

深度图像分割中的面元优化描述¹

王国宇 姬光荣 李欣 郑冰 张海燕

(青岛海洋大学电子工程系 青岛 266003)

摘要 该文提出了一种新的参数化面元的优化描述方法。基于二次型面表示模型,物体表面参数由深度图像数据拟合得到。基于一种改进的纠偏曲面拟合方法,提出了一个正态分布概率模型来描述面元估计的统计性质,并显式定义了面元描述的可靠性度量。以面元提取为目的,提出了一种新的基于参数估计的深度图像分割方法。在建立区域一致性判别优化准则的同时,使得区域增长总是收敛于所提取面元的“最可靠”描述。文中给出了实际深度图像分割的实验结果。

关键词 深度图像分割,面元,优化描述,参数估计,不确定性,区域增长
中图分类号 TN911.73

1 引言

由深度图像进行三维目标测量与识别是三维视觉领域中一个重要的研究内容,而深度图像分割是其中最重要也是最困难的任务之一^[1-4]。在机器视觉中的低层阶段,图像分割可视为聚类过程,其目的是将图像划分成相互独立的有意义的区域,这些区域可被模型描述并用于更高阶段的分析和识别。其中区域的一致性判别是关键。对于深度图像,区域的一致性定义依赖于对三维物体的表示方法,因为在一个基于模型的识别系统中,所谓一致性区域最终是由模型化的表示方法来描述的。

在三维物体的表示方法中,对物体表面的参数化描述(面表示)是一种有效而被广泛使用的表示方法。常用的参数模型如超二次型、广义柱面和高阶多项式^[1,5-7]可以描述一类较复杂形状的物体。但对于曲率光滑的物体,尤其是种类广泛的人造物体,其表面可以更简便地由低阶多项式,即二次型面模型表示^[8-10]。我们称满足此种面表示模型的图像区域为二次型面元。而所谓一致性区域则由满足二次型描述的图像像素组成。从这个意义上讲,深度图像分割即是面元提取过程。

深度图像分割的方法大致可以分为两种:基于边缘的和基于区域的。基于边缘的方法着重于边缘检测,即以面不连续的点集合做为划分区域的边界^[1,8,11-14]。在基于区域的方法之中^[1,7,9,10,15-18],具有同一性质的像素被逐步合并成为一致性区域(即区域增长),最终整个图像被分割成一组满足一致性条件的区域。也有将边缘检测与区域增长相结合的方法^[19,20]。另外,有关深度图像分割的稳健估计方法以及多尺度方法也得到研究^[14,18,21]。以面元提取为目的,本文中我们采用基于区域的分割方法。显然,当一致性条件定义在二次型面表示模型上时,最终所划分的区域即是二次型面元的集合。

在实现基于区域的分割方法中有两个关键问题,一是区域的一致性判别,二是区域增长过程中一致性像素的合并次序。区域的一致性判别常用待合并像素与面模型的匹配程度来度量,如点到面的距离准则^[3,8,10,15,16]。考虑到图像获取中的测量误差,为了使判别条件建立在统计优化的准则上,在文献[9]中,作者提出了一种贝叶斯准则下的分割方案。使用参数化面表示模型,从以观测为条件的后验概率导出了“一致性概率”概念,从而在优化的原则下实现分割。但由于该方法避免了面参数估计,因而在区域增长过程中,一个一致性区域与参数化模型的匹配程度是未知的。而一致性区域与面元模型的匹配程度依赖于对区域参数估计的不确定性描述。可以说,在基于参数估计的深度图像分割方法中,区域估计的不确定性描述是建立一致性判别准则的优化条件。而当建立了一致性判别准则后,区域增长过程中相邻像素的合并次序对分割

¹ 2001-01-15 收到, 2001-08-03 定稿

结果也有影响, 这是基于区域的图像分割方法中普遍存在的一个问题。这一问题源于图像中的测量误差和区域估计的不确定性。从本质上讲, 其解决方案取决于对区域分割的可靠性评价, 即在区域增长过程中, 像素的合并次序应由区域的“一致性”程度决定。对这一问题的解决方法, 目前在关于深度图像分割的研究文章中尚未涉及。

本文提出了一种面元参数估计的优化描述方法。针对二次型面元, 面元参数估计的不确定性用其协方差来描述并建立了估计的概率模型。在此基础上, 提出了一种新的基于参数估计的深度图像分割方法。由于区域估计的概率模型可以显式计算, 因而一致性判别建立在优化准则上。同时, 在区域增长过程中, 当前区域描述的可靠性由参数估计的不确定性来评价, 因此给出了选择相邻像素合并次序的优化原则, 即区域增长的方向, 总是以面元描述的“可靠性”为准则, 从而完成以面元提取为目的的图像分割。

2 面元参数估计的优化描述

在物体的面表示方法中, 面参数是通过将三维深度数据对参数化模型拟合而得到的。由于噪声以及实际物体表面与数学模型的差别, 导致在参数估计中存在固有的不确定性。这种估计的不确定性无疑给物体表示及特征空间的分类识别造成困难。如何描述估计的不确定性, 是建立统计优化分类准则所需要解决的问题。已有人对此作了研究。在文献 [22] 中, 作者讨论了物体的体积表示方法(超二次型)中的不唯一性问题。他们以“置信度椭球”来量化对某个体积表示模型的认可程度, 并导出使描述不确定性趋向最小的下一步观测视角。但其方法仅局限于某个局部极小的估计不确定性描述。文献 [6] 研究了以高阶多项式为面模型的估计不确定性问题。作者利用估计的渐进形式来描述多项式拟合的后验概率分布, 在此基础上提出了一种最小错误率分类准则。但此概率模型的实用性, 尤其是协方差的导出, 依赖于大样本拟合数据的假设。另外, 在上述两种方法中, 对图像噪声的估计都不够准确。

基于二次型面元模型, 我们提出了一种描述估计不确定性的方法。实际上, 参数估计的不确定性表现是非常复杂的, 不可能完全符合某种数学解析模型。一般情况下, 估计误差的主要统计特性可以由二阶矩, 即协方差所反映。因此我们用协方差来表示估计的不确定性, 而估计量及其协方差阵组成了对面元参数的优化描述。在此基础上, 提出了一个简化的正态分布的概率模型。

2.1 光滑表面的二次型建模及参数估计

我们用二次型模型来表示物体面元。在参考坐标系 $x-y-z$ 下, 二次型面元可以表示为

$$a_{11}x^2 + a_{22}y^2 + a_{33}z^2 + a_{12}xy + a_{13}xz + a_{23}yz + v_1x + v_2y + v_3z + k = 0 \quad (1)$$

给定曲面上的一组三维坐标点, 面元参数的估计可以由曲面拟合得到。在曲面拟合方法中, 梯度加权最小二乘准则已被广泛使用。设 $\{\mathbf{x}_i = (x_i, y_i, z_i)^T\} \forall i \in \{1, \dots, n\}$ 为曲面上的一组观测点, 则梯度加权最小二乘拟合的代价函数定义为 $\Theta = \sum_{i=1}^n w_i f^2(\mathbf{x}_i)$; 其中, $f^2(\mathbf{x}) = 0$ 为曲面的隐式表达式, $w_i = 1/\|\nabla f(\mathbf{x}_i)\|^2$ 为梯度权重。代价函数 Θ 可以近似解释为观测点到估计曲面的距离平方和 [5]。令 $\mathbf{p} = (a_{11}, a_{22}, a_{33}, a_{12}, a_{13}, a_{23}, v_1, v_2, v_3, k)^T$ 表示曲面参数矢量, 则其估计由

$$\hat{\mathbf{p}} = \arg \min_{\mathbf{p} \in P} \Theta(\mathbf{p}) \quad (2)$$

得到, 其中 P 表示参数的约束空间。若 f 为多项式, 非线性问题 (2) 式可由本征矢量方法求解 [17,23]。而对于二次型拟合, 文献 [24] 提出了一种新的纠偏方法。作者证明, 梯度加权最小二乘解是统计有偏的, 从而在本征矢量方法的基础上, 提出“重新归一化”的方法以得到无偏估计。该方法的另一个优点是, 噪声方差同时得到估计。但是, 在现有的本征矢量方法中, 由于在极小化问题的定义中忽略了权重项, 其解的误差较大。因此, 尽管“重新归一化”的方法可以

得到无偏估计, 仍存在解的精度不够的缺陷. 针对这一问题, 我们提出了一种改进的本征矢量方法, 并在此基础上, 改进了“重新归一化”方法, 在保持无偏估计的同时, 提高了估计的精度^[25].

2.2 协方差阵的计算

在应用改进的“重新归一化”方法做曲面拟合时, 曲面参数 \boldsymbol{p} 是用带归一化约束的本征矢量来表示的. 不失一般性, 令 \boldsymbol{p} 中的元素 $k = 1$ 为新的归一化条件, 则定义无约束参数矢量 $\boldsymbol{\theta} = (a_{11}, a_{22}, a_{33}, a_{12}, a_{13}, a_{23}, v_1, v_2, v_3)^T$. 显然, 当 $\hat{\boldsymbol{p}}$ 为面元参数的估计时, $\hat{\boldsymbol{\theta}}$ 亦是其估计. 令 $\boldsymbol{\theta}$ 为面元参数的真值, 当误差 $\Delta\boldsymbol{\theta} = \hat{\boldsymbol{\theta}} - \boldsymbol{\theta}$ 以及噪声 $\Delta\boldsymbol{x}_i (i = 1, \dots, n)$ 可视为扰动时, 可以求得 $\hat{\boldsymbol{\theta}}$ 的协方差阵的显式表达式.

令 $\Theta = \sum_{i=1}^n d_i^2$, 利用 Taylor 公式将 Θ 展开至 $\Delta\boldsymbol{\theta}$ 的二阶项, 则得到 $\Delta\boldsymbol{\theta} = -\boldsymbol{M}_{\theta\theta}^{-1} \sum_{i=1}^n \boldsymbol{M}_{i,x\theta} \Delta\boldsymbol{x}_i$, 其中

$$\boldsymbol{M}_{\theta\theta} = \sum_{i=1}^n \boldsymbol{M}_{i,\theta\theta}; \quad \boldsymbol{M}_{i,\theta\theta} = \frac{\partial^2 \Theta}{\partial \theta^2}; \quad \boldsymbol{M}_{i,x\theta} = \frac{\partial^2 \Theta}{\partial \theta \partial \boldsymbol{x}_i} \quad (3)$$

在高斯噪声的假设下, 有 $E\{\Delta\boldsymbol{x}_i \Delta\boldsymbol{x}_i^T\} = \sigma^2 \boldsymbol{I}$, $\forall i$; $E\{\Delta\boldsymbol{x}_i \Delta\boldsymbol{x}_j^T\} = 0$, $\forall i \neq j$. 于是, $\hat{\boldsymbol{\theta}}$ 的协方差阵可以表示为

$$\boldsymbol{\Psi} = E[\Delta\boldsymbol{\theta} \Delta\boldsymbol{\theta}^T] = \sigma^2 \boldsymbol{M}_{\theta\theta}^{-1} \left(\sum_{i=1}^n \boldsymbol{M}_{i,x\theta} \boldsymbol{M}_{i,x\theta}^T \right) \boldsymbol{M}_{\theta\theta}^{-1} \quad (4)$$

进一步, 可以将 (4) 式简化为^[25]

$$\boldsymbol{\Psi} = \sigma^2 \left(\sum_{i=1}^n w_i \boldsymbol{m}_i \boldsymbol{m}_i^T \right)^{-1} \quad (5)$$

其中 $\boldsymbol{m} = [x_i^2, y_i^2, z_i^2, x_i y_i, x_i z_i, y_i z_i, x_i, y_i, z_i]^T$.

上述协方差阵的导出基于 $\Delta\boldsymbol{\theta}$ 线性依赖于 $\{\Delta\boldsymbol{x}_i\}$ 的假设. 此假设的条件是, 一方面我们假定噪声水平不大, 另一方面, 在我们使用的拟合方法中, $\hat{\boldsymbol{\theta}}$ 是无偏估计. 故可以认为, 这一假设在中等噪声条件下是适用的. 与文献 [6] 中的方法不同, 上述协方差阵的计算不依赖于大样本数据的条件, 因而更适合对局部区域估计的不确定性描述.

3 基于参数估计的区域一致性定义

在深度图像分割中, 当面元估计的不确定性可以用协方差显式表示时, 区域一致性便可以在参数空间以优化准则定义.

我们用正态分布模型来描述面元估计的统计特性. 其理由是: 首先, 在协方差阵的计算中, 我们认为误差 $\Delta\boldsymbol{\theta}$ 与噪声 $\{\Delta\boldsymbol{x}_i\}$ 的线性关系的假设是适用的, 因假定噪声是高斯分布的, 所以 $\Delta\boldsymbol{\theta}$ 也近似视为正态分布. 其次, 梯度加权最小二乘曲面拟合的解可以近似解释为极大似然估计^[6], 其渐近分布是正态的. 另外, 在多数情况下, 仅用一阶和二阶统计量来描述估计的统计特性是一个实用的简化模型. 令 $\boldsymbol{\theta}$ 为真值, $\hat{\boldsymbol{\theta}}$ 为估计, 则其正态分布的 pdf 的表达式为 $f(\hat{\boldsymbol{\theta}}|\boldsymbol{\theta}) = C \exp\{-1/2(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \boldsymbol{\Psi}^{-1}(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})\}$, 其中 C 为归一化因子.

设 $\hat{\boldsymbol{\theta}}_1$ 和 $\hat{\boldsymbol{\theta}}_2$ 是两次测量所得到的估计, 则 $\hat{\boldsymbol{\theta}}_1$ 和 $\hat{\boldsymbol{\theta}}_2$ 为来自同一真值的两个估计, 即满足一致性条件 (用 H 表示) 的似然函数为: $f(\hat{\boldsymbol{\theta}}_1, \hat{\boldsymbol{\theta}}_2|H) = \int f(\hat{\boldsymbol{\theta}}_1, \hat{\boldsymbol{\theta}}_2|\boldsymbol{\theta}) d\boldsymbol{\theta} = \int f(\hat{\boldsymbol{\theta}}_1|\boldsymbol{\theta}) f(\hat{\boldsymbol{\theta}}_2|\boldsymbol{\theta}) d\boldsymbol{\theta}$.

将 f 的正态分布表达式代入并假定协方差阵 Ψ_1 和 Ψ_2 在积分中保持不变, 得到

$$f(\hat{\theta}_1, \hat{\theta}_2 | H) = C \exp \left\{ -\frac{1}{2} (\hat{\theta}_1 - \hat{\theta}_2)^2 \Psi_{1,2}^{-1} (\hat{\theta}_1 - \hat{\theta}_2) \right\} \quad (6)$$

其中 C 为归一化因子, $\Psi_{1,2} = \Psi_1 + \Psi_2$. 显然, 对 $\hat{\theta}_1$ 和 $\hat{\theta}_2$ 的一致性检验可以化为一个统计假设检验问题. 根据 (6) 式, 我们在概率空间定义一个“优化距离”

$$d_{1,2}^2 = \frac{1}{2} (\hat{\theta}_1 - \hat{\theta}_2)^2 \Psi_{1,2}^{-1} (\hat{\theta}_1 - \hat{\theta}_2) \quad (7)$$

来度量 $\hat{\theta}_1$ 和 $\hat{\theta}_2$ 的一致性. 给定阈值 T_d , 如果 $d_{1,2}^2 \geq T_d$, 则认为 $\hat{\theta}_1$ 和 $\hat{\theta}_2$ 是不一致的, 否则是一致的 (即来自同一面元的两个估计). 理论上讲, 阈值 T_d 的选择与所谓“显著性水平”有关, 但由于近似模型与实际计算的差别, T_d 的选择仍需要根据经验确定.

4 面元描述的可靠性度量

在基于区域的深度图像分割中, 如果某一区域的邻近元素在合并前后所得到的面元估计符合一致性准则, 则区域增长被认可. 由于面元估计的不确定性可以由协方差显式表示, 因此我们可以建立面元描述的可靠性度量来判断在区域增长过程中当前区域与面元模型的符合程度. 显然, 对于以面元提取为目的的图像分割, 刻画面元描述的可靠性对于更高阶段的处理与识别是必要的. 更重要的是, 在区域增长过程中, 邻近元素在合并次序将以合并后的“可靠性”为依据, 从而解决了在基于区域的图像分割中如何确定元素的合并次序这一广泛存在的问题.

设 Ψ 为当前面元估计协方差阵, 我们定义“面元描述的可靠性度量” M_r 为

$$M_r \equiv \|\Psi\|_2 \quad (8)$$

则 M_r 的值越小, 表示此估计越可靠. 因此, 在区域增长过程中, 我们选择如下的合并次序: 对于所有的满足一致性条件的邻近元素, 以各自合并后的 M_r 从小到大的顺序依次合并. 这一原则保证了所提取的面元将沿着“最可靠描述”的方向增长.

需要强调的是, 上述可靠性度量定义在参数空间, 而非图像空间. 它不仅与图像空间的噪声水平有关, 而且与图像数据的“可观察性”有关. 也就是说, 即使噪声水平较小, 若对当前区域的参数估计是病态的, 则其可靠性度量仍然较低 (M_r 较大).

5 一种新的基于面元提取的区域增长方法

根据上述对面元参数估计的优化描述, 以面元提取为目的, 我们提出了一种新的深度图像分割的区域增长方法. 其原理由图 1 所示. 整个过程包括 3 个步骤, 即不规则点检测; 区域增长和点细化.

由于二次型面元模型要求表面光滑的条件, 因此首先要把深度图像中的不规则点检测出来. 所谓不规则点包括物体边界、边缘等面不连续处以及异常噪声点. 采用矩形窗口对图像采样, 对窗口内的数据点做平面拟合, 若窗口中心点到拟合平面的距离超过设定阈值 (由于噪声方差在面元拟合的过程中已得到估计, 该阈值可根据噪声水平来设定), 则该点被视为不规则点. 将窗口沿整个图像移动, 则所有的不规则点被检测出并加以标记. 图 2(a) 为一实际深度图像², 其不规则点检测的结果用白色亮点表示在图 2(b) 中. 所有被标记为不规则点的数据都不参与下

²本文中原始深度图像图 2(a) 及图 3(a) 取自荷兰 Twente 大学 Laboratory of Measurement and Instrumentation.

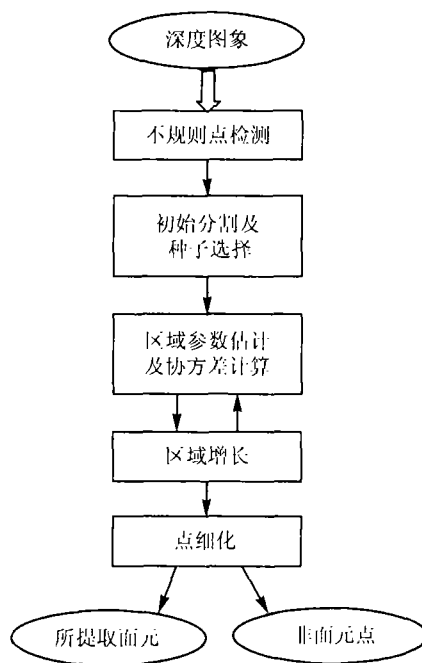


图 1 深度图像分割方法示意图

一步骤中的曲面拟合计算。实际上，由于使用区域增长的分割方法，因此不规则点检测结果在整个过程中并非关键，但它提供了不一致性区域的初步描述，并减少了区域增长阶段的计算量。这些不规则点将在最后的点细化过程中被重新检验。

区域增长是整个方法的关键步骤。不规则点检测完成后，整个深度图像用栅格状窗口做初始分割，如图 2(b) 所示。按照文献 [10] 的定义，此栅格区域可称为“面基元” (surface elements, 或 sels)。面基元的大小是人为设定的。一方面，它应足够小以保证此范围内的数据点是一致性的；另一方面，太小的面基元将增加区域增长的迭代运算量。在实验中，我们选择其大小与不规则点检测中的滑动窗口的大小一样。区域增长的“种子”由几个相邻的面基元组成 (6~9 个)，这主要是为了避免过小的初始区域导致参数估计中的病态问题。从一个“种子”开始，区域增长通过不断合并当前区域的相邻面基元而完成。这一过程由一致性准则来控制，如第 3 节所述。

设第 k 步迭代的当前区域为 $R^{(k)}$ ，对于相邻的面基元 S ，合并后的区域为 $R^{(k+1)} = R^{(k)} \cup S$ 。设 (θ_k, Ψ_k) 和 $(\theta_{k+1}, \Psi_{k+1})$ 分别为 $R^{(k)}$ 和 $R^{(k+1)}$ 的参数估计及协方差阵，如果 $R^{(k)}$ 和 S 是一致性的，则估计 θ_k 和 θ_{k+1} 应是同一面元的两次观测。依照假设检验，其一致性可由 (7) 式所定义的“优化距离”来检验，即 $d_{k,k+1}^2 = \frac{1}{2}(\theta_k - \theta_{k+1})^T \Psi_{k,k+1}^{-1}(\theta_k - \theta_{k+1})$ ，其中， $\Psi_{k,k+1} = \Psi_k - \Psi_{k+1}$ 。如果 $d_{k,k+1}^2 \geq T_d$ (T_d 为设定阈值)，则合并被拒绝，否则接受。一旦 S 与 $R^{(k)}$ 合并，则当前区域被 $R^{(k+1)}$ 更新并检验下一个相邻面基元。当所有相邻面基元都不能通过检验时，当前区域的生长停止。在余下的面基元中，再由种子开始进行新的区域增长过程。直到没有新的种子可选，则整个区域增长结束。在此过程中，如果一个面基元包含的不规则点的数目超过某一阈值，则此面基元不参与检验，而留待后面的点细化过程中处理。此过程结束后所提取的由一系列相邻面基元组成的区域我们称之为“主干区域”。在图 2(c) 中，4 个主干区域被用不同的灰度填充表示。

需要强调的是，在区域增长过程中，相邻面基元的合并次序是按照“可靠性度量”来决定的。正如在第 4 节中所叙述的，对于所有满足一致性条件的相邻面基元，一次合并只选择 M_i

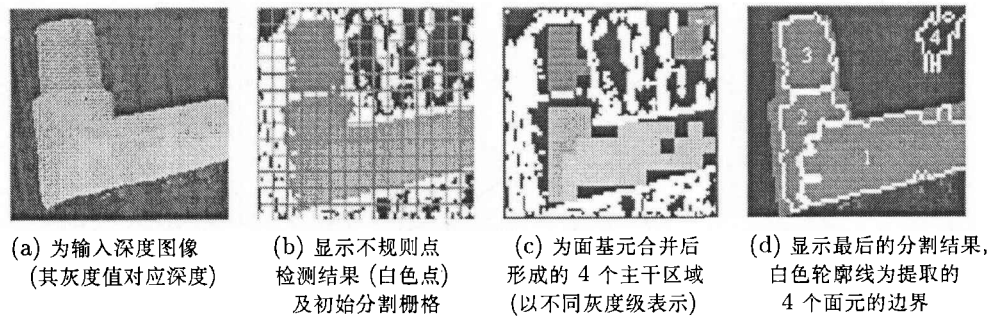


图 2 深度图像分割结果

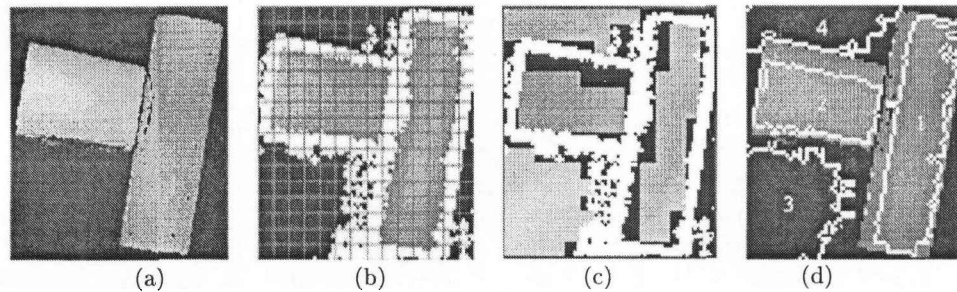


图 3 深度图像分割结果。(a)~(d) 所示内容与图 2 相同。

最小的那一个 S 来更新当前区域, 以保证当增长结束时, 所提取的区域在参数空间的描述上是最可靠的, 即估计的不确定性最低。

在随后的点细化阶段, 所有主干区域之外的数据点 (包括不规则点) 被重新检验划分为两类: 属于主干区的称为面元点, 其余的称为非面元点。检验的依据是点到面元的几何距离。若某点到任何主干区所代表的面元的距离都超过阈值 (该阈值根据噪声水平来设定), 则该点被标记为非面元点。否则, 将其标记为距离最近的那个主干区所代表的面元。在这一过程中, 某些不规则点可能被重新确认为面元点, 因为这些不规则点实际上处于物体面边界或边缘。

上述过程结束后, 整个深度图像即被分割成一组有意义的物体光滑表面面元及其它背景数据点。只有所提取的面元数据点才被用于更高阶段的分析识别中。图 2(d) 显示了最终所提取的四个闭合面元区域。图 3(a)~3(d) 显示了另一个深度图像分割的实验结果。显然, 对于图 2 和图 3 所示的物体类型 (即物体表面由不同的面元组成, 但面元间并无明显的边缘), 用基于边缘检测的分割方法无法获得所期望的结果。但应用本文所提出的区域增长方法, 可以实现面元提取的目的。

6 结 论

本文提出了一种以面元提取为目的的深度图像分割方法。其核心是对面元估计的优化描述。应用改进的纠偏拟合方法对二次型面元做参数估计, 并提出了描述估计不确定性的显式概率模型。在应用区域增长方法进行图像分割时, 区域描述的一致性判别则建立在优化的准则上, 因而可以使用假设检验的原则实现区域聚类。

此方法将图像分割解释为面元提取过程, 故着重于面元描述的可靠性。为此, 我们定义了“可靠性度量”的概念, 使用估计的协方差阵的范数来作为面元描述的可靠性度量。从而解决了区域增长过程中相邻子区域的合并次序问题。其原则是, 使得合并后的区域在参数空间描述上的不确定性最小, 从而保证了最终所提取的面元在描述上的可靠性。对实际深度图像的实验

结果表明, 所提出的算法能够有效提取所感兴趣的物体表面面元, 同时, 可以排除由于测量误差而引起的图像中不可靠数据点(例如在物体表面的边界部分)。从某种意义上讲, 本文所提出的深度图像分割方法并非以“场景的物理划分”为目的, 而是强调“场景划分的可靠描述”。由于图像分割作为低层处理手段, 其结果一般用于更高层次的分析和识别, 所以我们认为, 基于描述的图像分割方法更符合机器视觉系统的处理特点。

参 考 文 献

- [1] F. Arman, J. K. Aggarwal, Model-based object recognition in dense-range images—a review, *ACM Computing Survey*, 1993, 25 (1), 5–43.
- [2] R. Hoffman, A. K. Jain, Segmentation and classification of range images, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1987, PAMI-9(5), 608–620.
- [3] A. Hoover, *et al.*, An experimental comparison of range image segmentation algorithms, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1996, PAMI-18(7), 673–689.
- [4] 章毓晋, 图像分割, 北京, 科学出版社, 2001, 第七, 第八章.
- [5] R. M. Bolle, B. C. Vemuri, On three-dimensional surface reconstruction methods, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1991, PAMI-13(1), 1–13.
- [6] J. Subrahmonias, D. Cooper, D. Keren, Practical reliable Bayesian recognition of 2D and 3D objects using implicit polynomials and algebraic invariants, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1996, PAMI-18(5), 505–519.
- [7] H. Zha, T. Hoshida, T. Hasegawa, A Recursive fitting-and-splitting algorithm for 3-D object modeling using superquadrics, in *Proc. ICPR'98, Brisbane, Australia*, 1998, 658–662.
- [8] S. Kaveti, E. Khwang, H. Wang, Second-order implicit polynomials for segmentation of range images, *Pattern Recognition*, 1996, 29(6), 937–94.
- [9] S. M. LaValle, S. A. Hutchinson, A Bayesian segmentation methodology for parametric image models, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1995, PAMI-17(2), 211–217.
- [10] B. Sabata, F. Arman, J. K. Aggarwal, Segmentation of 3D range images using pyramidal data structures, *CVGIP: Image Understanding*, 1993, 57(3), 373–387.
- [11] A. P. Davignon, Detecting orientation discontinuities in range images by use of directional derivatives, in *Proc. IAPR 11th Int. Conf. Pattern Recognition, The Hague, Netherlands*, 1992, 3, 455–458.
- [12] M. Haindl, P. Zid, Range image segmentation by curve grouping, in *Proc. 7th Int. Workshop RAAD'98, Smolenice Castle, Slovak Republic*, 1998, 339–344.
- [13] Y. Zhang, Y. Sun, H. Sari-Sarraf, M. Abidi, Impact of intensity edge map on segmentation of noisy range images, *Conference on Three-Dimensional Image Capture and Applications III, San Jose, California, USA, Proc. SPIE*, 2000, 3958, 260–269.
- [14] S. G. Burgiss, R. T. Whitaker, M. A. Abidi, Range Image Segmentation Through Pattern Analysis of the Multiscale Wavelet Transform, *Digital Signal Processing, Academic Press*, 1998, 8, 267–276.
- [15] P. J. Besl, R. C. Jain, Segmentation through variable-order surface fitting, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1988, PAMI-10(2), 167–192.
- [16] G. Taubin, Estimation of planar curves, surfaces, and nonplanar space curves defined by implicit equations with applications to edge and range image segmentation, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1991, PAMI-13 (11), 1115–1138.
- [17] A. P. Ashbrook, R. B. Fisher, C. Robertson, N. Werghi, Segmentation of range data into rigid subsets using planar surface patches, in *Proc. ICCV'98, Bombay, India*, 1998, 201–206.
- [18] K. Koester, M. Spann, MIR: an approach to robust clustering-application to range image segmentation, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2000, PAMI-22(5), 430–444.
- [19] D. P. Mital, E. K. Teon, A. W. T. Lim, A hybrid method towards segmentation of range images for 3-D object recognition, *International Journal of Pattern Recognition and Artificial Intelligence*, 1994, 8(4), 969–995.
- [20] M. A. Wani, B. G. Batchelor, Edge-region-based segmentation of range images, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1994, PAMI-16(3), 314–319.

- [21] J. Miller, C. Steward, MUSE: robust surface fitting using unbiased scale estimates, in Proc. CVPR'96, San Francisco, California, USA, 1996, 300-306.
- [22] P. Whaite, F. P. Ferrie, From uncertainty to visual exploration, IEEE Trans. on Pattern Analysis and Machine Intelligence, 1991, PAMI-13(10), 1038-1049.
- [23] Z. Zhang, Parameter estimation techniques: a tutorial with application to conic fitting, Image and Vision Computing, 1997, 15, 59-76.
- [24] K. Kanatani, Statistical bias of conic fitting and renormalization, IEEE Trans. on Pattern Analysis and Machine Intelligence, 1994, PAMI-16(3), 320-326.
- [25] G. Y. Wang, Recognition of man-made objects from range data: optimization of surface based (quadric) representation, Ph.D. thesis, University of Twente, the Netherlands, 2000.

OPTIMAL DESCRIPTION OF SURFACE PRIMITIVE FOR RANGE IMAGE SEGMENTATION

Wang Guoyu Ji Guangrong Li Xin Zheng Bing Zhang Haiyan

(Department of Electronic Engineering, Ocean University of Qingdao, Qingdao 266003, China)

Abstract This paper proposes a new algorithm of optimal description of surface primitive. The 3-D surface parameters are estimated through fitting the range data to a quadric model. Based on an improved bias-corrected fitting algorithm, a probabilistic model with normal pdf to describe the statistical characteristics of the surface estimate is proposed. Consequently a metric defined as "measure of reliability" of the surface estimate is given. Towards reliable primitive extraction, a new method of estimation-based range image segmentation is thereby described. While the region homogeneity is defined on an optimal criterion, the region growing always converges to the state of "the most reliable description" of the extracted surface primitives. The experimental results with real range images are given.

Key words Range image segmentation, Surface primitive, Optimal description, Parameter estimation, Uncertainty, Region growing

王国宇: 男, 1962 年生, 副教授, 主要研究方向是图像分析与模式识别.
姬光荣: 男, 1953 年生, 教授, 博士生导师, 主要研究方向是信号处理、图像分析与模式识别.
李欣: 男, 1959 年生, 副教授, 主要研究方向是信号传感及信号处理.
郑冰: 男, 1968 年生, 副教授, 主要研究方向是信号处理及机器人视觉.
张海燕: 女, 1968 年生, 讲师, 主要研究方向是信号处理及机器人视觉.