

# 利用谱聚类实现深度图像遮挡边界检测

张世辉<sup>1,2\*</sup>, 杨萌<sup>1</sup>, 董利健<sup>1</sup>

<sup>1</sup>燕山大学信息科学与工程学院, 河北 秦皇岛 066004;

<sup>2</sup>河北省计算机虚拟技术与系统集成重点实验室, 河北 秦皇岛 066004

**摘要** 针对视觉目标中存在的遮挡现象, 提出一种基于谱聚类实现深度图像遮挡边界检测的方法。首先定义一种新的遮挡相关特征——有效标准差特征, 基于相关特征利用均卡方集距抽取部分像素点, 构建相似矩阵; 然后基于相似矩阵利用 Nystrom 逼近方法近似估算全部像素点的拉普拉斯矩阵与逼近特征向量, 对得到的逼近特征向量进行聚类分析, 把深度图像中的全部像素点划分为遮挡边界点和非遮挡边界点两大类; 最后可视化遮挡边界点得到深度图像中的遮挡边界。实验结果表明, 本文方法无需标记样本, 且在深度图像中目标物体的遮挡边界检测方面具有较好的有效性和普适性。

**关键词** 机器视觉; 遮挡边界; 谱聚类; 深度图像; 有效标准差特征; 均卡方集距

中图分类号 TP391

文献标识码 A

doi: 10.3788/AOS201838.0915002

## Occlusion Boundary Detection of Deep Image by Using Spectral Clustering

Zhang Shihui<sup>1,2\*</sup>, Yang Meng<sup>1</sup>, Dong Lijian<sup>1</sup>

<sup>1</sup>School of Information Science and Engineering, Yanshan University, Qinhuangdao, Hebei 066004, China;

<sup>2</sup>Key Laboratory for Computer Virtual Technology and System Integration of Hebei Province,  
Qinhuangdao, Hebei 066004, China

**Abstract** Aiming at the occlusion phenomenon in the visual object, we propose a novel occlusion boundary detection approach for deep images based on the spectral clustering. Firstly, a new occlusion-related feature, effective standard deviation feature, is defined. Secondly, some pixels are extracted by using mean chi-square set distance, and the similarity matrix is constructed based on the occlusion-related feature. Thirdly, the Laplacian matrix of all the pixels and approximation eigenvectors are approximated by Nystrom approximation method based on the similarity matrix. Then, the obtained approximation eigenvectors are clustered to divide all the pixels in the depth image into two categories, namely the occlusion boundary points and non-occlusion boundary points. Finally, the occlusion boundary of the depth image is obtained by visualizing occlusion boundary points. Experimental results show that the proposed method which does not need any labeled samples has good effectiveness and generality for occlusion boundary detection of the object in the depth image.

**Key words** machine vision; occlusion boundary; spectral clustering; depth image; effective standard deviation feature; mean chi-square set distance

**OCIS codes** 150.0155; 150.1135; 150.5670; 110.2960

## 1 引 言

视觉遮挡是指观测者在某一观测方位下进行观测时, 被观测物体(视觉目标)上的部分或全部区域被其他物体或自身的其他部分所遮挡, 使得这些区域无法被观测到, 即观测者在当前观测方位下无法

获取到上述区域的信息。根据视觉机制及光的直线传播原理可知, 遮挡现象既是一种光学现象也是一种几何现象。遮挡存在于大多数自然场景中, 且可被投影到数字图像上, 图像中几乎每个目标都会被遮挡或遮挡其他目标。遮挡信息对理解三维场景空间关系至关重要<sup>[1-2]</sup>, 若视觉系统能检测到这些遮挡

收稿日期: 2017-12-29; 修回日期: 2018-03-01; 录用日期: 2018-04-16

基金项目: 国家自然科学基金(61379065)、河北省自然科学基金(F2014203119)

\* E-mail: sshhzz@ysu.edu.cn

信息,将会有助于视觉任务的顺利完成;因此,遮挡边界检测在光学测量、几何重建、深度估计、物体感知、动作识别等领域应用广泛,受到了相关领域国内外学者的关注<sup>[3-4]</sup>。

目前,已有的遮挡边界检测方法主要分为两类:1)基于彩色图像,通过光流估计、深度估计等方法实现;2)基于深度图像,通过模型或学习的方法实现。由于基于彩色图像的遮挡边界检测方法主要利用视频序列或多幅图像实现,故普遍存在时空开销大、检测精度低等不足<sup>[5]</sup>。少数基于单幅彩色图像的遮挡边界检测方法以先验知识、区域分割及语义标注等为前提,故也存在适用范围及精度方面的问题<sup>[2]</sup>。

近年来,深度图像相比于彩色图像以其特有的优势,逐渐受到计算机视觉领域研究者的重视,在图像获取与分析、人机自然交互、目标重建等领域应用越来越多。但现有的基于深度图像研究遮挡边界检测的成果相对较少。文献<sup>[6-7]</sup>利用阈值分割的思想,明确提出了基于模型的深度图像遮挡边界检测方法,但准确性和通用性有待提高。文献<sup>[8-10]</sup>提出利用监督学习思想检测深度图像遮挡边界的方法,分别利用支持向量机(SVM)、随机森林和 Adaboost 分类器实现深度图像的遮挡边界检测。此类方法较大幅度地提高了遮挡检测的准确率和通用性,但需要标记并训练大量样本,耗费人力物力。文献<sup>[11]</sup>基于半监督学习思想,通过构建连通无向图、计算图顶点间的权值判断无向图中待检测像素点是否为遮挡边界点,以此实现深度图像的遮挡边界检测。相对于监督学习方法,此类方法虽然减少了标记样本的数量,但仍须标记部分样本。鉴于此,本文提出一种基于谱聚类的方法来解决深度图像的遮挡边界检测问题,可有效避免样本标记工作,并通过实验验证了所提方法的可行性和有效性。

## 2 方法概述

### 2.1 深度图像及其遮挡边界

深度图像能反映视觉目标三维空间几何信息且不受外界因素,如光照、阴影等影响。深度图像中每个像素点的深度值对应视觉目标上的点到参考平面(摄像机坐标系的  $xOy$  平面)的距离,通过利用深度值和对应摄像机在观测视觉目标时的各种参数即可计算出视觉目标在三维空间的几何信息。深度图像中像素点的深度值大小可由对应像素点的明暗灰度变化表示。其中,像素点越明亮(即灰度值越大)表

示其深度值越小,即该像素点对应视觉目标表面上的点距离给定参考平面越近;反之,像素点的亮度越暗(即灰度值越小)表示其深度值越大,即该像素点对应视觉目标表面上的点距离给定参考平面越远。

由深度图像的特点可知:不存在遮挡现象的像素点与其邻域点之间的深度值变化是连续的,即深度图像中相邻的点在空间上也相邻;而存在遮挡现象的像素点与其邻域点之间的深度值变化具有明显的阶跃,即深度图像中相邻的点在空间上不相邻。故遮挡边界是指在当前观测方位下遮挡前景与被遮挡部分之间的分界线,该分界线通常由遮挡前景上的若干像素点构成。

### 2.2 总体方法

基于谱聚类方法检测深度图像中目标物体的遮挡边界,总体流程如下:首先,将深度图像中的全部像素点作为待检测样本点,计算并提取每个待检测样本点的遮挡相关特征;其次,根据每个待检测样本点的遮挡相关特征计算均卡方集距,比较、选取均卡方集距值较大的部分样本点组成抽取样本点集,利用欧氏距离计算抽取样本点与抽取样本点间的相似矩阵,以及抽取样本点与未抽取样本点间的相似矩阵;然后,基于计算得到的相似矩阵以及 Nystrom 逼近方法近似估算对应的拉普拉斯矩阵,再通过拉普拉斯矩阵求出全部待检测样本点的逼近特征向量矩阵,并从逼近特征向量矩阵中选取合适的特征向量进行聚类分析,得到遮挡边界点和非遮挡边界点两类聚类结果;最后,可视化遮挡边界点得到深度图像中的遮挡边界。具体流程如图 1 所示。

## 3 遮挡相关特征

### 3.1 已有遮挡相关特征

归纳分析可知,目前已有的基于深度图像的遮挡相关特征可分为深度特征、几何特征和统计特征<sup>[8-10]</sup>。深度特征描述了深度图像中遮挡边界点与其 8 邻域内非遮挡边界点的深度值阶跃特性,包括平均深度差特征、最大深度差特征、8 邻域总深度差特征和 8 邻域有效深度差之和特征。几何特征从微分几何角度描述了遮挡边界点在一定邻域内所对应空间曲面的弯曲程度,包括曲率特征和夹角特征。统计特征描述了遮挡边界点在其 8 邻域内深度值的波动变化情况,包括深度值离散度特征和最大面积特征。虽然已有特征从不同角度为深度图像的遮挡边界检测提供了依据,但由于物体本身构造或观测角度不同,当目标物体的部分遮挡边界点与其 8 邻

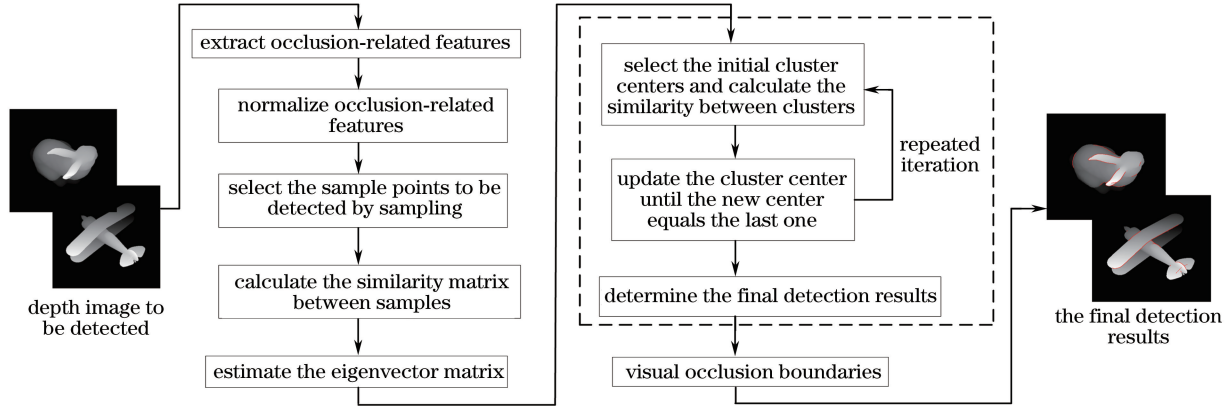


图 1 基于谱聚类实现深度图像遮挡边界检测方法的总体流程

Fig. 1 Overall process of occlusion boundary detection of depth image based on spectral clustering

域点间的深度值阶跃较小时,仅仅依靠现有特征不能完全检测出这类遮挡边界点。鉴于此,在进一步分析遮挡边界点与其邻域点深度值关系的基础上,提出有效标准差特征,以增强深度图像遮挡边界检测的效果。

### 3.2 有效标准差特征的提出及定义

标准差可以描述一组数据的离散程度,通过计算邻域内样本点的标准差来反映样本点的离散程度。在当前观测方位下,由于深度图像中存在遮挡的区域总是深度值小的像素点遮挡深度值大的像素点,所以定义深度图像中任一像素点与其 8 邻域点深度之差小于 0 的所有邻域点的标准差为该点的有效标准差特征。待检测像素点的有效标准差特征值越大,其是遮挡边界点的可能性也越大。记深度图像中任一待测像素点  $p(i, j)$  的深度值为  $d(i, j)$ ,  $p(i, j)$  的 8 邻域点的深度值大于  $d(i, j)$  的所有邻域点的平均深度值为  $E(i, j)$ , 8 邻域内点的深度值大于  $d(i, j)$  的所有邻域点的个数为  $n$ , 则对应的有效标准差特征  $f_{SDD}(i, j)$  定义为

$$f_{SDD}(i, j) = \sqrt{\frac{\sum_{x=i-1}^{i+1} \sum_{y=j-1}^{j+1} [d(x, y) - E(i, j)]^2}{n}} \quad \text{s.t. } d(x, y) > d(i, j). \quad (1)$$

### 3.3 新提特征与已有特征的比较

特征的性能可由利用特征进行相关检测所得结果的准确性衡量,特征重要性是影响检测准确性的重要因素。考虑到现有的遮挡相关特征较多,本文仅选取已知重要性较高的最大深度差特征<sup>[8]</sup>、8 邻域总深度差特征<sup>[9]</sup>、最大面积特征<sup>[9]</sup>,以及 8 邻域有效深度差之和特征<sup>[10]</sup>与所提特征进行比较。应用

随机森林得到以上遮挡相关特征的特征重要性,结果如图 2 所示。

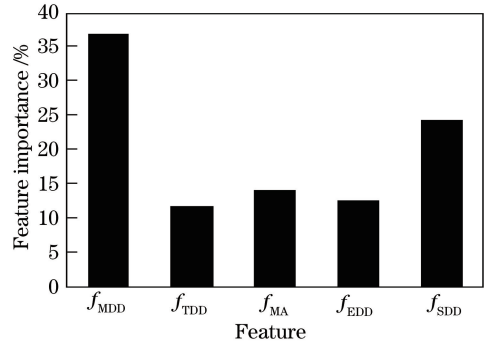


图 2 各遮挡相关特征的特征重要性

Fig. 2 Importance of all occlusion-related features

图中  $f_{MDD}$ 、 $f_{TDD}$ 、 $f_{MA}$ 、 $f_{EDD}$  和  $f_{SDD}$  分别表示最大深度差特征、8 邻域总深度差特征、最大面积特征、8 邻域有效深度差之和特征,以及本文所提的有效标准差特征。由图 2 可以看出,  $f_{MDD} > f_{SDD} > f_{MA} > f_{EDD} > f_{TDD}$ , 即最大深度差特征的特征重要性最大,其次是本文提出的有效标准差特征,最大面积特征的特征重要性相对较高,而 8 邻域总深度差特征的特征重要性最低。综上所述,本文选取特征重要性明显较高的最大深度差特征和有效标准差特征用于深度图像的遮挡边界检测。

## 4 基于谱聚类的深度图像遮挡边界检测方法

将深度图像遮挡边界检测问题视为二分类问题,即需要区分出待测深度图像中每一像素点是否为遮挡边界点。在对深度图像中的每一个像素点进行区分时,利用谱聚类思想将每一个像素点看作是无向加权图的一个顶点,将根据遮挡相关特征计算

所得的顶点间的相似性作为连接边的权值。同时,利用拉普拉斯矩阵表示无向加权图,通过分析矩阵的性质来描述图的结构和图中顶点的关系以实现图的划分,即把像素点的分类问题转化成图的划分问题。考虑到谱聚类算法面临大规模数据时的高计算复杂度和大内存使用等瓶颈问题<sup>[12-15]</sup>,本文利用均卡方集距抽取部分像素点,并将 Nystrom 逼近方法应用到谱聚类思想中,从而实现基于少量像素点信息估计出全部像素点分类结果的功能。

#### 4.1 谱聚类的基础理论

谱聚类算法是基于图论的聚类算法,其基本思想是将待测样本点作为顶点构造无向加权图,并利用不同的划分准则将无向加权图分成不同子图,使得不同子图间的相似性尽可能低,子图内的相似性尽可能高,从而将待测样本点聚类成不同的类别。其中,样本点间的相似性度量作为对应顶点间的权值<sup>[16]</sup>。在构建无向加权图时,通过全连接方法建立顶点间的连接,并利用欧氏距离对顶点间的相似性进行度量;在划分无向加权图时,利用规范割集准则求解图的最优划分,并依据图的基础理论与拉普拉斯矩阵的性质将求解图的最优划分问题转换成求解拉普拉斯矩阵的最小特征向量,选择一个或多个最小特征向量构成特征向量矩阵,利用传统聚类方法对特征向量矩阵进行聚类得到分类结果。在利用谱聚类实现深度图像的遮挡边界检测时,由于需要构建的无向加权图较大,所以利用少量像素点估计全部像素点的分类结果以减小无向加权图的规模,进而降低相似矩阵的规模,减少计算量。

#### 4.2 利用均卡方集距抽取像素点

为了实现基于少量样本点估计全部样本点的分类结果,要求被选中的少量样本点尽可能包含全部样本点的类别,即所抽取样本点应尽可能属于不同的类别。在深度图像中,两个像素点遮挡相关特征的差值越大,这两个像素点属于不同类别的可能性越大。利用遮挡相关特征计算像素点间的卡方距离可以衡量像素点间的差异,距离越大表示差异程度越大。鉴于此,本文通过定义均卡方集距的概念,并利用均卡方集距抽取部分像素点组成抽取样本点集,将剩余像素点作为未抽取样本点集。像素点的具体抽取过程及均卡方集距的定义如下所述。

首先,借助 FAST (Features from Accelerated Segment Test) 算法<sup>[17]</sup>从深度图像中获取部分像素点,由这些像素点组成未抽取样本点集。

其次,从未抽取样本点集中任意选取一样本点

暂设为抽取样本点,计算该抽取样本点与抽取样本点集(初始时空集)中每个样本点间的卡方距离并求均值(初始时该值为 0),计算公式定义为

$$\chi_1^2 = \frac{1}{n} \sum_{i'=0}^n \frac{(c_i - c_{i'})^2}{c_i + c_{i'}}, \quad (2)$$

式中  $c_i$  表示该样本点  $i$  的特征值,  $c_{i'}$  表示抽取样本点集中任一样本点  $i'$  的特征值,  $n$  表示抽取样本点集中样本点的个数。

然后,将该点视为抽取样本点集中的一点,计算抽取样本点集中每个样本点与未抽取样本点集中每个样本点间的卡方距离并求均值(此时未抽取样本点集中已不包括该点),计算公式定义为

$$\chi_2^2(c_i, c_j) = \frac{1}{n \times m} \sum_{j=0}^m \sum_{i=0}^n \frac{(c_i - c_j)^2}{c_i + c_j}, \quad (3)$$

式中  $c_i$  是抽取样本点集中任一样本点  $i$  的特征值,  $c_j$  是未抽取样本点集中任一样本点  $j$  的特征值,  $n$  为抽取样本点集中样本点的个数,  $m$  为未抽取样本点集中样本点的个数。

最后,将两次求得的卡方距离均值之和作为该样本点的均卡方集距,计算公式定义为

$$\chi = \chi_1^2 + \chi_2^2. \quad (4)$$

通过循环计算每个样本点的均卡方集距并比较其大小,选取均卡方集距值较大的样本点作为真正抽取的样本点加入到抽取样本点集中,并在未抽取样本点集中删除该点,直至抽取样本点集中样本点的个数为  $n$  时停止( $n$  为经验值,其值一般远远小于全部样本点的数量)。此时,再将 FAST 算法获取的像素点外的所有像素点加入到未抽取样本点集中,从而获得最终的抽取样本点集和未抽取样本点集。基于最终的抽取样本点集和未抽取样本点集,利用 Nystrom 逼近方法可以计算深度图像中所有像素点的逼近特征向量,通过对特征向量的聚类分析即可实现基于谱聚类的深度图像遮挡边界检测。

#### 4.3 利用 Nystrom 逼近方法实现基于谱聚类的深度图像遮挡边界检测

为了利用 Nystrom 逼近方法实现基于谱聚类的深度图像遮挡边界检测,首先,通过欧氏距离计算出抽取样本点间的相似矩阵  $\mathbf{A}$ ,以及抽取样本点与未抽取样本点间的相似矩阵  $\mathbf{B}$ ;然后,基于相似矩阵估计深度图像中所有像素点的拉普拉斯矩阵,进而计算出对应的逼近特征向量;最后,利用  $K$  均值 ( $K$ -means) 对特征向量进行聚类,从而实现对深度图像中所有像素点的划分。

为了求得所有像素点的逼近特征向量矩阵,首

先基于相似矩阵  $\mathbf{A}$  和  $\mathbf{B}$  定义深度图像中全部像素点间的相似矩阵  $\mathbf{W} = \begin{bmatrix} \mathbf{A} & \mathbf{B} \\ \mathbf{B}^T & \mathbf{C} \end{bmatrix}$ , 式中  $\mathbf{C}$  表示未抽取样本点间的相似矩阵。通过 Nystrom 逼近方法<sup>[14]</sup> 得到相似矩阵  $\mathbf{W}$  的逼近矩阵  $\hat{\mathbf{W}}$ , 以及对应的正交特征向量  $\hat{\mathbf{U}}$ , 即:

$$\begin{cases} \hat{\mathbf{W}} = \begin{bmatrix} \mathbf{A} & \mathbf{B} \\ \mathbf{B}^T & \mathbf{B}^T \mathbf{A}^{-1} \mathbf{B} \end{bmatrix}, \\ \hat{\mathbf{U}} = \begin{bmatrix} \mathbf{A} \\ \mathbf{B}^T \end{bmatrix} \mathbf{A}^{-1/2} \mathbf{U}_s \mathbf{A}_s^{-1/2} \end{cases}, \quad (5)$$

式中  $\mathbf{U}_s$ 、 $\mathbf{A}_s$  分别表示矩阵  $\mathbf{S} = \mathbf{A} + \mathbf{A}^{-1/2} \mathbf{B} \mathbf{B}^T \mathbf{A}^{-1/2}$  经过奇异值分解得到的特征向量矩阵和特征值矩阵。

然后, 根据  $\mathbf{L} = \mathbf{I} - \mathbf{D}^{-1/2} \hat{\mathbf{W}} \mathbf{D}^{-1/2}$  估算深度图像中所有像素点对应的拉普拉斯矩阵  $\mathbf{L}$ , 其中, 度矩阵  $\mathbf{D}$  是以  $\hat{\mathbf{W}}$  每一行的元素之和  $d_i$  为第  $i$  个对角线元素的对角矩阵, 计算  $\mathbf{D}^{-1/2}$  时只须把  $\mathbf{D}$  对角线上的元素  $d_i$  开方后取倒数即可。考虑到计算  $\mathbf{L}$  的前  $l$  个较小特征值所对应的特征向量等价于计算  $\mathbf{D}^{-1/2} \hat{\mathbf{W}} \mathbf{D}^{-1/2}$  的前  $l$  个较大特征值所对应的特征向量, 故可通过  $\mathbf{D}^{-1/2} \hat{\mathbf{W}} \mathbf{D}^{-1/2}$  求解  $\hat{\mathbf{W}}$  中矩阵  $\mathbf{A}$  对应的逼近拉普拉斯矩阵  $\hat{\mathbf{A}}$  和矩阵  $\mathbf{B}$  对应的逼近拉普拉斯矩阵  $\hat{\mathbf{B}}$ , 矩阵  $\hat{\mathbf{A}}$  中的元素  $\hat{\mathbf{A}}_{ij}$  和矩阵  $\hat{\mathbf{B}}$  中的元素  $\hat{\mathbf{B}}_{ic}$  可分别定义为

$$\hat{\mathbf{A}}_{ij} = \frac{\mathbf{A}_{ij}}{\sqrt{d_i d_j}}, i, j = 1, 2, \dots, n, \quad (6)$$

$$\hat{\mathbf{B}}_{ic} = \frac{\mathbf{B}_{ic}}{\sqrt{d_i d_{c+n}}}, i = 1, 2, \dots, n, \quad (7)$$

$$c = 1, 2, \dots, m,$$

式中  $\hat{\mathbf{A}}_{ij}$  和  $\mathbf{A}_{ij}$  分别表示矩阵  $\hat{\mathbf{A}}$  和  $\mathbf{A}$  中第  $i$  行第  $j$  列元素(样本点)的值,  $\hat{\mathbf{B}}_{ic}$  和  $\mathbf{B}_{ic}$  分别表示矩阵  $\hat{\mathbf{B}}$  和  $\mathbf{B}$  中第  $i$  行第  $c$  列元素(样本点)的值,  $n$  表示抽取样本点的个数,  $m$  表示未抽取样本点的个数。

将  $\hat{\mathbf{A}}$  和  $\hat{\mathbf{B}}$  分别替换  $\mathbf{A}$  和  $\mathbf{B}$  代入(5)式即可得到深度图像中所有像素点对应的拉普拉斯矩阵  $\mathbf{L}$  的逼近特征向量  $\hat{\mathbf{U}}_L$ 。

依据上述方法求得逼近特征向量  $\hat{\mathbf{U}}_L$  后, 即可利用  $K$ -means 聚类  $\hat{\mathbf{U}}_L$  中与前  $l$  个较大特征值对应的特征向量, 这  $l$  个特征向量组成的特征向量矩阵

的每一行均对应深度图像中的一个像素点, 即每个像素点可由对应的  $l$  个特征表示, 通过计算行向量之间的相似程度对行向量进行划分, 也就是说, 聚类结果中每个行向量所属的类别就是对应像素点的类别, 从而将深度图像中的所有像素点聚类成遮挡边界点和非遮挡边界点两类。

#### 4.4 基于谱聚类的深度图像遮挡边界检测算法

输入: 待测深度图像。

输出: 深度图像遮挡边界检测结果。

Step 1: 分析待测深度图像中像素点的深度信息, 计算遮挡相关特征并进行归一化。

Step 2: 利用均卡方集距抽取部分像素点组成样本点集, 并记录抽取样本点的横、纵坐标。

Step 3: 将抽取样本点和未抽取样本点分别转化为列向量, 基于欧式距离计算抽取样本点间的相似矩阵, 以及抽取样本点与未抽取样本点间的相似矩阵。

Step 4: 利用所求相似矩阵, 基于(5)~(7)式分别估算全部样本点的拉普拉斯矩阵和对应的特征向量矩阵。

Step 5: 在特征向量矩阵中选取前  $l$  个特征向量, 利用抽取样本点的横、纵坐标, 通过调整对应行向量的位置将其还原成深度图像中像素点原位置对应的特征向量。

Step 6: 将像素点位置还原后对应的  $l$  个特征向量输入到  $K$ -means 聚类算法中, 将深度图像中所有像素点聚类为遮挡边界点和非遮挡边界点两类。

Step 7: 可视化遮挡边界点得到遮挡边界检测结果。

## 5 实验及分析

为了验证本文方法的检测效果, 采用 Stuttgart Range Image Database 中 400 pixel × 400 pixel 的深度图像进行实验。实验硬件环境为 CPU Intel(R) Core (TM) i5-6500 3.20 GHz、内存 4.0 GB。实验程序采用 C++ 语言实现。鉴于 Stuttgart Range Image Database 中目标物体种类较多、深度图像数量较大, 且部分图像不存在遮挡现象, 从中选取 50 幅存在遮挡现象的深度图像作为测试数据集, 并通过手工标记的方式得到每幅深度图像对应的参考标准(Ground Truth)。实验过程中, 根据经验设定  $n = 100, l = 5$ 。

对实验结果进行评估时, 以查准率、查全率和  $F$  值( $F$ -score)作为实验效果好坏的衡量标准。

$$R_p = \frac{N_r}{N_d} \times 100\%, \quad (8)$$

$$R_r = \frac{N_r}{N_{gt}} \times 100\%, \quad (9)$$

$$F = \frac{2 \times R_p \times R_r}{R_p + R_r}, \quad (10)$$

式中  $N_r$  表示检测正确的遮挡边界点数,  $N_d$  表示检测出的遮挡边界点数,  $N_{gt}$  表示 Ground Truth 中的遮挡边界点数。由于  $F$ -score 综合了查准率和查全率, 故  $F$ -score 的值越大, 表明效果越好。

### 5.1 基于不同特征的遮挡边界检测实验

为了验证所提有效标准差特征的有效性, 设计两组对比实验: 1) 基于文献[9]中的遮挡边界检测方




图3 基于不同特征的遮挡边界检测结果。(a)深度图像;(b) Ground Truth;(c)文献[9]方法结合相关特征;(d)文献[9]方法结合联合特征;(e)本文方法结合最大深度差特征;(f)本文方法结合所提特征

Fig. 3 Detection results of occlusion boundary based on different features. (a) Depth image; (b) Ground Truth;

(c) method in Ref. [9] combined with related features; (d) method in Ref. [9] combined with joint features;

(e) proposed method combined with maximal depth difference feature; (f) proposed method combined with proposed feature

观察图3可知,与图3(b)Ground Truth相比,图3(c)中Bunny的头部和Rocker的上部凹凸处存在未被检测出的遮挡边界点,在联合本文所提特征后,这些未被检测出的遮挡边界点已被准确检测出,如图3(d)中绿色的点所示。在基于本文方法结合不同特征进行实验时,图3(e)中Bunny的头部和耳朵交接处存在明显的不连续遮挡边界,在Rocker的下部凹凸处存在未被检测出的遮挡边界点。但如图3(f)中的绿色点所示,上述图3(e)中未被检测出的遮挡边界点已有部分被检测出来,原本不连续的遮挡边界识别效果有所改善,验证了本文所提特征能更好地检测出深度值不明显的遮挡边界点。综上所述可知,无论是文献[9]还是本文方法,通过使用或联合使用本文所提特征后,某些基于现有特征无法检测出的遮挡边界点可以被正确地检测出来,充分说明了本文所提特征的有效性。

为了进一步量化分析本文所提特征的检测效果,表1所示为图3结果的查全率、查准率和  $F$ -score。

法,利用文献中的遮挡相关特征、本文所提特征联合文献中的遮挡相关特征,分别实现深度图像中物体的遮挡边界检测;2)基于本文方法,分别利用最大深度差特征和本文所提有效标准差特征实现深度图像中物体的遮挡边界检测。部分对比实验结果如图3所示,其中,图3(a)为待测深度图像,图3(b)为Ground Truth,图3(c)和图3(d)为采用文献[9]方法,分别基于文献[9]特征和本文特征联合文献[9]特征的遮挡边界检测结果,图3(e)和图3(f)为采用本文方法,分别基于最大深度差特征和本文所提特征的遮挡边界检测结果。图3中,两类视觉目标的名称自上而下分别为Bunny和Rocker。

分析表1可知,无论是文献[9]方法还是本文方法,在查准率基本不变的情况下,引入本文所提特征后,检测到的遮挡边界点数量,以及匹配的遮挡边界点数量上均有一定增加,从而提高了查全率,同时也具有较高的  $F$ -score 值。由此可见,本文所提遮挡相关特征有利于检测出更多的遮挡边界点,提高检测方法检测遮挡边界的性能,充分说明了所提遮挡相关特征的有效性和可行性。

### 5.2 基于不同方法的遮挡边界检测实验

为了更加全面地验证本文方法的有效性,将本文方法与文献[7]、文献[10],以及文献[11]方法进行比较。文献[7]方法基于阈值分割的思想实现深度图像的遮挡边界检测,平均深度差阈值由程序自动计算;文献[10]方法通过集成学习思想实现深度图像的遮挡边界检测,主要利用训练好的 AdaBoost 分类器实现遮挡边界点的分类;文献[11]方法基于图的半监督思想实现深度图像的遮挡边界检测,通过构建连通无向图,并计算对应边的权值判断待检测像素点是否被遮挡。图4所示为本文方法与上述

表 1 基于不同特征的遮挡边界检测结果量化分析

Table 1 Quantitative analysis of occlusion boundary detection results based on different features

Method	Feature	Depth image	$N_{gt}$	$N_d$	$N_t$	$R_p / \%$	$R_r / \%$	$F$ -score
Method in Ref. [9]	Existed features	Bunny	732	731	724	99.04	98.91	98.97
		Rocker	656	641	640	99.84	97.56	98.69
	Joint features	Bunny	732	732	727	99.32	99.32	99.32
		Rocker	656	643	643	99.84	97.87	98.85
Proposed method	Maximal depth difference feature	Bunny	732	757	691	91.28	94.40	92.81
		Rocker	656	598	598	1.00	91.16	95.37
	Proposed feature	Bunny	732	771	701	90.92	95.77	93.28
		Rocker	656	615	614	99.84	93.60	96.62




图 4 基于不同方法的遮挡边界检测结果。(a)深度图像;(b) Ground Truth;(c)文献[7]方法;  
(d)文献[10]方法;(e)文献[11]方法;(f)本文方法

Fig. 4 Detection results of occlusion boundary based on different methods. (a) Depth image; (b) Ground Truth; (c) method in Ref. [7]; (d) method in Ref. [10]; (e) method in Ref. [11]; (f) proposed method

方法的实验对比结果。从上到下 9 种视觉目标的名称分别为 Duck、Knot、Mole、Plane、Rocker、Dragon、Dinopet、Pitbull 和 Bunny。

结合图 4 不同方法的实验结果,并对照图 4(b) 的 Ground Truth 分析可知:文献[7]方法仅检测到了部分遮挡边界,如 Duck 头部遮挡边界、除 Knot 底部弯曲处的遮挡边界等;文献[10]方法检测出的遮挡边界较完整且连续,同时误检较少,如 Plane 仅机头有个别漏检遮挡边界点、Pitbull 遮挡边界等;文献[11]方法相较于文献[7]方法检测到相对较多的遮挡边界,但相对于文献[10]方法仍存在部分漏检误检的遮挡边界,如部分 Dragon 嘴部和腹部的遮挡边界点、Dinopet 胯部较少的遮挡边界点等;本文方法相对于文献[7]方法可较完整地检测出遮挡边界,但相较于文献[10]方法仍有少量遮挡边界未被检测出来,与文献[11]方法相比误检的遮挡边界点相对较多,如 Bunny 眼部和腹部的遮挡边界点等被误检、漏检。以 Mole 和 Rocker 图像为例,对本文方法与其他方法的比较进行具体描述。对于 Mole 图像:文献[7]方法检测到的 Mole 遮挡边界较完整且误检少;文献[10]方法可检测出 Mole 大部分遮挡边界,仅在 Mole 头部和右腿处漏检少量的遮挡边界点;本文方法检测到了较完整且连续的 Mole 遮挡边界,但在 Mole 尾部存在部分误检现象。对于 Rocker 图像:文献[7]方法漏检了 Rocker 顶部凹凸处,以及底部的遮挡边界;文献[10]、文献[11]和本文方法能够检测出 Rocker 顶部凹凸处及底部的遮挡边界,但顶部凹凸处的遮挡边界不连续,比较而言,本文方法的检测效果与文献[11]方法相差不多,但略低于文献[10]方法。

由上述分析可知:文献[7]方法仅能检测出图像中比较明显的遮挡边界,且检测结果中存在一些较明显的漏检;文献[10]方法能检测出相对完整的遮挡边界,不仅连续性较好,而且准确性较文献[7]方法有很大提高;文献[11]方法相较于文献[7]方法明显减少了漏检现象,但与文献[10]方法相比,检测到遮挡边界点的数量偏少;本文方法较文献[7]方法的检测结果有明显改善,与文献[11]方法相比尽管检测到的遮挡边界存在少量的误检现象,但检测到的遮挡边界具有较好的连续性,相较于文献[10]方法虽然有少数遮挡边界点未被检测出来,但遮挡边界的连续性和完整性相差不多。综上分析可知,本文方法可以有效地检测出深度图像中物体的遮挡边界。

为了进一步评估本文方法的检测效果,在对图 4 中视觉目标的实验结果进行定性分析的基础上,分别从平均查准率  $R_{ap}$ 、平均查全率  $R_{ar}$  和  $F$ -score 三方面进行量化评估,评估结果如表 2 所示。

表 2 不同遮挡边界检测方法的量化评估结果  
Table 2 Quantitative evaluation results of different occlusion boundary detection methods

Method	$R_{ap} / \%$	$R_{ar} / \%$	$F$ -score
Method in Ref. [7]	52.18	50.35	0.5125
Method in Ref. [10]	95.38	96.07	0.9572
Method in Ref. [11]	95.92	91.68	0.9379
Proposed method	93.60	93.33	0.9346

结合图 4 和表 2 可知,本文方法相较于文献[7]方法在平均查准率、平均查全率和  $F$ -score 上均有大幅度提高。与利用监督学习的文献[10]方法相比,本文方法在平均查准率、平均查全率和  $F$ -score 上均有所降低,但  $F$ -score 仅低了 0.0226,而文献[10]方法需要进行大量的样本标记工作。相较于采用半监督学习的文献[11]方法,本文方法虽然在平均查准率和  $F$ -score 上均有所降低,但在平均查全率上略有增加,且  $F$ -score 仅低了 0.0033,同时,文献[11]方法也需要部分样本标记工作。本文方法基于无监督学习思想直接训练分类模型,无须进行样本标记,且对数据分布的适应性较强。综上可知,本文方法与监督学习、半监督学习方法检测深度图像遮挡边界的效果相当,且通用性较好。

## 6 结 论

提出一种基于谱聚类实现深度图像中遮挡边界检测的方法,并通过实验验证了所提方法的可行性和有效性。主要贡献为:1)提出一种新的遮挡相关特征——有效标准差特征,丰富了深度图像中遮挡检测特征的种类;2)结合遮挡相关特征,利用均卡方集距抽取部分像素点,并利用抽取像素点与未抽取像素点构建相似矩阵,有效地减小了谱聚类实现遮挡边界检测时相似矩阵的规模;3)利用谱聚类方法检测深度图像中的遮挡边界,获得了较好的检测结果,实现了图的谱理论,以及无监督学习思想在遮挡边界检测方面的应用突破,克服了监督学习和半监督学习需要标记样本的不足。

## 参 考 文 献

- [1] Chen P G, Zhang X M, Yuen P C, *et al.* Combination of spatio-temporal and transform domain for sparse occlusion estimation by optical flow



- [J]. *Neurocomputing*, 2016, 214: 368-375.
- [2] Chen X W, Li Q, Zhao D Y, *et al.* Occlusion cues for image scene layering [J]. *Computer Vision and Image Understanding*, 2013, 117(1): 42-55.
- [3] Chen C, Corso J J. Joint occlusion boundary detection and figure/ground assignment by extracting common-fate fragments in a back-projection scheme [J]. *Pattern Recognition*, 2017, 64: 15-28.
- [4] Cheng H M, Tseng C Y, Hsin C H, *et al.* Single-image 3-D depth estimation for urban scenes [C]. 2013 20th IEEE International Conference on Image Processing, 2013: 2121-2125.
- [5] Fu H, Wang C, Tao D, *et al.* Occlusion boundary detection via deep exploration of context [J]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 241-250.
- [6] Zhang S H, Zhang Y J, Kong L F. Self-occlusion detection approach based on depth image [J]. *Journal of Chinese Computer Systems*, 2010, 31(5): 964-968.  
张世辉, 张煜婕, 孔令富. 一种基于深度图像的自遮挡检测方法 [J]. *小型微型计算机系统*, 2010, 31(5): 964-968.
- [7] Zhang S, Gao F, Kong L. A self-occlusion detection approach based on range image of vision object [J]. *ICIC Express Letters*, 2011, 5(6): 2041-2046.
- [8] Zhang S H, Liu J X. A self-occlusion detection approach based on depth image using SVM [J]. *International Journal of Advanced Robotic Systems*, 2012, 9(6): 230.
- [9] Zhang S H, Liu J X, Kong L F. Using random forest for occlusion detection based on depth image [J]. *Acta Optica Sinica*, 2014, 34(9): 0915003.  
张世辉, 刘建新, 孔令富. 基于深度图像利用随机森林实现遮挡检测 [J]. *光学学报*, 2014, 34(9): 0915003.
- [10] Zhang S H, Pang Y C. Occlusion boundary detection method for depth image based on ensemble learning [J]. *Acta Metrologica Sinica*, 2014, 35(6): 569-573.  
张世辉, 庞云冲. 基于集成学习思想的深度图像遮挡边界检测方法 [J]. *计量学报*, 2014, 35(6): 569-573.
- [11] Zhang S H, Zhang Y C, Zhang H Q, *et al.* Occlusion boundary detection using graph-based semi-supervised learning [J]. *Acta Metrologica Sinica*, 2016, 37(6): 576-581.  
张世辉, 张钰程, 张红桥, 等. 基于图的半监督学习的遮挡边界检测方法 [J]. *计量学报*, 2016, 37(6): 576-581.
- [12] Liu G, Wang X. Adaptive semi-supervised spectral clustering based on nyström method [C]. 2010 3rd International Congress on Image and Signal Processing, 2010: 524-528.
- [13] Bai X D, Cao Z G, Wang Y, *et al.* Image segmentation using modified SLIC and Nyström based spectral clustering [J]. *Optik*, 2014, 125(16): 4302-4307.
- [14] Fu X, Martin S, Mills S, *et al.* Improved spectral clustering using adaptive mahalanobis distance [C]. 2013 2nd IAPR Asian Conference on Pattern Recognition (ACPR), 2013: 171-175.
- [15] Fowlkes C, Belongie S, Chung F, *et al.* Spectral grouping using the Nystrom method [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, 26(2): 214-225.
- [16] Dong A G, Li J X, Zhang B, *et al.* Hyperspectral image classification algorithm based on spectral clustering and sparse representation [J]. *Acta Optica Sinica*, 2017, 37(8): 0828005.  
董安国, 李佳逊, 张蓓, 等. 基于谱聚类和稀疏表示的高光谱图像分类算法 [J]. *光学学报*, 2017, 37(8): 0828005.
- [17] Rosten E, Drummond T. Machine learning for high-speed corner detection [C]. *European Conference on Computer Vision*, 2006: 430-443.