

基于权重能量自适应分布的三维形状分割算法

舒振宇^{1,2)}, 杨思鹏^{3)*}, 辛士庆⁴⁾, 庞超逸^{1,2)}, 杨雨璠¹⁾, 胡超⁵⁾

¹⁾ (浙江大学宁波理工学院计算机与数据工程学院 宁波 315100)

²⁾ (浙江大学宁波研究院 宁波 315100)

³⁾ (浙江大学机械工程学院 杭州 310027)

⁴⁾ (山东大学计算机科学与技术学院 青岛 266237)

⁵⁾ (浙江大学宁波理工学院信息科学与工程学院 宁波 315100)
(21825205@zju.edu.cn)

摘要: 针对三维形状分割问题, 提出一种引入权重能量自适应分布参与深度神经网络训练的全监督分割算法。首先对三维形状表面进行过分割得到若干小块, 提取每一个小块的特征描述符向量作为神经网络的输入, 计算权重能量自适应分布, 将经过加权后的分割标签作为神经网络的输出, 训练深度神经网络。对于新的未分割的三维模型, 提取模型表面三角面片的特征向量后输入到神经网络中进行预测分割后, 对预测分割的边缘进行修整得到分割结果, 实现三维模型的自动分割。在普林斯顿三维模型分割数据集上的实验结果表明, 算法通过在训练过程中引入权重能量自适应分布, 可以大幅降低神经网络训练时的均方误差, 提高神经网络预测结果的准确率; 与传统算法相比, 该算法具有高准确率、强鲁棒性、强学习扩展能力等优点。

关键词: 三维模型; 三维模型分割; 权重能量自适应分布; 深度学习

中图法分类号: TP391.72 **DOI:** 10.3724/SP.J.1089.2020.17937

3D Shape Segmentation Algorithm Using Weighted Energy Adaptive Distribution

Shu Zhenyu^{1,2)}, Yang Sipeng^{3)*}, Xin Shiqing⁴⁾, Pang Chaoyi^{1,2)}, Yang Yufan¹⁾, and Hu Chao⁵⁾

¹⁾ (School of Computer and Data Engineering, Ningbo Institute of Technology, Zhejiang University, Ningbo 315100)

²⁾ (Ningbo Institute, Zhejiang University, Ningbo 315100)

³⁾ (School of Mechanical Engineering, Zhejiang University, Hangzhou 310027)

⁴⁾ (School of Computer Science and Technology, Shandong University, Qingdao 266237)

⁵⁾ (School of Information Science and Engineering, Ningbo Institute of Technology, Zhejiang University, Ningbo 315100)

Abstract: In this paper, a fully supervised segmentation algorithm is proposed by using weighted energy adaptive distribution (WEAD). Firstly, the 3D shapes are divided into several small patches using an over-segmentation method. Secondly, feature vectors of the patches are extracted as the training input and WEADs are used as the training output to re-weight the labels of segmentation. Finally, a corresponding deep neural network is trained. For an unlabeled 3D shape, our algorithm automatically segments it by using the trained deep neural network followed by the graph cuts method. Extensive experimental results show that the mean square error (MSE) in the training process can be greatly reduced by using WEAD in our algo-

收稿日期: 2019-06-23; 修回日期: 2019-09-02. 基金项目: 国家自然科学基金(61872321, 61572022); 浙江省自然科学基金(LQ17F030002, LQ19C060001); 宁波市自然科学基金(2019A610086); 宁波市领军和拔尖人才培养工程择优资助科研项目(NBLJ201801010); 宁波市科技计划项目创新团队专项(2014B82015, 2016C11024); 浙江大学CAD&CG国家重点实验室开放课题(A1702). 舒振宇(1979—), 男, 博士, 教授, 硕士生导师, 主要研究方向为计算机图形学、机器学习、数据挖掘; 杨思鹏(1995—), 男, 硕士研究生, 论文通讯作者, 主要研究方向为机器学习、计算机辅助设计; 辛士庆(1979—), 男, 博士, 副教授, 博士生导师, 主要研究方向为计算机图形学; 庞超逸(1960—), 男, 博士, 教授, 博士生导师, 主要研究方向为数据挖掘、数据压缩; 杨雨璠(1997—), 女, 硕士研究生, 主要研究方向为机器学习、计算机辅助设计; 胡超(1960—), 男, 博士, 教授, 博士生导师, 主要研究方向为自动化控制、机器视觉。

rithm. And our method performs better than other fully supervised and unsupervised algorithms on the Princeton Segmentation Benchmark (PSB) dataset.

Key words: 3D shape; 3D shape segmentation; weighted energy adaptive distribution; deep learning

随着三维扫描技术和建模技术的不断发展, 三维模型被广泛地应用于实际的生产生活和科学研究中, 相关的数字几何处理技术研究也得到了不断深入. 其中, 三维模型分割算法是许多数字几何处理技术的基础, 如网格变形编辑、模型骨架提取和形状检索等都可以用到模型分割算法. 三维模型种类和数量的飞速增长对模型分割算法的效能提出了更高的要求.

近年来, 国内外的很多学者对三维模型分割问题进行了大量的研究. 基于学习的三维模型分割算法可以在训练好的算法模型上快速对新输入的模型进行分割, 具有较好的应用前景, 已成为研究的热点之一. 基于学习的三维模型分割算法按照学习方式可以分为全监督算法、弱监督算法和无监督算法^[1].

全监督算法在人工完全分割好的模型上进行学习训练, 分割效果较好. 在 2010 年计算机图形学顶级会议 SIGGRAPH 上, Kalogerakis 等^[2]最先提出基于监督学习的三维模型分割算法, 通过构建目标函数来建立三维模型面片与分类标签之间的对应关系, 用人工标记好的三维模型训练和优化目标函数, 最终实现对未标记模型的分割. 随着研究的深入, 全监督学习的三维模型分割算法分成基于三维形状特征描述符和基于模型投影的分割算法^[3]. 基于三维形状特征描述符的算法通过特征描述符实现模型表面特征的提取. Guo 等^[4]提出一种基于深度卷积神经网络的三维模型分割方法, 通过卷积核提取三维特征向量的信息实现模型的分割. Xie 等^[5]提出了一种基于极限学习机(extreme learning machine, ELM)的全监督快速学习分割算法, 在保证模型分割效果良好条件下缩短了训练时间. 基于模型投影的分割算法的原理是将三维模型投影到二维平面上, 利用投影得到的轮廓图和深度图来提取三维形状的特征, 进而实现模型分割. 例如, Kalogerakis 等^[6]提出通过训练卷积网络实现全监督模型分割学习的方法, 网络训练的输入是模型的轮廓图和深度图, 输出是三维模型的分割结果, 其实验结果明显优于前人的算法结

果. Le 等^[7]提出将循环神经网络(recurrent neural network, RNN)与多视角投影(multi-view)相结合的三维模型分割算法, 克服了多视角投影图像训练时图像方向不一致造成的训练效果差的问题.

弱监督三维模型分割算法使用不完全标记的数据作为训练样本, 因此极大地减少了模型标记所花费的时间^[8]. 例如, Bergamasco 等^[9]使用预先在模型上标注的很少的点作为分割种子, 通过迭代地访问模型面片的权重图(weighted graph)来分割三维网格模型. Wang 等^[10]提出一种用户在训练过程中逐步输入约束条件的弱监督模型分割算法.

无监督的三维模型分割方法不需要人工标记数据集, 因此节省了标记所花费的时间^[11]. Wu 等^[12]运用谱聚类方法实现了三维模型的自动分割. Sidi 等^[13]的应用于非刚体模型(non-rigid shape)分割的无监督学习算法, 通过扩散图(diffusion maps)建立了模型面片之间的相互关系, 并用谱聚类(spectral clustering)实现模型的分割. Wu 等^[12]的无监督模型分割算法与 Sidi 等^[13]的方法类似, 都是运用谱聚类方法实现最后的分割. Shu 等^[14]提出了基于深度学习的三维模型分割方法, 其核心是通过深度神经网络学习模型面片从高维度特征描述符向量到一维的面片标签之间的转换特征, 应用密度峰值聚类(density peaks clustering)算法^[15]得出面片的分割标签, 最终实现无监督三维模型分割算法的训练.

虽然弱监督和无监督算法可以大幅减少标记和训练所花费的时间, 但是最终的分割结果与全监督方法的结果对比存在一定的差距. 此外, 基于学习的模型分割算法的最大优势在于训练完成后, 人工神经网络可以运用在所有同类别的三维模型上^[16], 因此, 准确率较高的全监督算法更受青睐. 但是, 传统的全监督学习算法使用割裂式的数字标签进行训练, 降低了神经网络的学习能力, 导致了在分割边缘处神经网络的预测表现较差, 损失函数难以下降等问题. 本文采用一种全新的权重能量分布来重新定义神经网络训练的输出结构, 可以优化训练过程, 提升神经网络的学习和预测效果.

1 本文算法概述

本文提出一种基于权重能量自适应分布的三维模型分割算法, 主要的流程图如图1所示. 给定一类三维模型, 首先使用过分割^[17](over-segment)算法将三维网格模型分成很多小片, 每一个小片包含若干个三角面片. 在每一个小片上随机地选取一个面片作为这一小片的代表; 以如下方式构造神经网络: 计算每一个小片的特征向量, 作为神经网络训练的输入; 根据人工标注的分割标签信息计算权重能量分布, 给每一个小片的分割标签的 one-hot 形式赋值权重作为神经网络的输出. 以上述定义的输入和输出, 训练一个可用于三维模型分割预测的深度学习神经网络.




图1 本文算法流程图

对于一个未做分割标记的新的三维模型, 先计算模型上每一个三角面片的特征向量, 之后输入到深度学习中去预测其分割的结果, 最后用图割(graph cuts)算法^[18]对分割的边缘进行修整, 完成模型的自动分割.

本文算法的优势在于可以在保证高准确率的分割结果的情况下快速实现三维模型的分割, 通过在深度神经网络的训练时引入权重能量分布来优化训练过程, 与传统的全监督学习算法相比, 可以达到更好的分割预测效果.

2 测地距离的权重能量分布表达

本文算法采用形状特征描述(shape descriptor)

提取三维模型表面三角面片的几何特征, 以实现三维模型分割的鲁棒学习. 理论上, 对于同一类三维模型, 2个具有相似的特征向量的面片应该被分割为同一类, 可以通过神经网络学习预测相似面片的分类, 即把相似的三角面片分割为同一部分.

然而, 传统的全监督算法输入训练的三维模型的标签是割裂式的. 如图2所示, 在分割线附近, 2个相邻的面片A和面片B, 它们的特征向量可能相差不大, 但是它们的分类标签却完全不同. 用这种带有很多混淆标签的数据集进行训练, 可能会导致神经网络预测的准确率大幅降低, 甚至会造成训练过程中梯度消失, 损失函数难以优化等问题. 这极大地影响了深度学习神经网络在模型分割问题上的学习和预测效果.




图2 模型分割边界

为了解决这个问题, 本文设计了一个权重能量分布参与神经网络的训练, 可以改善训练时割裂式的标签带来的负面影响, 提高训练时损失函数下降的稳定性和神经网络预测的准确率, 最终实现更好的三维模型分割预测结果.

给定一个人工分割好的三维模型, 可以计算得到每一个三角面片的形状特征描述符向量 $\mathbf{x}_i$ 以及每一个三角面片上的分割标签信息 l_i , 将特征描述向量与标签信息组合得到初始的神经网络训练数据 $\mathbf{T}_0 = \{\mathbf{x}_i | l_i\} (i=1, 2, \dots, n)$. 本文定义了一个权重能量分布来改善训练数据的可学习性, 权重能量分布 $\mathbf{M}$ 定义为

$$\mathbf{M}_i = \varphi_{\mu, \sigma^2} \left(\min_{l_i \neq l_j} (d_{ij}) \right) \quad (1)$$

其中, d 表示面片间的测地距离^[19]; $\min_{l_i \neq l_j} (d_{ij})$ 表示面片 i 到与它分割标签不一致的面片 j 的测地距离中最小的一个; $\varphi_{\mu, \sigma^2}(\chi)$ 表示高斯函数, 用来对测地距离进行归一化处理; 设参数 $\mu=0$, 设参数 σ 为最小的测地距离的平均值, 即 $\sigma = \text{avg} \left(\min_{l_i \neq l_j} (d_{ij}) \right)$.

如图 3 所示, 图 3a 是由人工标记好的三维模型, 图 3b 是权重能量分布 $\mathbf{M}$ 表示每一面片上的分割标签在训练过程中的重要程度, 颜色越深表示该三角面片的权重越大. 引入权重能量分布的意义是: 对于模型中被分割出来的某一部分, 远离分割线的面片特征在神经网络学习过程中应该被赋值更大的权重, 而靠近分割线的部分在训练过程中的权重应该被调低. 通过这种方式, 原先的训练数据集 $T_0 = \{x_i | l_i\} (i = 1, 2, \dots, n)$ 的硬标签形式被改进为 $T = \{x_i | (\mathbf{M}_i \cdot \zeta_i)\} (i = 1, 2, \dots, n)$ 的软标签; 其中, ζ_i 是标签 l_i 的 one-hot 编码形式.




图 3 权重能量分布

然而, 计算测地距离是一个非常耗费计算时间和资源的过程. 为了减少计算量, 本文算法先对模型进行过分割处理, 将模型分成数百个小块, 每一个小块上包含了几个到几十个三角面片. 通过随机选取一个三角面片代替整一小块的特征, 极大地减少计算量, 在加快算法运行速度的同时减小内存占用.

3 基于深度神经网络的学习和预测过程

得到了优化过的三维模型分割训练数据之后, 本文算法创建了一个带有神经元随机失活(dropout)的深度神经网络, 来学习和预测三维模型的分割特性. 如图 4 所示, 该神经网络包含 1 个输入层, 6 个隐含层和 1 个输出层. 输入层负责接收三角面片的特征描述符向量, 输入层神经元的个数与特征描述符向量的维度相同. 输出层是模型分割结果的 one-hot 表达以及权重, 其神经元的数量与模型分割结果的类别数相同. 中间的 6 个隐含层包含 4 个全连接层和 2 个随机失活层. 随机失活就是在神经网络的随机失活层上, 为每一个神经元设置一个随机消失的概率, 随机失活层只会保留

随机的神经元参与训练. 虽然保留的神经元是随机的, 但是数量是固定的, 这样做的目的是降低神经元对某些输入特征的依赖, 所有输入的特征都可能被随机消除, 训练的结果就不依赖于某些权重太大的输入特征, 有效地提高了神经网络的鲁棒性.




图 4 本文深度神经网络

在深度神经网络训练完成之后, 就可以对未标记的模型进行分割预测. 给定一个未做标记的三维模型 S , 首先计算得到模型表面所有三角面片的特征描述符向量 $x_1, x_2, \dots, x_n$; 然后输入到训练好的神经网络中进行预测, 可以得到每一个三角面片的分割标签的概率 $\zeta_1, \zeta_2, \dots, \zeta_i$; 最后利用图割算法^[18]对分割标签概率向量 ζ_i 进行分割处理, 得到分割标签 $L = \{l_1, l_2, \dots, l_n\}$, 使得分割边缘更加整齐, 最终实现对三维模型的自动分割.

4 全监督分割算法的实现

4.1 三维形状特征描述符选择

三维形状特征描述符可以用来刻画模型的几何特征, 在数字几何处理领域应用广泛^[20]. 常用的三维形状特征描述符包括高斯曲率(Gaussian curvature, GC)^[21]、形状直径函数(shape diameter function, SDF)^[22]、平均测地距离(average geodesic distance, AGD)^[23]、热核签名(heat kernel signatures)^[24]、尺度不变热核签名(scale-invariant heat kernel signatures)^[25]等. 不同的特征描述符刻画了模型不同方面的特性, 本文使用了多特征描述符组合的方法^[26], 以达到更好的算法效果.

本文算法的学习框架不依赖于特定的特征描述符, 为了充分挖掘深度神经网络的学习能力, 本文选择了3个特征描述符, 将GC, SDF和AGD串接成三维的特征向量, 输入到深度神经网络中训练。

4.2 利用图割算法修整分割边缘

神经网络预测模型分割结果中, 大部分三角面片的预测结果是正确的, 但是在分割边缘处存在一些不符合视觉的预测结果。因此, 本文算法在最后利用图割算法^[18]对分割边缘进行修整, 以获得更好的分割结果。

图割算法^[18]首先建立目标函数, 然后进行优化求解, 并获得相应结果。该目标函数以三角面片的分割标签 l 作为自变量, 通过求解目标函数 $E(l)$ 来调整三角面片的标签, 从而获得更好的分割结果。本文算法使用的目标函数为

$$E(l) = \sum_{f \in F} e_1(f, l_f) + \lambda \sum_{\{f, g\} \in N} e_2(l_f, l_g) \quad (2)$$

其中,

$$\begin{cases} e_1(f, l_f) = -\lg(\max(P(f | l_f), \varepsilon)) \\ e_2(l_f, l_g) = \begin{cases} -\lg(\theta(f, g) / \pi), & l_f \neq l_g; \\ 0, & l_f = l_g \end{cases} \end{cases}$$

F 表示三维模型上所有面片的集合; G 表示任意2个相邻面片所构成的集合; l_f 表示面片 f 的分割标签; $P(f | l_f)$ 表示面片 f 的标签为 l_f 的概率; $\theta(f, g)$ 表示面片 f 和面片 g 之间的二面角; λ 是权重常值; ε 是一个极小的概率值。该目标函数中含有2个优化项 e_1 和 e_2 , 分别代表预测标签和分割面片的夹角尽量沿着凹边。本文采用 α -expansion算法^[18]求解目标函数 $E(l)$, 对于 $E(l)$ 中的参数 λ , 本文采用学习的策略, 在训练样本中获取针对每一类模型的最优 λ 值, 从而保证图割算法^[18]适用于每一类三维模型。

4.3 算法的具体步骤

给定一类三维模型数据 $D = \{S_1, S_2, \dots, S_m\}$ 及其分割的标签信息 $L = \{L_1, L_2, \dots, L_m\}$, 本文算法的目标是用全监督学习的方式从已经由人工分割好的三维模型学习分割特性, 引入权重能量分布 M 优化输出标签, 最后进行深度神经网络的训练, 并在未标记的模型上进行测试和对比。

本文算法步骤如下:

Step1. 对于给定的三维模型 S_k 及其分割标签 L_k , 使用过分割算法将 S_k 分割成 n 个小块 $\{s_1, s_2, \dots, s_n\}$, 随机选取 s_i 上的一个三角面片代表小块 s_i 的特征。

Step2. 利用特征描述符GC, SDF和AGD提取三维模

型上每一小块的特征向量 $\{x_1, x_2, \dots, x_n\}$, 将所有小块的特征向量组成的集合作为深度神经网络训练的输入 $I = \{x_1, x_2, \dots, x_n\}$ 。

Step3. 通过分割标签 $L = \{l_1, l_2, \dots, l_n\}$ 计算从小块 s_i 到与 s_i 标签不同的小块 s_j 的测地距离, 再利用激活函数 $\phi_{\mu, \sigma^2}(\chi)$ 得到权重能量分布 M , 计算得到软标签 $y_i = M_i \cdot \zeta_i$; 其中, ζ_i 是标签 l_i 的one-hot编码形式, 将所有小块的软标签作为深度神经网络训练的输出 $O = \{y_1, y_2, \dots, y_n\}$ 。

Step4. 用上述的输入和输出训练一个带有随机失活层的深度神经网络。

Step5. 对于一个未做分割的三维模型, 提取其所有三角面片的特征向量 $\{x_1, x_2, \dots, x_n\}$, 输入到训练好的神经网络中得到预测的分割结果软标签 $\{\zeta_1, \zeta_2, \dots, \zeta_c\}$, 最后利用图割算法^[18]自动修整分割边缘, 以获得更好的视觉效果。

5 实验与讨论

5.1 实验结果

为了验证算法的分割效果, 本文选择普林斯顿模型分割 (Princeton segmentation benchmark, PSB)数据集^[27]作为训练和测试数据。该数据集包含19类三维模型, 每一类包含20个, 共计380个三维模型。PSB数据集的部分三维模型采用本文算法的分割结果如图5所示。本文算法从PSB数据集中随机选择10个模型作为训练集数据, 剩下10个作为测试数据。



图5 本文算法对PSB数据集部分模型的分割结果

图 6 展示了本文算法运行过程的中间结果. 本文算法首先从图 6a 所示模型的人工标记的分割标签获得图 6b 所示的权重能分布, 之后进行深度神经网络的训练; 对于图 6c 所示的测试三维模型, 将其特

征向量输入到神经网络中进行前向传递, 得到图 6d 所示的初始分割结果, 该结果是对每一面片的预测概率取最大值而得到的; 最后使用图割算法^[18]进一步优化分割边缘, 并得到图 6e 所示的最终分割效果.




图 6 算法中间过程

图 7 展示了本文算法分割结果与人工标注的分割之间的对比. 可以明显地看出, 本文算法的预测分割结果与人工分割的结果非常接近, 获得了较好的分割效果.



图 7 分割结果对比

5.2 权重能量分布对深度学习的影响

为了测试在深度神经网络训练过程中引入权重能量分布后的效果, 本文对比了直接使用人工分割标签进行训练和基于权重能量分布优化后的标签进行训练. 实验组是本文算法, 采用权重能量分布对分割标签的 one-hot 形式做优化, 之后进行

深度神经网络训练; 对照组是直接使用人工分割标签进行训练; 评价指标是神经网络训练结束时测试集的均方误差(mean square error, MSE), 误差越低, 表示神经网络的训练结果越好^[28].

图 8 展示了在测试的 5 类模型上本文算法和对照组的深度学习训练 MSE 对比. 可以明显看出, 本文算法在训练过程中引入权重能量分布可以大幅提升神经网络的学习及预测能力. 图 9 展示上述 5 类模型的兰德指数(rand index, RI)^[27]值对比. 其中, 引入权重能量分布的分割结果平均 RI 值为 0.048, 不引入权重能量分布的分割结果平均 RI 值为 0.071. 在引入权重能量分布后, RI 值明显低于未引入权重能量分布的分割结果, 验证了本文算法的有效性.




图 8 引入权重能量分布的 MSE 对比

5.3 与其他三维模型分割算法的比较

本文与其他的 7 种三维模型分割算法进行了比较, 包括全监督算法^[2,4], 以及 5 种结果较好的

无监督算法 WcSeg^[29], CoreExtra^[30], FitPrim^[31], RandCuts^[17]和 NormCuts^[27]. 对比的评价指标采用 PSB 数据集推荐的 RI 值, 即

$$RI = 1 - \left(\frac{2}{n} \right)^{-1} \sum_{i,j,i < j} [P_{ij}Q_{ij} + (1-P_{ij})(1-Q_{ij})] \quad (3)$$

其中, P 表示基准分割; Q 表示需要评价的分割; n 是模型上三角面片的数量. 当面片 f_i 和面片 f_j 在基准结果中的分割标签一致时, $P_{ij}=1$; 否则, $P_{ij}=0$. 类似地, 当面片 f_i 和面片 f_j 在需要评价分割结果中的分割标签一致时, $Q_{ij}=1$; 否则, $Q_{ij}=0$. 对于 RI 值, 数值越小, 表示分割效果与基准结果越相似, 即分割结果越好^[32].

本文算法和其他 7 种分割算法在 PSB 数据集上进行了实验对比, 每一类三维模型的实验结果

如表 1 所示, 部分对比图如图 10 所示. 本文及分割算法^[2,4]均为全监督算法, 可以明显地看出, 它们的 RI 值都低于传统的无监督分割算法. 同时, 本文的基于权重能量分布的深度学习算法在多数模型上的分割结果优于分割算法^[2,4], 整个数据集的平均 RI 值也较低, 分割结果更好.




图 9 引入权重能量分布的 RI 值对比

表 1 不同算法 RI 值对比

三维模型	本文	文献[2]	文献[4]	WcSeg ^[29]	CoreExtra ^[30]	FitPrim ^[31]	RandCuts ^[17]	NormCuts ^[27]
Human	0.100	0.120	0.142	0.128	0.189	0.159	0.132	0.163
Cup	0.055	0.090	0.100	0.165	0.291	0.436	0.277	0.392
Glasses	0.134	0.135	0.155	0.175	0.287	0.225	0.105	0.147
Airplane	0.096	0.079	0.085	0.089	0.243	0.172	0.130	0.185
Ant	0.014	0.018	0.026	0.021	0.062	0.128	0.044	0.097
Chair	0.054	0.055	0.072	0.105	0.185	0.214	0.189	0.113
Octopus	0.026	0.019	0.050	0.029	0.052	0.128	0.088	0.106
Table	0.059	0.062	0.097	0.089	0.222	0.318	0.402	0.240
Teddy	0.028	0.033	0.068	0.057	0.114	0.138	0.067	0.122
Hand	0.140	0.101	0.106	0.112	0.155	0.196	0.116	0.164
Plier	0.102	0.054	0.049	0.086	0.094	0.194	0.126	0.208
Fish	0.127	0.128	0.156	0.203	0.268	0.433	0.299	0.387
Bird	0.051	0.078	0.083	0.103	0.124	0.204	0.124	0.192
Armadillo	0.089	0.069	0.096	0.080	0.133	0.102	0.086	0.199
Bust	0.186	0.241	0.299	0.264	0.314	0.313	0.247	0.340
Mech	0.070	0.109	0.114	0.173	0.327	0.343	0.327	0.337
Bearing	0.067	0.076	0.079	0.105	0.367	0.162	0.139	0.166
Vase	0.135	0.150	0.166	0.162	0.231	0.281	0.162	0.326
Fourleg	0.115	0.136	0.137	0.153	0.184	0.198	0.183	0.220
平均	0.087	0.092	0.109	0.121	0.202	0.229	0.171	0.216

注. 黑体表示每一类模型中分割表现最好的算法结果.

本文算法采用 Matlab 和 C++ 进行实现, 测试环境为 3.20 GHz Intel Core™ 12 核 CPU, 16GB 内存和 NVIDIA GeForce GTX 1070 Ti 显卡. 在训练过程中, 本文算法针对每类三维模型(包含 10 个三维模型样本)进行神经网络训练, 所需时间平均为 18 min. 在

测试过程中, 本文算法分割一个三维模型所需时间平均为 5.7s. 表 2 展示了不同算法分割一个三维模型所花费的时间, 其中*表示在 Intel Core™ 3.20 GHz CPU 环境下, \$表示 Xeon E55355 2.66 GHz CPU 环境下, +表示 Xeon E5-2670 2.60 GHz CPU 环境下, #表示




图 10 不同算法对 PSB 数据集中模型处理结果比较

在 2.00 GHz CPU 环境下, 可以明显看出, 本文算法在神经网络训练完成之后能够快速对三维模型进行分割, 所需时间较少。

表 2 不同算法对单个模型分割处理所花费的时间 s

算法	时间
本文	5.7 *
文献[2]	180.0 \$
文献[4]	120.0 +
WcSeg ^[29]	93.7 +
CoreExtra ^[30]	19.5 #
FitPrim ^[31]	4.6 #
RandCuts ^[17]	83.8 #
NormCuts ^[27]	49.4 #

5.4 本文算法限制和不足的讨论

首先, 本文算法通过三维模型特征描述符获取三维模型表面每一面片的特征向量, 然而, 由于很多特征描述符只能适用于二维流形, 包括本文算法所使用的 3 个特征描述符, 因此, 本文提出的三维形状分割算法也只能适用于二维流形。

其次, 本文算法的深度神经网络训练和测试过程都是在同类三维模型中进行的。对于分类信息未知的三维模型, 可以在本文算法之前通过三维模型分类算法, 预先获取三维模型的类别, 再选择相应的神经网络进行预测分割。

最后, 本文算法中每一类模型需要单独训练一个神经网络, 一个训练好的神经网络也只能适用于某一类三维模型。未来可以进一步研究更普适的算法, 实现一个神经网络同时对多个类别的模型进行训练, 也能对多个类别的模型进行分割。

6 结 语

本文提出一种基于权重能量分布的全监督深

度学习模型分割算法。该算法首先利用过分割减少模型数据计算量, 之后运用多种特征描述符提取模型上三角面片的特征向量, 然后通过权重能量分布对分割标签进行重新定义, 最后用深度神经网络学习分割特性。给定一个需要分割的三维模型, 提取特征向量之后输入到神经网络中预测, 之后用图割算法^[18]修整分割边缘得到更好的分割结果。实验结果表明, 本文算法的分割结果优于无监督分割算法。对比传统的全监督算法, 本文算法的分割结果也有较为明显的提升。此外, 本文提出的权重能量分布方法对类似地基于分类标签的深度神经网络训练模型也会有优化作用。

基于深度学习的算法的最大优势在于可以通过训练的方式学习特征, 之后用于快速处理海量的数据。近年来, 随着机器学习算法研究的推进和计算机硬件性能的提升, 深度学习技术在各个方面都展示出了优秀的学习能力和可扩展性。如何将它应用到更多的数字几何处理问题中以获得更好的算法结果, 是未来研究的重点。

参考文献(References):

- [1] van Kaick O, Tagliasacchi A, Sidi O, *et al.* Prior knowledge for part correspondence[J]. Computer Graphics Forum, 2011, 30(2): 553-562
- [2] Kalogerakis E, Hertzmann A, Singh K. Learning 3D mesh segmentation and labeling[J]. ACM Transactions on Graphics, 2010, 29(4): Article No.102
- [3] Rodrigues R S V, Morgado J F M, Gomes A J P. Part-based mesh segmentation: a survey[J]. Computer Graphics Forum, 2018, 37(6): 235-274
- [4] Guo K, Zou D Q, Chen X W. 3D mesh labeling via deep convolutional neural networks[J]. ACM Transactions on Graphics, 2015, 35(1): Article No.3
- [5] Xie Z G, Xu K, Liu L G, *et al.* 3D shape segmentation and la-

- beling via extreme learning machine[J]. *Computer Graphics Forum*, 2014, 33(5): 85-95
- [6] Kalogerakis E, Averkiou M, Maji S, *et al.* 3D shape segmentation with projective convolutional networks[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2017: 6630-6639
- [7] Le T, Bui G, Duan Y. A multi-view recurrent neural network for 3D mesh segmentation[J]. *Computers & Graphics*, 2017, 66: 103-112
- [8] Lv J J, Chen X L, Huang J, *et al.* Semi-supervised mesh segmentation and labeling[J]. *Computer Graphics Forum*, 2012, 31(7): 2241-2248
- [9] Bergamasco F, Albarelli A, Torsello A. Semi-supervised segmentation of 3D surfaces using a weighted graph representation[C] // *Proceedings of the 8th IAPR-TC-15 International Workshop on Graph-Based Representations in Pattern Recognition*. Heidelberg: Springer, 2011: 225-234
- [10] Wang Y H, Asafi S, van Kaick O, *et al.* Active co-analysis of a set of shapes[J]. *ACM Transactions on Graphics*, 2012, 31(6): Article No.165
- [11] Meng M, Xia J Z, Luo J, *et al.* Unsupervised co-segmentation for 3D shapes using iterative multi-label optimization[J]. *Computer-Aided Design*, 2013, 45(2): 312-320
- [12] Wu Z Z, Wang Y H, Shou R Y, *et al.* Unsupervised co-segmentation of 3D shapes via affinity aggregation spectral clustering[J]. *Computers & Graphics*, 2013, 37(6): 628-637
- [13] Sidi O, van Kaick O, Kleiman Y, *et al.* Unsupervised co-segmentation of a set of shapes via descriptor-space spectral clustering[J]. *ACM Transactions on Graphics*, 2011, 30(6): Article No.126
- [14] Shu Z Y, Qi C W, Xin S Q, *et al.* Unsupervised 3D shape segmentation and co-segmentation via deep learning[J]. *Computer Aided Geometric Design*, 2016, 43: 39-52
- [15] Wang G T, Song Q B. Automatic clustering via outward statistical testing on density metrics[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2016, 28(8): 1971-1985
- [16] Xu K, Kim V G, Huang Q X, *et al.* Data-driven shape analysis and processing[J]. *Computer Graphics Forum*, 2017, 36(1): 101-132
- [17] Golovinskiy A, Funkhouser T. Randomized cuts for 3D mesh analysis[J]. *ACM Transactions on Graphics*, 2008, 27(5): Article No.145
- [18] Boykov Y, Veksler O, Zabih R. Fast approximate energy minimization via graph cuts[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(11): 1222-1239
- [19] Hilaga M, Shinagawa Y, Kohmura T, *et al.* Topology matching for fully automatic similarity estimation of 3D shapes[C] // *Proceedings of the 28th Annual Conference on Computer Graphics and Interactive Techniques*. New York: ACM Press, 2001: 203-212
- [20] Shu Zhenyu, Qi Chengwu, Xin Shiqing, *et al.* Unsupervised 3D shape classification algorithm using density peaks[J]. *Journal of Computer-Aided Design & Computer Graphics*. 2016, 28(12): 2142-2150(in Chinese)
(舒振宇, 祁成武, 辛士庆, 等. 基于密度峰值的三维模型无监督分类算法[J]. *计算机辅助设计与图形学学报*, 2016, 28(12): 2142-2150)
- [21] Gal R, Cohen-Or D. Salient geometric features for partial shape matching and similarity[J]. *ACM Transactions on Graphics*, 2006, 25(1): 130-150
- [22] Shapira L, Shamir A, Cohen-Or D. Consistent mesh partitioning and skeletonisation using the shape diameter function[J]. *The Visual Computer*, 2008, 24(4): Article No.249
- [23] Shapira L, Shalom S, Shamir A, *et al.* Contextual part analogies in 3D objects[J]. *International Journal of Computer Vision*, 2010, 89(2/3): 309-326
- [24] Raviv D, Bronstein M M, Bronstein A M, *et al.* Volumetric heat kernel signatures[C] // *Proceedings of the ACM Workshop on 3D Object Retrieval*. New York: ACM Press, 2010: 39-44
- [25] Bronstein M M, Kokkinos I. Scale-invariant heat kernel signatures for non-rigid shape recognition[C] // *Proceedings of the 23rd IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2010: 1704-1711
- [26] Xie J, Fang Y, Zhu F, *et al.* DeepShape: deep learned shape descriptor for 3D shape matching and retrieval[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2015: 1275-1283
- [27] Chen X B, Golovinskiy A, Funkhouser T. A benchmark for 3D mesh segmentation[J]. *ACM Transactions on Graphics*, 2009, 28(3): Article No.73
- [28] Xu L. Least mean square error reconstruction principle for self-organizing neural-nets[J]. *Neural Networks*, 1993, 6(5): 627-648
- [29] van Kaick O, Fish N, Kleiman Y, *et al.* Shape segmentation by approximate convexity analysis[J]. *ACM Transactions on Graphics*, 2014, 34(1): Article No.4
- [30] Katz S, Leifman G, Tal A. Mesh segmentation using feature point and core extraction[J]. *The Visual Computer*, 2005, 21(8-10): 649-658
- [31] Attene M, Falcidieno B, Spagnuolo M. Hierarchical mesh segmentation based on fitting primitives[J]. *The Visual Computer*, 2006, 22(3): 181-193
- [32] Huang Q X, Koltun V, Guibas L. Joint shape segmentation with linear programming[J]. *ACM Transactions on Graphics*, 2011, 30(6): Article No.125