

基于图卷积网格自编码器的网格参数化

高 晨

(中国科学技术大学 数学科学学院,安徽 合肥 230026)

摘 要: 网格参数化作为数字几何处理的基本工具,在游戏娱乐、工程设计、仿真模拟等多种领域有着广泛的应用背景。传统的网格参数化方法大多通过求解线性系统或者非线性系统获得结果,存在着求解速度慢、不够鲁棒的问题。提出了一个基于图卷积网格自编码器的网格参数化模型,采用了图卷积网格自编码器的编码部分与自行构建的参数化解码部分结合的方式生成网络,使用一类人脸网格数据集作为网络训练数据,并与传统优化算法进行对比。结果表明,使用建立的网格参数化模型,在保证参数化效果的同时,获得参数化结果的速度比 SLIM(Scalable Locally Injective Mappings, SLIM)算法快 68%,比 PP(Progressive Parameterizations)算法快约 4 倍。

关键词: 网格参数化;卷积神经网络;自编码器;图卷积网格自编码器

中图分类号: TP393

文献标识码: A

DOI: 10.19358/j.issn.2096-5133.2020.10.003

引用格式: 高晨. 基于图卷积网格自编码器的网格参数化[J]. 信息技术与网络安全, 2020, 39(10): 11-17.

Mesh parameterization based on convolutional mesh autoencoders

Gao Chen

(School of Mathematical Science, University of Science and Technology of China, Hefei 230026, China)

Abstract: As a basic tool of digital geometry processing, mesh parameterization has a wide range of applications in game entertainment, engineering design, simulation and other fields. Most of the traditional meshing parameterization methods obtain results by solving linear or nonlinear systems. This article presents a mesh parameterization model based on convolutional mesh autoencoders, the network model is generated by the combination of the encoding part of a convolutional mesh autoencoders and the decoding part, and using a class of human face mesh data set as the network training data. The results show that the algorithm is more than 68 percent faster than the SLIM(Scalable Locally Injective Mappings) algorithm and more than four times faster than the PP(Progressive Parameterizations) algorithm, while the parameters of the mesh parameterization are used to ensure the parameterization effect.

Key words: mesh parameterization; convolutional neural network; autoencoders; convolutional mesh autoencoders

0 引言

网格参数化在计算机图形学与数字几何处理有着广泛的应用,例如纹理贴图、细节映射、网格编辑、网格修复、重网格化、曲面拟合等。因为三角形网格拥有着简单的几何特性,是网格曲面的一种主要表示形式,因此对于三角形网格的参数化也一直是参数化研究的热点。三角形网格的参数化是建立在流形曲面与参数域之间的一一映射,三角形网格被映射到参数域为二维平面的参数化,被称为平面参数化。

1963年, TUTTE W T^[1]提出重心映射定理,证明

了网格模型中,一个顶点的坐标可以表示为其邻接顶点坐标的加权组合,这为网格参数化提供了理论基础,基于这个定理, ECK M 等人^[2]和 FLOATER M S^[3]描述了一种简单的参数化方法,将每个内部顶点表示为其相邻顶点的凸组合。使用不同的权重设置,获得了不同的参数化,著名的权值方法有余切权值和均值权值,然而,重心坐标法要求网格的边界固定在平面上的凸多边形上,这是一种任意的办法,通常会导致明显的失真。

若三角形网格在映射前后边长发生了变化,称之为等距失真,若三角形网格在映射前后角度发生

了变化,则将其称之为共形失真。为了衡量这些失真,一些扭曲度量函数相继被提出,例如保形能量^[4]和MIPS能量^[5],它们都是为保持映射前后的角度而设计的能量;格林-拉格朗日变形能量、ARAP能量^[6],则要求映射为等距映射,保持映射前后的长度。考虑到失真度量大多是高度非线性函数,因此开始产生一些非线性的参数化方法,例如:基于角度的拍平化法^[7]及其改进方法ABF++^[8]、基于最小二乘的保角参数化^[4]、最等距参数化法^[5]、局部全局参数化方法^[6]等。

与此同时,卷积神经网络^[9]自从被提出以来,已经在计算机视觉^[10-11]、自然语言处理^[12]、语音处理^[13]等相关的大量问题中取得了最先进的结果,这得益于卷积神经网络的多尺度层次结构,使得网络模型能够学习平移不变的局部特征,但也使得卷积神经网络局限在具有欧几里得结构的数据上。为了将卷积网络应用在非欧数据上,人们开始研究基于图结构和网格结构的图卷积神经网络模型。BRUNA J等^[14]利用图拉普拉斯基与傅里叶基之间的联系,首次提出了CNNs在图上的泛化,因此产生了泛化图卷积的谱滤波器。随后,BOSCAINI D等人^[15]利用傅里叶变换在频率空间中对其进行了扩展。为了降低谱图卷积的计算复杂度,DEFERRARD M等人^[16]对这些特殊的滤波器进行了近似处理,并对其进行了特征向量的显式计算,引入了高效的操作符集合。KIPF N^[17]使用Chebyshev多项式对其进行了简化,提出了图卷积神经网络,ANURAG R^[18]等利用图卷积网络在网格上建立了图卷积网格自动编码器,提出基于网格的池化层。在此基础上,多种图卷积网络模型相继建立,并有了广泛而快速的发展。

在本文中,建立一类应用在网格上的参数化神经网络模型,针对一类人脸网格数据,根据不同的度量函数,获得相应的人脸网格参数化结果,具体如下:

(1)构建一类基于图卷积网格自动编码器的参数化网络模型,它由网格卷积层、网格上采样层、网格下采样层构建而成,其中网格卷积层由一类快速局部化的卷积滤波器组成。

(2)使用参数化网络模型,针对不同的参数化扭曲度量函数,在人脸数据集上获得相应的人脸网格参数化结果。

(3)保证参数化效果,并使用建立的图卷积网络

模型,可对人脸网格进行批量处理,更快地获得参数化结果。

1 图卷积网格自编码器

基于网格数据的图卷积自动编码器模型的建立主要依靠卷积操作的定义,来完成网格数据在网络层与层之间的传播,同时对应于图卷积网络的池化层,建立起网格上采样层与网格下采样层。

1.1 网格数据基本定义

给定一个三维网格,其网格数据形式可以表示为 $\mathcal{G}=(V,A)$,其中 $|V|=n$ 是三维欧几里得空间中网格的顶点集合, $V \in \mathbf{R}^{n \times 3}$ 。 A 则是一个 $n \times n$ 的矩阵,表示 V 中顶点之间的邻接关系,若 V 中的点 i 和点 j 之间存在一条边,则在 A 中, $A_{ij}=1$,若 V 中的点 i 和点 j 之间没有边相连,则在 A 中, $A_{ij}=0$,考虑到网格结构中点的邻接关系不会过多,矩阵 A 是一个对称稀疏邻接矩阵,描述了网格数据的拓扑信息,由邻接矩阵的性质,可以轻易地得到 V 中一个点的度, $D_{ij}=\sum A_{ij}$,即度为矩阵 A 中第 i 行的元素求和。网格上的Laplacian矩阵^[19]可以定义为 $L=D-A$,其中 D 为 $n \times n$ 对角矩阵,主对角线上元素即为 V 中点的度。

$$L_{ij} = \begin{cases} D_{ij}, & i=j \\ -1, & \text{点 } i \text{ 与点 } j \text{ 有连接关系} \\ 0, & \text{点 } i \text{ 与点 } j \text{ 无连接关系} \end{cases} \quad (1)$$

Laplacian矩阵 L 拥有良好的性质,是一个半正定堆成矩阵,因此,可以将 L 写成特征分解形式: $L=U\Lambda U^T$ 。其中 $U=[u_0, u_1, \dots, u_{n-1}]$ 是 L 的正交特征向量。 $\Lambda = \text{diag}(\lambda_0, \lambda_1, \dots, \lambda_{n-1}) \in \mathbf{R}^{n \times n}$,则是由Laplacian矩阵特征值组成的对角矩阵,其中特征值具有非负实值性质。网格数据上的傅里叶变换可以定义为 $x_\omega = U^T x$,傅里叶逆变换则为 $x = U x_\omega$ 。

1.2 网格卷积操作

网格数据上的卷积公式在傅里叶空间由如下公式定义:

$$(x * y) = U(U^T x) \odot (U^T y) \quad (2)$$

其中 x, y 为网格中的顶点, $U^T x, U^T y$ 为 x, y 对应的傅里叶变换, \odot 表示哈达马积,对于两个维度相同的向量、矩阵、张量进行对应位置的逐元素乘积运算。对于一个输入信号 x ,在网格数据上的卷积操作定义为,它和一个带有参数 θ 的滤波器 g_θ 在傅里叶空间的乘积:

$$y = \sigma(g_\theta(\mathbf{L})\mathbf{x}) = \sigma(g_\theta(\mathbf{U}\mathbf{A}\mathbf{U}^T)\mathbf{x}) = \sigma(\mathbf{U}g_\theta(\lambda)\mathbf{U}^T\mathbf{x}) \quad (3)$$

其中 $\sigma(\cdot)$ 是激活函数, $g_\theta(\lambda)$ 为对应的卷积核。这样的参数定义存在弊端如下:

- (1) 每一次参数传播, 都需要计算 \mathbf{U} 、 $g_\theta(\lambda)$ 、 \mathbf{U}^T 三者的矩阵乘积, 计算复杂度很高。
- (2) 对于每个卷积核, 都需要 n 个参数。

因此, KIPF N 等人^[17]使用切比雪夫多项式对其进行拟合, 使得卷积核可以表示为如下形式:

$$g_\theta(\mathbf{L}) = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{\mathbf{L}}) \quad (4)$$

其中 $\tilde{\mathbf{L}} = 2\mathbf{L}/\lambda_{\max} - \mathbf{I}_n$ 是缩放后的 Laplacian 矩阵。 θ_k 是对应的系数(训练中更新的参数), $T_k(\cdot)$ 是 k 阶的 Chebyshev 多项式。可由 Chebyshev 多项式递推公式获得:

$$\begin{cases} T_k(\mathbf{x}) = 2\mathbf{x}T_{k-1}(\mathbf{x}) - \mathbf{x}T_{k-2}(\mathbf{x}) \\ T_0 = 1 \\ T_1 = \mathbf{x} \end{cases} \quad (5)$$

此时卷积核可被定义为如下形式:

$$y_j = \sum_{i=1}^{\text{Fin}} g_{\theta_j}(\mathbf{L})x_i \quad x_i \in \mathbf{R}^n \quad (6)$$

y_j 是输出 $\mathbf{y} \in \mathbf{R}^{n \times \text{Fout}}$ 中的第 j 个特征, 而输入 $x_i \in \mathbf{R}^{n \times \text{Fin}}$ 拥有 Fin 个特征, 则对于一个卷积核, 其拥有 $\text{Fin} \times \text{Fout}$ 个参数, 每个卷积层拥有 $K \times \text{Fin} \times \text{Fout}$ 个参数, 其中 K 是切比雪夫多项式的阶, K 的值决定了每层卷积的作用范围, 如图 1 所示, $K=1$ 时, 卷积作用于节点的一阶邻居上, 通过卷积作用, 生成输出。通过这样的卷积核和输入数据的卷积, 可以在图数据结构或者网格数据结构的高部参数共享。

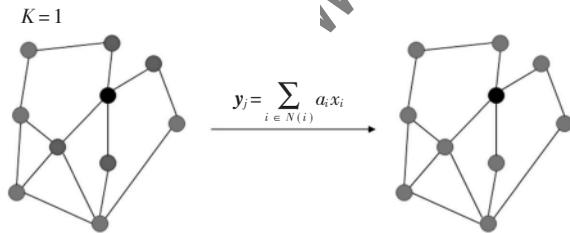


图 1 一阶图卷积示意图

1.3 网格采样操作

网格数据的采样操作包括上采样层和下采样层, 其中下采样层移除网格中的点, 以获得压缩后的网格数据, 上采样层则通过还原来恢复网格数据。

考虑网格数据, 一个拥有 n 个顶点的网格数据输入可以表示为 $n \times F$ 的形式, 其中 F 为每个顶点的

特征个数。

1.3.1 网格下采样操作

定义一个变换矩阵 $\mathbf{Q}_d \in \{0, 1\}^{m \times n}$, $n > m$ 用于完成图卷积网络中网格的下采样操作, 下采样利用二次矩阵^[20]迭代收缩顶点对, 保持曲面误差逼近。如图 2 所示, 深灰色点在下采样操作后被丢弃, 留下的浅灰色点即为收缩后的顶点子集, 记为 V_d 满足 $V_d \in V$ 。变换矩阵则可定义为: $\forall p, \mathbf{Q}_d(p, q) = 1$ 表示第 q 个顶点被保留, $\mathbf{Q}_d(p, q) = 0$ 表示第 q 个顶点在下采样操作中被丢弃。

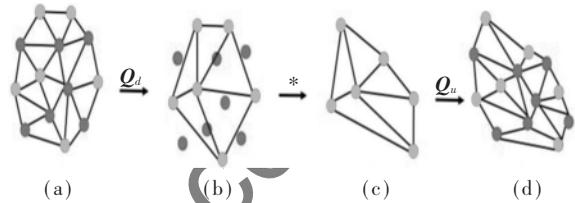


图 2 网格采样层示意图

1.3.2 网格上采样操作

定义变换矩阵 $\mathbf{Q}_u \in \{0, 1\}^{n \times m}$, $n > m$ 用于上采样操作, 为了能获得和输入数据结构一致的数据结构, 上采样操作矩阵是在下采样操作中同时建立的。如图 3 所示, 下采样后保留的顶点进行相应的卷积变换, 获得输出网格数据, 这些在下采样中被保留的顶点依旧在上采样中被保留, 即有 $\mathbf{Q}_u(q, p) = 1$, 当 $\mathbf{Q}_d(p, q) = 1$ 。而对于那些在下采样操作中被丢弃的顶点, $V_q \in V$, 即满足 $\forall p, \mathbf{Q}_d(p, q) = 1$ 的点的集合, 在做下采样操作时考虑其所对应的重心坐标, 即在下采样网格中, 将 V_q 中的点 v_q 投影到其相近的三

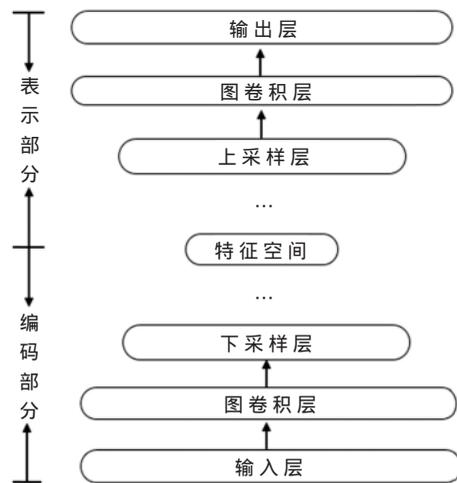


图 3 参数化网格模型示意图

角形 (i, j, k) 中, 投影后的点用 \tilde{v}_q 表示, 由重心坐标性质有 $\tilde{v}_q = \omega_i \mathbf{v}_i + \omega_j \mathbf{v}_j + \omega_k \mathbf{v}_k$, 其中 $\mathbf{v}_i, \mathbf{v}_j, \mathbf{v}_k \in V_d$, 并满足 $\omega_i + \omega_j + \omega_k = 1$ 。则在对应的上采样矩阵 Q_u 中, 可定义 $Q_u(q, i) = \omega_i, Q_u(q, j) = \omega_j, Q_u(q, k) = \omega_k$, 并有 $Q_u(q, l) = 0, \forall l \neq i, j, k$ 。故由此可得对应于下采样操作矩阵 Q_d 和下采样操作后的顶点集合 V_d 的上采样操作矩阵 Q_u , 同时, 上采样后的顶点集合 V_u 可以由 $V_u = Q_u V_d$ 给出。

2 搭建参数化网格模型

2.1 网络搭建

基于图卷积网格自编码器的参数化网格模型以图卷积神经网络为基本单元, 首先获得输入网格数据的坐标信息, 网络的拓扑连接关系则蕴含在神经网络的卷积中, 通过 Laplacian 矩阵保证网络的拓扑结构不变。网络的前半段为图卷积网格自编码器的编码部分, 通过网格卷积层与网格下采样层, 在潜在空间里学习到输入数据的特征信息, 后半段则为自行建立参数化解码过程, 以网格卷积层与网格上采样层组成, 并通过一次额外卷积层获得输出。与自编码器不同, 通过解码直接得出输入数据的参数化表示。当训练完成后, 得到的参数化网格模型相当于网格参数化过程。如图 3 所示, 首先对输入数据进行一次卷积操作, 之后每一个矩阵块之间均代表着一次卷积操作与网格下采样操作, 下采样尺度为 2, 交替多次进行, 在潜在空间学习到特征信息后, 再交替多次进行网格上采样操作与卷积操作, 最后由一层卷积层构成整个网络。

2.2 数据集获取

本文中使用的数据集由文献[18]中的数据集裁剪而成, 共有 20 465 个人脸三角网格, 其中每个三角网格有 2 105 个点, 4 148 个面。按照 10:1 的比例划分训练集与测试集, 训练集有 18 415 个网格数据, 测试集有 2 050 个网格数据。其中训练集中分出 1 000 个数据作为训练中的验证集。图 4 给出数据

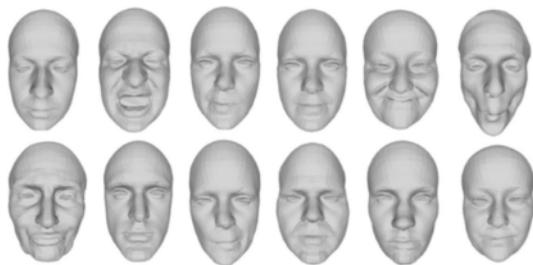


图 4 人脸数据集示例图

集中的一些数据集中的人脸数据。本文中 will 使用此人脸数据集作为构造的基于图卷积网格自动编码器的参数化网格模型的输入。同时, 利用一个 C++ 中的几何处理库, libigl 库中的 SLIM (Scalable Locally Injective Mappings) 算法^[21]对原始数据集做基于对称 Dirichlet 能量函数的参数化, 并将参数化结果作为网络中的标签进行训练, 随后和本文中所使用的参数化网络模型的输出做对比。

2.3 模型调优

2.3.1 Dropout 与正则化

Dropout 可以作为训练深度神经网络的一种防止过拟合的方法供选择。在每个批量训练中, 通过忽略一定比例的的特征节点 (即让一定比例的隐层节点值取为 0), 可以明显地减少过拟合现象。这种方式可以减少隐层节点之间的相互作用。网络工作流程如下:

(1) 以概率 p 随机地删除掉卷积网络中隐层的神经元, 其中保持输入输出神经元保持不变 (即将神经元经激活函数的输出值置为 0)。

(2) 使得输入数据通过修改后的卷积网络前向传播, 得到的输出再进行反向传播。每次批量的训练样本在执行此过程之后, 在剩余的神经元上 (即没有被删除的部分) 按照随机梯度下降法或者其他参数更新方法更新对应的参数。

(3) 恢复那些在第一步中被删除的神经元, 然后从隐层神经元中再随机以概率 p 选取一个节点集合, 将其删除掉。对小批量训练数据, 继续前向传播与网络反向传播, 并通过随机梯度下降法更新对应的参数。

防止网络过拟合的方法还有正则化方法, 即对损失函数添加惩罚项。所谓惩罚是指对损失函数中的某些参数做一些限制。常用的正则化有 L1 正则化和 L2 正则化。

在本文所采用的网络模型中, 使用了 dropout 方法, 其中 drop 概率设置为 0.9 (保留参数概率), 同时使用 L2 正则化, 使网络模型中的权值参数值尽可能小, 提高网络模型的抗扰动能力。

2.3.2 超参数优化

本文建立的参数化网络模型有两个重要的超参数, 一个为网络深度 (即网络的隐藏层个数), 在本文中, 并不直接使用隐藏层个数作为网络深度的定义, 而是考虑到建立的参数化网络模型中卷积

层与采样层交替的形式,与网格下采样层与上采样层一一对应的关系,本文分别测试了网络深度为 2、3、4、5 时损失函数的下降趋势。此外,另一个极为重要的参数为 K 值, K 值是卷积层中使用的切比雪夫多项式的阶数,在网络传播中关系到一个节点的 K 阶邻居。为此,本文分别选取 $K=1, 2, 3$ 做实验对比,结论如图 5 所示。网络中 `batchsize` 设置为 16,每经过 200 次训练输出一次损失函数,记为一次 step,图中给出了每个网络前 200 step 所对应的验证集的损失函数,可以看出不论 K 为多少,深度为 2 和 3 时的网络训练效果不如网络深度为 4 和 5 时的网络,而 $K=1$ 时的网络也没有 $K=2, 3$ 时的网络效果好,但当网络深度设置过深时,训练速度会变得缓慢,因此综合训练效果与时间上的考虑,本文中的网络深度取 4,并令 K 值取 2。

通过构建模型与参数调优,最终得到应用于人

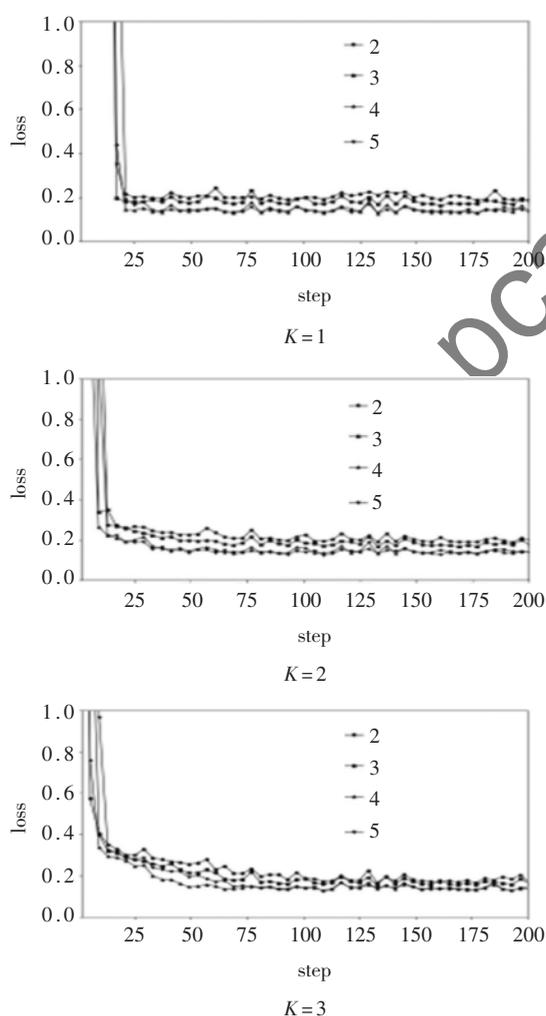


图 5 不同超参数对比图

脸数据集上的基于图卷积网格自编码器的参数化网络模型,在表 1 中,列出了网络模型具体的层参数,可以看出,网络在编码部分与参数化表示部分均经过了 4 次下采样与 4 次上采样,同时在卷积过程中,设置卷积核的 K 值为 2,并在编码过程中,依次采用了 16、16、32、64 个卷积核,在参数化表示过程中,依次采用了 64、32、16、16 个卷积核。多个卷积核表示使得网络可以学习到尽可能多的特征表示。

表 1 参数化网络模型具体层参数

Layer	Input	Output
Convolution	2 105×3	2 105×16
Down-sampling	2 105×16	1 053×16
Convolution	1 053×16	1 053×16
Down-sampling	1 053×16	526×16
Convolution	526×16	526×32
Down-sampling	526×32	263×32
Convolution	263×32	263×64
Down-sampling	263×64	132×64
Convolution	132×64	132×64
Up-sampling	132×64	263×64
Convolution	263×64	263×32
Up-sampling	263×32	526×32
Convolution	526×32	526×16
Up-sampling	526×16	1 053×16
Convolution	1 053×16	1 053×16
Up-sampling	1 053×16	2 105×16
Convolution	2 105×16	2 105×2

3 实验分析

本文人脸数据集测试集内共有 2 050 个数据,从中随机抽取了 5 例数据,与经典参数化方法进行了对比,对比结果如图 6 所示,本文实验在基于 TensorFlow 深度学习框架的 Ubuntu 系统下进行。网络初始学习率设置为 0.008,优化时学习率采用了学习率指数衰减的方法,即学习率随着训练次数的增加而逐渐衰减,衰减步数为 1 000,衰减率为 0.95。同时为了加快网络收敛速度,网络中动量设置为 0.9。选定 L1 损失函数为网络优化目标函数,并使用小批量随机梯度下降算法进行训练,其中 `Batchsize` 设置为 16。

图 6 展示了网络模型与 PP^[22]算法在参数化结果上的效果对比,图中第一列为原始人脸网格,第二列是 PP 算法的参数化结果,第三列为网络模型算

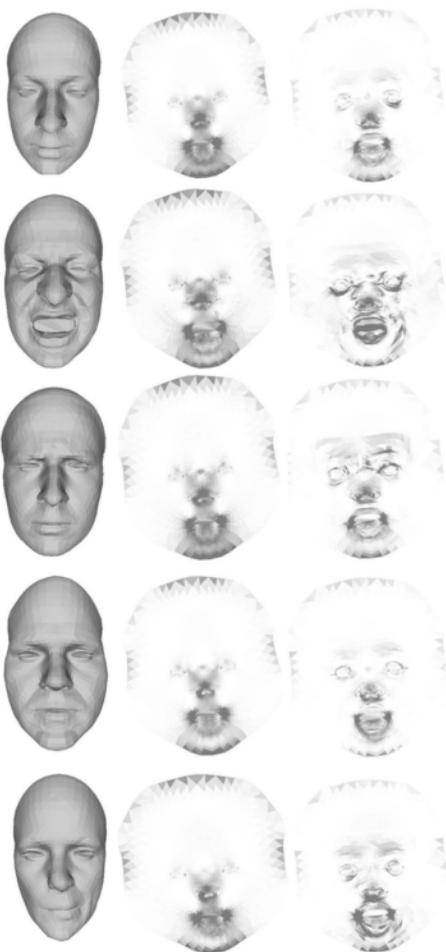


图 6 参数化结果示意图

法的参数化结果。图中颜色表示对应三角形面上的度量损失,在这里,均对参数化结果做了对称 Dirichlet 度量函数的计算,从图中可以看出,网络模型取得了非常不错的参数化效果。相比较 PP 算法在部分区域陷入局部解的情况,网络模型表现更好。

除此之外,在本文中给出了网络模型与 PP 算法、SLIM 算法之间的参数化时间对比,结果见表 2。可以看出,基于 PP 算法的参数化处理单个网格平均用时为 1.009 s,基于 SLIM 算法的参数化处理单个网格平均用时为 0.382 6 s,但基于图卷积网络的参数化处理单个用时只需 0.227 1 s。相比 PP 算法和

表 2 参数化算法运行时间比较

算法	单个网格运行时间/s	测试集运行时间/s
PP	1.009	2 068.45
SLIM	0.382 6	784.33
本文	0.227 1	4.619 7

SLIM 算法的顺序处理,本文建立的参数化网络模型可以对数据集进行批量处理,并拥有极高的效率,处理全部测试集(共 2 050 个网格数据)仅需 4.619 7 s。

4 结论

当前,网格参数化已经取得了极为丰富的理论成果和应用技术,大多参数化方法都采用算法迭代求解非线性系统的方法,在本文中,设计了一类基于图卷积网络自编码器的参数化网络模型,并针对构造的人脸数据集进行了参数化处理。深度学习方法的引入,对于网格参数化而言是一个全新的思考方向。针对网格数据,图卷积网络展现了其强大的特征提取和表达能力,同时从参数化结果来看,也展现了构建的参数化网络模型的鲁棒性与快速处理能力,同时在需要批量处理参数化的应用中,网络模型展现了高效的应用能力。

参考文献

- [1] TUTTE W T. How to draw a graph[J]. Proceedings of the London Mathematical Society, 1963(1): 743-767.
- [2] ECK M. Multiresolution analysis of arbitrary meshes[J]. ACM SIGGRAPH Computer Graphics, 1995(95): 173-182.
- [3] FLOATER M S. Parameterization and smooth approximation of surface triangulations[J]. Computer Aided Geometry Design, 1997(3): 231-250.
- [4] LEVY B, PETITJEAN S, RAY N, et al. Least squares conformal maps for automatic texture atlas generation[J]. ACM Transactions on Graphics, 2002, 21(3): 362-371.
- [5] HORMANN K, GREINER G. MIPS: an efficient global parametrization method[M]. Curve and Surface Design, Tennessee: Vanderbilt University Press, 1999.
- [6] GOTSMAN C, LIU L, ZHANG L, et al. A local/global approach to mesh parameterization[M]. John Wiley & Sons, 2008.
- [7] SHEFFER A, DE STURLER E. Parameterization of faceted surfaces for meshing using angle-based flattening[J]. Engineering with Computers, 2001, 17(3): 326-337.
- [8] SHEFFER A, LEVY B, MOGILNITSKY M, et al. ABF++: fast and robust angle based flattening[J]. ACM Transactions on Graphics, 2005, 24(2): 311-330.
- [9] LECUN Y. Generalization and network design strategies[C]. Connectionism in Perspective. Elsevier, 1989.

- [10] LECUN Y, KAVUKCUOGLU K, CLEMENT F. Convolutional networks and applications in vision[C]. International Symposium on Circuits & Systems. IEEE, 2010.
- [11] CIRESAN D, MEIER U, MASCI J, et al. A committee of neural networks for traffic sign classification[C]. International Joint Conference on Neural Networks. IEEE, 2011.
- [12] KE Y, HAGIWARA M. Alleviating overfitting for polysemous words for word representation estimation using lexicons[C]. International Joint Conference on Neural Networks. IEEE, 2017.
- [13] GRAVES A, MOHAMED A R, HINTON G. Speech recognition with deep recurrent neural networks[C]. IEEE International Conference on Acoustics. IEEE, 2013.
- [14] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and deep locally connected networks on graphs[J]. Computer ENCE, 2013.
- [15] BOSCAINI D, MASCI J, EMANUELE R, et al. Learning shape correspondence with anisotropic convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2016 : 3189–3197.
- [16] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering[J]. Advances in Neural Information Processing Systems, 2016 : 3844–3852.
- [17] KIPFT N, WELLING M. Semi-supervised classification with graph convolutional networks[C]. International Conference on Learning Representations, 2017.
- [18] ANURAG R, TIMO B, Michael J B. Convolutional mesh autoencoders for 3d face representation[C]. ECCV, 2018.
- [19] CHUNG F R K. Spectral graph theory[J]. American Mathematical Society, 1997.
- [20] GARLAND M, HECKBERT P S. Surface simplification using quadric error metrics[J]. ACM SIGGRAPH Computer Graphics, 1997 : 209–216.
- [21] RABINOVICH M, PORANNE R, PANOZZO D, et al. Scalable locally injective mappings[J]. ACM Transactions on Graphics, 2017, 36(2) : 1–16.
- [22] LIGANG L, CHUNYANG Y, RUIQI N, et al. Progressive parameterizations[J]. ACM Transactions on Graphics, 2018, 37(4) : 1–12.

(收稿日期: 2020-07-24)

作者简介:

高晨(1996-), 通信作者, 女, 硕士, 主要研究方向: 计算机图形学、深度学习。E-mail: gaochen@mail.ustc.edu.cn。

(上接第 10 页)

- et al. Design, aerodynamics, and vision-based control of the delfly[J]. International Journal of Micro Air Vehicles, 2009, 1(2) : 71–97.
- [13] 曾锐, 昂海松. 仿鸟复合振动的扑翼气动分析[J]. 南京航空航天大学学报, 2003, 35(1) : 6–12.
- [14] 蔡常睿. 基于信鸽翅膀的仿生机翼气动性能研究[D]. 长春: 吉林大学, 2018.
- [15] 郑焕魁. 微型飞行器新式局部翼面运动翼型气动特性研究[D]. 上海: 华东理工大学, 2015.

- [16] 吴海宇. 仿生微型飞行器的设计与测试实验的研究[D]. 长春: 吉林大学, 2019.

(收稿日期: 2020-03-30)

作者简介:

徐韦佳(1989-), 女, 硕士, 讲师, 主要研究方向: 电子与通信工程。

姚奎(1972-), 男, 硕士, 教授, 主要研究方向: 数学教育与管理。

宋阿羚(1979-), 男, 硕士, 讲师, 主要研究方向: 通信工程。

版权声明

经作者授权，本论文版权和信息网络传播权归属于《信息技术与网络安全》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、JST日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《信息技术与网络安全》编辑部
中国电子信息产业集团有限公司第六研究所