 本文使用面片邻域作为滤波算子对分割模型进行优化, 提出了一种网格模型自适应邻域滤波算法。该算法遍历模型面片进行优化, 其核心是对误差的判断。

若面片  $i$  的一阶邻域中均为同一种颜色  $C$  且与面片  $i$  颜色不同, 则将面片  $i$  视为误差, 并将其颜色设置为颜色  $C$ 。

若面片  $i$  一阶邻域中存在两种(或以上)颜色  $C_a$ 、 $C_b$ , 并且数量最多的颜色  $C_m$  占比超过 80%, 同时面片  $i$  颜色不为  $C_m$ , 则将面片  $i$  视为误差, 将其颜

色设置为颜色  $C_m$ 。

若一阶顶点邻域中数量最多的颜色  $C_m$  占比不超过 80%, 同时面片  $i$  颜色不为  $C_m$ , 则将邻域扩大为二阶邻域进行判断, 将面片  $i$  颜色设置为二阶邻域中数量最多的颜色  $C'_m$ 。

使用自适应邻域滤波算法对分割结果进行优化, 得到优化后的模型俯视图如图 5 所示, 基本上消除了因矩阵估计引起的分割误差。



(a) 几何 A 模型 (b) 几何 B 模型

图 5 分割模型优化结果俯视图

Fig. 5 Top view of optimization results of segmentation

### 3 实验

本文使用 Python 编程实现方法, 在 CPU 为 Intel Core i5-6300HQ (2.30 GHz)、内存为 16 GB、系统为 Windows 10 的 PC 上进行实验。由于普林斯顿数据集中模型面片数较少, 本文从中选择了 8 类, 每类 2 个, 共计 16 个网格模型进行 Loop 细分, 并进行人工二分割, 作为实验数据集。

使用 Nyström 方法时, 需要确定对模型的采样数  $m$ 。图 6 为几何模型 A 的分割误差俯视图 (未进行误差优化), 其中  $m$  为采样数, 可见采样数从 2 增加到 10, 分割误差基本相同。

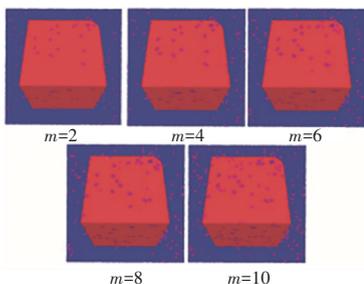


图 6 几何 A 模型不同采样数的分割误差俯视图

Fig. 6 Top view of segmentation error of geometry A with different sampling numbers

采样数取不同数值时, 对选取的 16 个模型进行分割 (未进行误差优化), 并对结果进行定量比较, 选组评估指标为兰德分数 (Rand Score, RS) 和运行时间, 兰德分数用来衡量分割方法与基准的相似性, 数值越大代表分割效果越好, 实验结果如图 7 和图 8 所示。可见采样数从 2 增加到 10, 兰德分数基本

持平, 分割时间明显上升。因此, 本文选取采样数目为  $m = 2$ 。

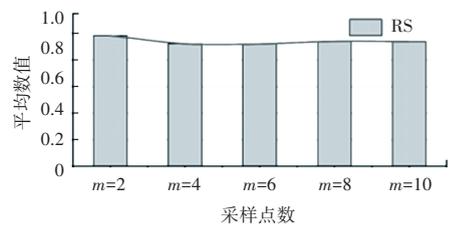


图 7 测试模型不同采样数的兰德分数平均值

Fig. 7 Average Rand scores of the testing models with different sampling numbers

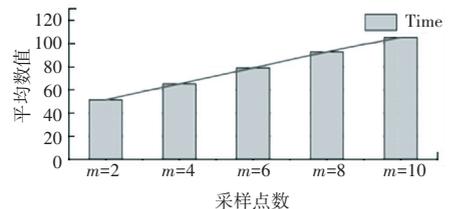


图 8 测试模型不同采样数的运行时间平均值 (/s)

Fig. 8 Average running time of the testing models with different sampling numbers (unit: second)

本文方法对模型的二分结果 (每类模型中上方的命名为 A, 下方为 B) 如图 9 所示, 可以看出本文方法得到的分割结果符合人眼的视觉标准。

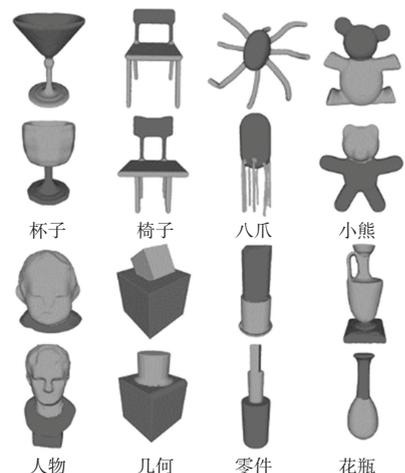


图 9 本文方法对普林斯顿数据集部分细分模型分割结果

Fig. 9 The segmentation results by the proposed method of partial Princeton dataset models after subdivision

对比指标除兰德分数外, 还有准确率分数 (Accuracy Score, AS) 和汉明损失 (Hamming Loss, HL)。准确率分数与兰德分数类似, 用来衡量分割方法与基准的相似性, 其数值越大越好; 汉明损失用来衡量分割结果中错误的比例, 数值越小代表分割效果越好。

为进一步验证本文方法的有效性, 采用量化评估标准将本文方法与 BIRCH (Balanced Iterative

Reducing and Clustering using Hierarchies, BIRCH) 算法, K-Means 算法, Mini Batch K-Means 算法, Liu 等<sup>[5]</sup>提出的算法和 Katz 等<sup>[13]</sup>提出的算法进行二分比较。实验结果如图 10、图 11 所示。可见本文方法具有较好的分割效果, 兰德分数、准确率分数高于其他算法, 汉明损失低于其他算法。在本文实验环境下, Liu 等<sup>[5]</sup>提出的算法和 Katz 等<sup>[13]</sup>提出的算法仅可正常分割 1 个模型, 分割其余模型时超出 16 GB 内存限制, 无法运行, 因此无法显示这两种方法的指标平均值。

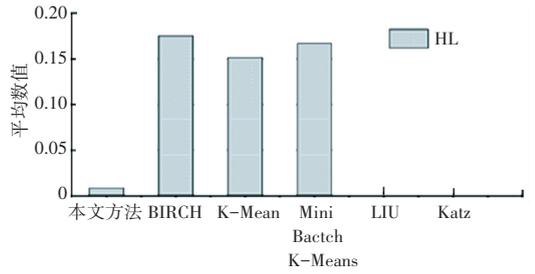


图 11 测试模型汉明损失平均值

Fig. 11 Average Hamming loss of the testing models

6 种算法在本文数据集上的兰德分数和运行时间见表 1 (本文方法已进行误差优化)。在面片数最小的模型零件 A (面片数 3w) 上, Liu 等<sup>[5]</sup>提出的算法获得了最高的兰德分数 0.992, 运行时间为 397.3 s; Katz 等<sup>[13]</sup>提出的方法获得的次高的兰德分数 0.988, 运行时间为 1 256.1 s, 这两种方法在其余模型上均超出 16 GB 内存限制, 无法运行 (数据在表 1 中显示为横线)。本文方法在零件 A 模型上获得的兰德分数为 0.986, 高于其余 3 种方法, 运行时间为 19.1 s; 在其余模型上, 兰德分数均为最高, 运行时间在几十秒左右。

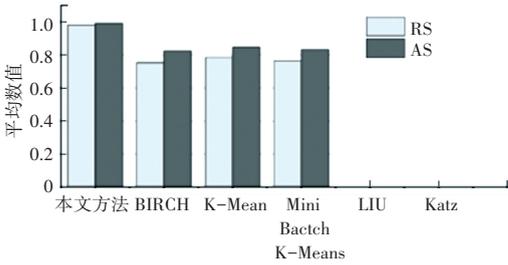


图 10 测试模型兰德分数、准确率分数平均值

Fig. 10 Average Rand scores, accuracy scores of the testing models

表 1 测试模型兰德分数、运行时间评价表

Tab. 1 Rand score, running time evaluation table of the testing models

模型信息		本文方法		BIRCH		K-Means		Mini Batch K-Means		Liu		Katz	
模型名称	面片数目	Rand Score	Time/s	Rand Score	Time/s	Rand Score	Time/s	Rand Score	Time/s	Rand Score	Time/s	Rand Score	Time/s
杯子 A	12w	<b>0.999</b>	71.5	0.955	16.1	0.971	14.4	0.965	14.0	-	-	-	-
杯子 B	12w	<b>0.998</b>	71.4	0.966	16.5	0.968	15.4	0.971	14.5	-	-	-	-
椅子 A	11w	<b>0.987</b>	64.5	0.754	15.4	0.902	12.8	0.566	13.9	-	-	-	-
椅子 B	11w	<b>0.982</b>	62.8	0.919	14.5	0.962	13.9	0.979	12.3	-	-	-	-
八爪 A	6w	<b>0.928</b>	37.0	0.687	8.6	0.870	7.7	0.873	7.3	-	-	-	-
八爪 B	7w	<b>0.938</b>	44.0	0.502	10.4	0.502	9.0	0.502	10.9	-	-	-	-
小熊 A	11w	<b>0.993</b>	64.2	0.590	13.6	0.645	12.7	0.642	12.2	-	-	-	-
小熊 B	10w	<b>0.996</b>	58.1	0.510	12.5	0.550	10.6	0.556	11.1	-	-	-	-
人物 A	7w	<b>0.969</b>	43.8	0.886	13.7	0.905	11.5	0.912	11.0	-	-	-	-
人物 B	19w	<b>0.993</b>	116.2	0.650	31.9	0.674	27.7	0.666	27.7	-	-	-	-
几何 A	12w	<b>0.995</b>	74.8	0.513	21.2	0.544	17.8	0.543	18.4	-	-	-	-
几何 B	12w	<b>0.990</b>	71.0	0.750	20.3	0.576	18.4	0.574	19.4	-	-	-	-
零件 A	3w	<b>0.986</b>	19.1	0.867	4.8	0.985	4.3	0.984	4.2	<b>0.992</b>	397.3	0.988	1 256.1
零件 B	8w	<b>0.986</b>	50.0	0.879	14.5	0.852	12.4	0.852	12.7	-	-	-	-
花瓶 A	12w	<b>0.997</b>	70.2	0.710	19.9	0.705	17.7	0.705	17.4	-	-	-	-
花瓶 B	11w	<b>0.993</b>	65.9	0.928	14.1	0.946	12.8	0.956	11.6	-	-	-	-
平均值	10w	<b>0.983</b>	61.5	0.754	15.5	0.785	13.7	0.766	13.7	-	-	-	-

传统谱聚类算法因其巨大的时间、空间开销无法分割面片数较多的模型;K-Means、BIRCH等算法运行时间短、消耗内存空间小,但无法有效利用模型的几何特征,分割效果差。本文方法相比于传统谱聚类算法,有效减少了分割模型所需时间、空间开销,同时也获得了较高的兰德分数,分割效果比K-Means、BIRCH等算法好。

## 4 结束语

本文提出了一种结合Nyström方法的三维网格模型分割方法。首先,使用K-Means++算法对模型面心进行聚类,将距离聚类中心最近的面心作为采样点;其次,计算采样点和所有面心的亲和力数值,并使用Nyström方法估计亲和力矩阵的主特征向量;将特征向量拼接为矩阵,并对矩阵每行元素使用K-Means方法聚类,实现对模型的分割;最后,使用自适应邻域滤波算法对分割结果进行优化,去除估计误差。实验结果表明本文方法有效避免了计算亲和力矩阵的时间、空间开销,可以获得符合人类视觉划分效果的分割结果。

本文使用Nyström方法估计亲和力矩阵,存在一定分割误差,在二分割上取得了较好的效果,而对于多分割则会存在较大误差。降低Nyström方法的估计误差,更好地逼近真实的亲和力矩阵是接下来的研究重点。

## 参考文献

[1] RODRIGUES R S, MORGADO J F, GOMES A J. Part - based

mesh segmentation: a survey [C]//Computer Graphics Forum, 2018: 235-274.

- [2] 龚思洁, 贺焯臻, 陈小雕. 基于能量优化的三维网格模型分割方法[J]. 计算机辅助设计与图形学学报, 2021, 33(1): 11-18.
- [3] 赵云成, 王琳, 盛步云, 等. 综合曲率约束的在线网格模型分割方法研究[J]. 计算机工程与应用, 2020, 56(16): 176-182.
- [4] 梁楚萍, 印杰, 伍静, 等. 三维网格分割中聚类分析技术综述[J]. 计算机辅助设计与图形学学报, 2020, 32(4): 680-692.
- [5] LIU R, ZHANG H. Segmentation of 3D meshes through spectral clustering [C]//12<sup>th</sup> Pacific Conference on Computer Graphics and Applications, 2004: 298-305.
- [6] JIAO X, WU T, QIN X. Mesh segmentation by combining mesh saliency with spectral clustering [J]. Journal of Computational and Applied Mathematics, 2018, 329: 134-146.
- [7] 万燕, 刘巧雪, 姚砾. 三维模型分割的研究及其在人体测量中的应用[J]. 智能计算机与应用, 2022, 12(1): 1-7, 15.
- [8] TONG W, YANG X, PAN M, et al. Spectral mesh segmentation via gradient minimization [J]. IEEE Transactions on Visualization and Computer Graphics, 2018, 26(4): 1807-1820.
- [9] LINGFEI L, TIERU W. Automatic spectral method of mesh segmentation based on fiedler residual [J]. Chinese Journal of Electronics, 2021, 30(3): 426-436.
- [10] WILLIAMS C, SEEGER M. Using the Nyström method to speed up kernel machines [C]//Proceedings of the 14<sup>th</sup> annual conference on neural information processing systems, 2001: 682-688.
- [11] NG A Y, JORDAN M I, WEISS Y. On spectral clustering: Analysis and an algorithm [C]//Advances in neural information processing systems, 2002: 849-856.
- [12] OGLIC D, GÄRTNER T. Nyström method with kernel k-means++ samples as landmarks [C]//International Conference on Machine Learning, 2017: 2652-2660.
- [13] KATZ S, TAL A. Hierarchical mesh decomposition using fuzzy clustering and cuts [J]. ACM transactions on graphics (TOG), 2003, 22(3): 954-961.

(上接第133页)

表3 不同社区内的股票构成

Tab. 3 Share composition in different communities

社区	股票名称
社区1	中国中冶、中国石化、三一重工、中国铝业、宝钢股份、中国核电、江西铜业、紫金矿业、中国电建、陕西煤业、中国石油、北方稀土、宝丰能源
社区2	北京银行、海通证券、新华保险、浦发银行、民生银行、中国人寿、交通银行、招商银行、中国银行、建设银行、金地发展、邮储银行
社区3	国泰君安、中国银河、中信建投、国金证券、东方证券、财通证券、方正证券、招商证券、国投资本
社区4	伊利股份、贵州茅台、海尔智家、片仔癀、青岛啤酒、绝味食品、今世缘、口子窖
社区5	工业富联、长电科技、生益科技、中科曙光、汇顶科技

## 4 结束语

本文基于时间序列的相似性以及复杂网络理论对网络中最重要的特性——社区结构进行了相应的分析,并利用上证180指数成分股票的时间序列数据对其网络进行了社区结构的分析,表明利用时间序列相似性对现实经验世界中的复杂网络的社区结构进行分析和解释其内在运行机制是有效可行的。但本文忽略了复杂系统中每个个体之间原本存在着一定的联系,仅仅利用每个个体时间序列之间的相似性表示每个个体之间的关系,没有非常准确地描述现实场景。未来的工作应该考虑保留复杂系统中个体之间原本的联系,再结合时间序列之间的相似性,考虑复杂系统每个个体之间不同类型的关系的结合并分析其对复杂系统的社区结构的影响,从而能够更精准地预测和控制这些复杂系统。