

# 支持向量学习机在点云去噪中的应用

张 琴<sup>1</sup>, 蔡 勇<sup>2</sup>

(1. 西南科技大学 计算机科学与技术学院, 四川 绵阳 621000;

2. 西南科技大学 制造科学与工程学院, 四川 绵阳 621000)

**摘 要:**在解决非线性、高维模式识别以及小样本等问题中,支持向量机表现出许多独有的优势。提出将支持向量机学习分类方法应用于点云去噪中,能够稳定地进行机器学习,训练得到判别模型,快速、准确地识别出噪声点与非噪声点。通过对小样本数据的统计学习,能够推广到大规模数据中去进行结果的预测估计。用SVM对点云数据样本进行学习训练、测试,识别分类,从而达到去噪光顺的目的。实验表明,此方法在有效去除噪声的同时能较完整地保留点云数据信息。

**关键词:**点云;支持向量机;去噪;分类

**中图分类号:**TP181

**文献标识码:**A

**文章编号:**1673-629X(2011)06-0085-04

## Application of Support Vector Machine in Point Clouds Denoising

ZHANG Qin<sup>1</sup>, CAI Yong<sup>2</sup>

(1. Institute of Computer Science and Technology, Southwest University of Science and Technology,  
Mianyang 621000, China;

2. Institute of Manufacturing Science and Engineering, Southwest University of Science and Technology,  
Mianyang 621000, China)

**Abstract:**SVM represented many unique advantages in many applications, such as solving the problem of nonlinear, high dimension pattern recognition and small sample problem. A method was promoted in this paper. It was removing point clouds using SVM sorting technique. It could be generalized to test and estimate the big scale data by training the small sample. SVM classification method was used to train, test, classify the point clouds data sample, so that it could achieve to the goal of denoising. The experiment showed that this method could remove the noise effectively while preserving the point clouds information relative completely.

**Key words:**point clouds;support vector machine;denoising;classify

## 0 引 言

一直以来,三维网格模型都是作为主流研究对象来进行一系列网格化的数字处理,随着点云数据模型的出现,由于其数据获取方便、数据结构简单等优点,现已成为计算机图形学中又一研究热点<sup>[1]</sup>。

点云数据一般是使用各种三维数据采集设备得到的空间上离散的海量几何点,这些点是由物体模型表面上一系列空间采样点构成的<sup>[2]</sup>。三维物体数据测量实际上就是获取物体模型表面轮廓上离散点的三维几何坐标数据信息,从而将真实物体模型的整体几何形状数字化。海量点云数据最基本的单位是单个孤立的点,有些三维数据采集设备在获取数据信息的同时还

会得出与之相关的一些简单的物体表面属性。点云中每一个离散点都包含有三维坐标、大小和法向量等相应的几何信息,而更复杂的物体会带有诸如纹理、光照参数和透明度等其它表面属性。然而,在三维点云数据获取的过程中,扫描环境、光照等一些不可避免的影响因素,使得采样的数据会受到噪声的污染。除此之外,不同的三维扫描设备其自身也会存在不同的局限,如设备精度、扫描速度等,以及一些人为干扰因素和被测物体表面材质等的影响,从而使得采集到的三维点云数据往往带有许多小振幅噪声和离群点<sup>[3,4]</sup>。噪声的产生是无法避免的,正因为噪声的存在使得对后续建模中的曲面重建以及实体重构等也造成了一定障碍,若不及时处理,而后重建的模型会变得粗糙零乱甚至变形。因此,为了给后续处理工作创造一个良好的基础,在对扫描设备采集到的三维点云数据进行曲面重构之前必须对其进行光顺去噪等预处理。点云去噪工作是三维重建中最为首要,也是最为关键的一个部分。

收稿日期:2010-11-19;修回日期:2011-02-23

基金项目:国家自然科学基金项目(10576027)

作者简介:张 琴(1985-),女,硕士,研究方向为计算机图形图像处理、反求工程;蔡 勇,博士,教授,研究方向为计算机图形学、智能控制等。

## 1 相关研究及分析

相对于三维网格模型来说,应用到三维点云数据去噪的方法还不是很多。三维点云数据又分为有序点云、部分有序点云以及无序无组织点云数据。然而,对于不同类型的点云数据有着相对应合适的去噪方法。对于有序或者部分有序的点云数据来说,可以采用的去噪算法有:最小二乘滤波、卡尔曼滤波和平滑滤波<sup>[5]</sup>等。针对于无序无结构的散乱点云数据,许多相关学者也进行了深入的研究,提出了拉普拉斯(Laplacian)算子、平均曲率流、移动最小二次曲面等方法<sup>[6]</sup>。

Pauly 等人<sup>[7]</sup>将 Laplacian 算子应用到点模型上,主要通过一致扩散高频几何噪声达到光顺目的,算法较为简单,但该算法会出现特征被磨光的情况,且由于点不在法向方向进行移动容易产生顶点漂移及过光顺,网格的体积便快速收缩,从而使模型变得模糊,凹凸特征不明显。Bayesian 方法非常流行,然而在三维模型的降噪和重建研究中,该方法的应用也不是非常成熟,文献[8]的方法不仅平滑了噪声,而且强化了模型的特征,但研究发现,对于一些细节特征非常丰富的复杂模型,此算法过度强化了尖锐特征部分。Alexa<sup>[9]</sup>采用 MLS(Moving Least-Squares, 移动最小二乘)曲面来逼近原始点集模型,然后将点移到其对应的曲面上去除噪声,但该方法效率不是很高。

然而,支持向量机,是针对小样本统计问题而建立的,追求在现有有限信息的条件下得到最优结果。由于统计学习理论和支持向量机建立了一套较好的有限样本下机器学习的理论框架和通用方法,既有严格的理论基础,又能较好地解决小样本、非线性、高维数和局部极小点等实际问题,因此成为九十年代末发展最快的研究方向之一<sup>[10]</sup>。此算法是在学习精度与学习能力之间找寻其最佳折衷,从而获得最好的推广泛化能力(Generalization Ability),其优点:专门针对有限样本数据,得到小范围下的最优解,而不仅是在趋于无穷大的范围下求得的最优解;算法将求解最优分类面问题转化为求解凸二次规划问题<sup>[11]</sup>,理论上,由此求得的就是全局的最优解,从而解决了局部极值问题,而这一问题是神经网络方法无法避免的;此外,通过适当选择函数子集及该子集中的判别函数使学习机的实际风险达到最小,通过非线性变换把低维特征空间转换到高维的特征空间(Feature Space),由此可解决原空间中的一些非线性问题<sup>[12]</sup>。SVM 独有的特点能保证其最优分类能力及推广泛化能力,同时也巧妙地解决了维数问题。

基于支持向量机的众多优点,文中提出将支持向量机的分类算法运用于对三维点云数据的去噪研究,即就是把带噪声的点云数据的噪声点和非噪声点区别

开来,从而识别出噪声,予以剔除。此算法是直接三维空间对点云数据进行相应处理,绕过了繁琐的曲面拟合重建等复杂费时的过程,支持向量机(Support Vector Machine or SVM)能够快速、准确地进行学习预测,其分类算法在点云去噪中能得到很好的应用。

## 2 支持向量分类机

最优分类的目的就是寻找到最大超平面,以最大限度地不同的两个类别分开,为了计算上的方便,取目标函数为  $\frac{1}{2} \|W\|^2$ , 求其最小值。对于任意学习样本  $(X_i, y_i)$ , 其分布必然在直线  $l_1$  之上或直线  $l_2$  以下。则有如下表达式:

$$\begin{aligned} g(X_i) &= \langle W \cdot X_i \rangle + b \geq 1; y_i = 1, X_i \in C_1 \\ g(X_i) &= \langle W \cdot X_i \rangle + b \leq -1; y_i = -1, X_i \in C_2 \end{aligned} \quad (1)$$

上式又可表示如下:

$$y_i \cdot [\langle W \cdot X_i \rangle + b] \geq 1 \quad (2)$$

约束条件也就是为了保证每个学习样本都能够被正确分类,不允许任何错误偏差出现,然而达到百分之百的分类正确率并不容易,于是放松约束条件,引入了松弛变量  $\xi$ 。也就是说没有前面条件那么硬,不需要所有的学习样本都满足约束条件,具有一定范围的容错能力。松弛变量  $\xi$  也不能太放任它,应尽量避免松弛变量太大,因此需要对松弛变量进行一定的惩罚,即便引入惩罚因子  $C$ 。则表示成为一个约束优化问题,即二次优化问题如下所示:

$$\begin{aligned} \min_{w, b, \xi} \quad & \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i \quad C > 0 \\ \text{subject to} \quad & y_i (\langle W^T \cdot X_i \rangle + b) \geq 1 - \xi_i \\ & \xi_i \geq 0, \quad i = 1, \dots, N \end{aligned} \quad (3)$$

(3) 式中,  $\{(X_i, y_i)\}_{i=1}^N$  是用于参加训练的样本,其中  $X_i \in R^D$  是特征矢量,  $y_i \in \{1, -1\}$  是  $X_i$  的归属类别值,  $y_i = 1$  表示  $X_i$  属于  $C_1$  类,  $y_i = -1$  表示  $X_i$  属于  $C_2$  类。

目标函数是一个最大化分类间隔和最小化训练误差的双目标优化问题。此二次规划问题是凸优化问题,由于目标函数和约束条件都是凸的,根据最优化理论,这一问题存在唯一全局最小解。满足对偶性条件,可以转化为拉格朗日(Lagrange)问题, Lagrange 乘子为  $A = (a_1, a_2, \dots, a_N)^T$ , (3) 式转化为拉格朗日函数如下:

$$\begin{aligned} L(W, b, \xi, A) = \quad & \frac{1}{2} W^T W + C \sum_{i=1}^N \xi_i - \\ & \sum_{i=1}^N a_i [y_i (\langle W^T \cdot X_i \rangle + b) - 1 + \xi_i] \end{aligned} \quad (4)$$

(4) 式中,  $a_i \geq 0$ , 对偶表示可以通过求对应于  $W$ ,

$\xi, b$  的偏导, 置零计算获得, 如下所示:

$$\frac{\partial L(W, b, \xi, A)}{\partial W} = W - \sum_{i=1}^N y_i a_i X_i = 0 \quad (5)$$

$$\frac{\partial L(W, b, \xi, A)}{\partial b} = \sum_{i=1}^N y_i a_i = 0 \quad (6)$$

$$\frac{\partial L(W, b, \xi, A)}{\partial \xi_i} = C - a_i = 0 \quad (7)$$

将(5)、(6)、(7)式代入(4)式得到对偶目标函数修正如下:

$$L(W, b, \xi, A) = \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j a_i a_j \langle X_i \cdot X_j \rangle \quad (8)$$

$$\max_{a_i} \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j a_i a_j \langle X_i \cdot X_j \rangle$$

subject to  $0 \leq a_i \leq C$  (9)

$$\sum_{i=1}^N a_i y_i = 0 \quad i = 1, \dots, N$$

$a_i \neq C$  时, 松弛变量  $\xi_i$  为零; 而仅当  $a_i = C$  时松弛变量  $\xi_i$  不为零。Karush-Kuhn-Tucke 互补条件如下:

$$a_i [y_i (\langle W^T \cdot X_i \rangle + b) - 1 + \xi_i] = 0$$

$$a_i \geq 0 \quad (10)$$

$$\xi_i (C - a_i) = 0 \quad i = 1, \dots, N$$

利用 KKT 互补条件, 对(8)式对应于  $a_i$  求偏导, 相继求得 Lagrange 乘子、 $W$  以及  $b$ , 从而可以得到决策分类函数:

$$g(X_i) = \sum_{i=1}^N a_i y_i \langle X_i \cdot X_j \rangle + b \quad (11)$$

### 3 非线性分类

非线性分类问题就是说在原样本空间中无法直接利用线性的支持向量机来训练样本, 以至于无法分类, 即为线性不可分。为了解决这种线性不可分的问题, 就需要进行一些变换, 即就相当于一个非线性变换:  $\Phi: R^D \rightarrow H$ 。也就是一个空间映射过程, 从原来样本的  $D$  维空间映射到一个高维的特征空间  $H$ 。在这个高维空间  $H$  中就可以寻找到最优分类超平面, 从而得到相应的分类判定函数。这样就把一个不可分的分类问题变成了线性可分, 并且引入核函数来解决高维空间维数过高而计算困难的问题。核函数方法可以把高维特征空间中的内积运算转化为低维训练样本空间的函数来运算, 从而使运算简便、高效。如下所示:

$$\varphi(X_i) \cdot \varphi(X_j) = K(X_i, X_j) \quad (12)$$

则(8)式可以写为:

$$L(W, b, \xi, A) = \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j a_i a_j K(X_i \cdot X_j) \quad (13)$$

### 4 训练样本确定

由于支持向量机主要针对于小样本数据来进行训练学习, 使用少量的数据信息得到最优的结果, 其优势也在于此。小样本数据投入支持向量分类器中, 其计算快速, 分类识别能力高。然而, 对于大规模的数据来说, 其整体的运行速度急剧下降。为了解决这个问题, 文中引入了包围盒技术, 先对应包围盒训练得到相应支持向量, 然后从中选出部分支持向量作为样本, 再次训练出适合于全局的预测模型。

首先把读入的三维点云数据进行包围盒技术的分解。在整个点云数据中分别搜索到  $x, y, z$  方向上的最小、最大值, 构成最小点  $P_{\min}(X_{\min}, Y_{\min}, Z_{\min})$ , 最大点  $P_{\max}(X_{\max}, Y_{\max}, Z_{\max})$ , 从而得到所有点云范围的包围盒。包围盒栅格的宽度通过交互式输入。接着, 对划分好的每一个小栅格里面所包含的点云数据分别进行学习训练, 得到相应的支持向量。然后取出每个栅格支持向量的半数, 作为整体训练所需要的样本数据。这样, 就大大减小了训练样本, 同时使用支持向量来作为样本选择, 对获得最优训练结果有很大促进作用。

表1所用核函数为径向基核函数, 包围盒划分宽度  $d = 0.1$ , 参数  $C = 2, \gamma = 2$ 。

表1 不同样本训练情况比较

青铜人 面像	训练样 本点数	支持向量	训练、预测 总耗时
原样本	142,341	15579	57.2(min)
缩小样本	4719	529	41.609(s)

### 5 实验与结果

#### 5.1 核函数选择

目前几种常用核函数:

a. 多项式核函数:

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d$$

b. 径向基核函数:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$$

c. sigmoid 核函数:

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$$

文中所使用点云数据是用三维激光扫描仪采集得到, 样本训练数据集为:

$$D = \{(X_i, y_i) \mid X_i \in R^3, y_i \in \{-1, 1\}, i = 1, \dots, N\}$$

分别采用以上三种核函数构成不同的支持向量分类机,  $X_i$  作为输入, 针对不同样本进行学习训练、测试, 表2所示其比较结果(参数:  $C = 2, \gamma = 2, d = 2, r = 2$ )。

如表2所示, 相同的参数情况下, 三种不同的核函数对应于不同的训练样本, 其训练测试效果还是有所差异。可以看出, 多项式核函数相对于其它两个核函

数,其用时是相对较短的,但参数数量最多,然而,核函数性能好坏主要决定于参数的选择,参数越多,就越不容易找到核函数最佳状态。其中,RBF 核函数性能是比较适中的,稳定性较好,也是应用最为广泛的核函数。并且 RBF 核函数能够实现非线性的映射,其参数数量最少,易于运算。经过综合考虑,文中选择 RBF 核函数。

表 2 不同核函数对不同样本的训练结果比较

训练样本集 (点数)	核函数	总耗时 (ms)	准确率 (百分比)
253	多项式	953	97.6285
	径向基	1079	
	Sigmoid	1093	
1260	多项式	843	94.3651
	径向基	1328	
	Sigmoid	1375	
5130	多项式	4266	94.2690
	径向基	5219	
	Sigmoid	6406	

## 5.2 参数选择

然而参数  $C$  和  $\gamma$  直接影响着训练的结果,决定着能否得到具有很好推广能力的分类判定函数。 $C$  的取值小表示对经验误差的惩罚小,学习训练机的复杂度小而经验风险值较大;反之  $C$  的取值大,学习训练机的经验风险值小而复杂度较大。因此,确定参数  $(C, \gamma)$  的取值显得尤为重要。文中选择交叉验证(cross-validation)的方法来计算比较出最佳的参数值。

交叉验证的过程为:将训练样本集随机地近似平均地划分为  $K$  个子集合,依次从每个子集合开始,拿其中的  $K-1$  个子集合来进行训练,得到一个决策判定函数,然后用此决策函数对剩下的那个子集合的样本进行测试。重复  $K$  次循环过程,计算出训练测试的准确率。不同参数组通过交叉验证,取其使得准确率最高的参数对  $(C, \gamma)$ 。 $C$  与  $\gamma$  参数对的选择基本是凭经验,对于不同的核函数,不同的训练样本,其选择的方法也都有所不同。这就需要多次反复试验,从而选出所需的最佳参数。

运用最佳参数训练样本数据,得到训练模型,利用这个模型对同类点云数据进行预测估计,对每一个数据点进行识别,判定其所属类别,修改该点所对应的类别信息,最后进行三维实体重绘。即就是把正确分好类的的数据点依次进行辨别输出,如果该点所属类别为正类  $y_i = 1$ ,则此点是非噪声点;反之,  $y_i = -1$  该点所属类别为负类。属于负类的点则为噪声点,予以去除。最后输出非噪声点云数据到三维显示平台。

表 3 所使用的数据是青铜人面像(142341 点)。图 1 和图 2 分别为原点云数据和 SVM 的点云去噪效

果。

表 3 参数选择情况(栅格宽=0.1)

参数 $(C, \gamma)$	准确率(百分比)	总耗时(ms)
$(C=2, \gamma=2)$	99.189271	6687
$(C=2, \gamma=10)$	99.298164	4437
$(C=2, \gamma=50)$	99.471691	6610
$(C=2, \gamma=100)$	99.568642	5141
$(C=2, \gamma=200)$	99.708447	5797
$(C=2, \gamma=300)$	99.791346	5125
$(C=2, \gamma=500)$	99.863708	8891
$(C=10, \gamma=2)$	99.291841	8687
$(C=50, \gamma=2)$	99.435862	10329
$(C=100, \gamma=2)$	99.489957	10719
$(C=200, \gamma=2)$	99.527192	10547
$(C=300, \gamma=2)$	99.552483	10453
$(C=500, \gamma=2)$	99.579882	12953




图 1 原点云数据



图 2 SVM 的点云去噪效果

## 6 结束语

文中运用支持向量机分类方法,对点云数据进行去噪滤波处理,使用 Visual C++ 和 OpenGL<sup>[13]</sup> 工具来实现文中算法的实验研究。首先需要已经分好类别的样本集,用此样本集来进行训练,这样才能得到比较理想的训练模型。而后就可以运用这个模型来对同样带噪声的点云数据集进行预测分类。实验表明,SVM 分类算法存在全局优化,是鲁棒的,同时通过对训练样本选择的缩小,使得点云去噪能够更加高效的实现,特别是对小样本数据的应用。(下转第 94 页)

&lt;/Package&gt;

## 5 结束语

文中将 MDA 的开发思想导入 workflow 系统的开发中来,提出基于 MDA 的 workflow 管理系统开发架构。基本上,流程的 PIM 模型可视为流程模型与 workflow 实现平台模型间的中介模型,它具体化了流程模型中的抽象概念,同时也省略了不同实现平台间的差异化特征。

在目前的研究中仅提出了初步的架构来验证 MDA 开发 workflow 的可行性,在以后的研究中希望从以下几点改进:

①在 workflow PIM 的设计方面,由于仅参考了 WfMC 的参考模型,难免会有遗漏或不足之处,希望能改善 workflow PIM 模型的设计,使其更能符合不同领域对企业流程建模的需求。

②针对模型转换部分,目前仅以 BSF 的环境撰写模型转换程序的 script,在转换程序的撰写上感觉缺乏弹性且不够方便,希望能开发流程模型转换的框架与工具集来辅助模型转换规则的开发人员建立 workflow PIM to PSM 与 PSM to PIM 的转换程序。

③建立 workflow 模型的验证机制与程序来协助流程开发人员验证 workflow PIM 模型以及转换出的 PSM 模型的正确性。

希望通过以上的改进,改善目前 MDA 的 workflow 架构的设计,更加贴近企业在工作流程上的需求。

### 参考文献:

[1] Hollingsworth D. The Workflow Reference Mode[EB/OL].

(上接第 88 页)

### 参考文献:

- [1] 王仁芳. 点模型数字几何处理若干技术研究[D]. 杭州: 浙江大学, 2007.
- [2] 刘立国. 点云模型的光顺去噪研究[D]. 杭州: 浙江大学, 2007.
- [3] 刘大峰, 廖文和, 戴宁, 等. 散乱点云去噪算法的研究与实现[J]. 东南大学学报(自然科学版), 2007(6): 1108-1112.
- [4] Pauly M, Mitra N J, Guibas L J. Uncertainty and variability in point cloud surface data[C]//Eurographics Symposium on Point Based Graphics. Zurich: [s. n.], 2004: 77-84.
- [5] 戴静兰. 海量点云预处理算法研究[D]. 杭州: 浙江大学, 2006.
- [6] 张毅, 刘旭敏, 隋颖, 等. 基于 K-近邻点云去噪算法的研究与改进[J]. 计算机应用, 2009(4): 1011-1014.
- [7] Pauly M, Kobbelt L, Gross M. Multiresolution modeling of

1995-01-19. <http://www.wfmc.org/standards/docs/tc003v11.pdf>.

- [2] OMG. Model Driven Architecture (MDA) [EB/OL]. 2010-06-02. <http://www.omg.org/cgi-bin/doc?omg/03-06-01.pdf>.
- [3] 汪文元, 沙基昌. 基于 MDA 的 workflow 管理系统开发研究[J]. 微型电脑应用, 2005, 21(11): 29-31.
- [4] 赵文, 袁崇义, 张世琨, 等. 一种模型驱动的工作流过程定义途径[J]. 计算机科学, 2006, 33(12): 10-15.
- [5] 魏佳璇. MDA 在科学 workflow 建模中的应用研究[D]. 兰州: 兰州大学, 2009.
- [6] 杨萍, 曹健. 基于 MDA 的工作流门户整体风格的配置[J]. 信息技术, 2007(11): 50-55.
- [7] 魏歌. 基于 MDA 的工作流建模框架[J]. 软件导刊, 2009(10): 49-50.
- [8] 胡健. 基于工作流的电信增值业务管理系统的建模及实现[D]. 北京: 北京邮电大学, 2009.
- [9] XML Process Definition Language Specification [EB/OL]. 2008-10-10. <http://www.wfmc.org/Download-document/WFMC-TC-1025-Oct-10-08-A-Final-XPDL-2.1-Specification.html>.
- [10] Milicev D. Automatic Model Transformations Using Extended UML Object Diagrams in Modeling Environment[J]. IEEE Transactions on Software Engineering, 2002, 28(4): 413-431.
- [11] Oldevik J, Solberg, A, Elvesæter B, et al. Framework for model transformation and code generation[C]// IEEE Enterprise Distributed Object Computing Conference. [s. l.]: [s. n.], 2002: 181-189.
- [12] JMI Expert Group. Java Metadata Interface (JMI) Specification [EB/OL]. 2002-06-28. <http://java.sun.com/products/jmi/collateral.html>.
- [13] point-sampled geometry[R]. [s. l.]: [s. n.], 2002.
- [8] Diebel J R, Thrun S, Bruning M. A Bayesian Method for Probable Surface Reconstruction and Decimation[J]. ACM Transactions on Graphics, 2006, 25(1): 39-59.
- [9] Alexa M, Behr J, Cohen-or D, et al. Point set surfaces[C]// Proceedings of IEEE Visualization. San Diego, California: [s. n.], 2001: 21-28.
- [10] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报, 2000(1): 32-42.
- [11] 李雷, 鲁延玲, 周蒙蒙, 等. 基于核方法的一种新的模糊支持向量机[J]. 计算机技术与发展, 2010, 20(2): 9-11.
- [12] 张苗, 张德贤. 多类支持向量机文本分类方法[J]. 计算机技术与发展, 2008, 18(3): 139-141.
- [13] 赵越超, 李忠科, 王勇, 等. 基于 OpenGL 的三维牙颌模型可视化研究[J]. 计算机技术与发展, 2008, 18(1): 119-121.