

文章编号 1004-924X(2015)08-2357-12

结合特征定位噪声表征的单应矩阵精确鲁棒估计

赵春阳^{1,2,3*}, 赵怀慈^{1,3}

(1. 中国科学院 沈阳自动化研究所, 辽宁 沈阳 110016;

2. 中国科学院大学, 北京 100049; 3. 中国科学院 光电信息处理重点实验室, 辽宁 沈阳 110016)

摘要:针对基于特征匹配的单应矩阵估计方法的特征定位噪声的各向异性非同分布对其精度和鲁棒性的影响,提出了一种结合特征定位噪声表征的单应矩阵估计方法。该方法采用协方差矩阵来表征特征点定位噪声;基于协方差矩阵加权采样一致性(CWSAC)的内点检验方法来提高单应矩阵估计的鲁棒性。最后,提出一种单应矩阵高精度估计算法——协方差加权 Levenberg-Marquardt(CW L-M)法。该方法结合协方差矩阵重新定义优化目标函数,提高了单应矩阵的估计精度。基于仿真数据和真实图像的实验表明,在相同定位噪声和内点比例条件下,本文算法的估计精度显著优于 RANSAC(RANdom SAmple Consensus)、LMedS(Least Median of Squares)、PROSAC(PROgressive SAmple Consensus)、M-SAC(M-estimator SAmple Consensus)和 MLESAC(Maximum Likelihood SAmple Consensus)等传统算法,投影均方误差比次优方法降低了 3%~21%。另外,本文方法对定位噪声和内点比例变化均具有较好的鲁棒性。

关键词:单应矩阵估计;特征定位噪声;协方差加权;随机采样一致(RANSAC);Levenberg-Marquardt

中图分类号:TP391.4 **文献标识码:**A **doi:**10.3788/OPE.20152308.2357

Accuracy and robust estimation of homography based on feature point location noise

ZHAO Chun-Yang^{1,2,3*}, ZHAO Huai-Ci^{1,3}

(1. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China;

3. Key Laboratory of Optical-electronics Information Processing,
Chinese Academy of Sciences, Shenyang 110016, China)

* Corresponding author, E-mail: zcyneu@sina.com, zhaocy@sia.cn

Abstract: The feature location noise from feature-based homography estimation methods is isotropic and non-identical distribution, and it effects the accuracy and robustness of homography estimation methods significantly in practical applications. Therefore, this paper proposes a high accuracy and robust homography estimation method based on location noise of feature points. The method uses a covariance matrix to characterize the location noise of feature points and takes an inner point verification method based on Covariance matrix Weight SAmple Consensus(CWSAC) to improve the robustness of the homography estimation method. Finally, a high accuracy homography matrix refined method, Co-

收稿日期:2015-04-03; **修订日期:**2015-06-03.

基金项目:国家 973 重点基础研究发展规划资助项目;中国科学院光电信息处理重点实验室开放基金资助项目
(No. OEIP-O-201203)

variance matrix Weight Levenberg-Marquardt (CW L-M) is proposed by combining covariance matrix with Levenberg-Marquardt method, and it improves the estimation accuracy of homography matrix by redefining a optimized object function. The experiments on simulation data and real images show that as compared with state-of-the-art methods, such as RANSAC (RANDOM SAMPLE CONSENSUS), LMedS (Least Median of Squares), PROSAC (PROGRESSIVE SAMPLE CONSENSUS), M-SAC (M-estimator SAMPLE CONSENSUS) and MLESAC (Maximum Likelihood SAMPLE CONSENSUS), the accuracy of homography estimation has improved greatly and the root mean squares of reproject error has reduced 3% - 21% than that of the subprime method in the same location noise and the same inlier proportion. In addition, the proposed method is robust to the noise level and inlier proportion changing.

Key words: homography estimation; feature localization noise; covariance weighting; RANDOM SAMPLE CONSENSUS (RANSAC); Levenberg-Marquardt

1 引 言

平面单应性可以表示平面间坐标点的非奇异线性关系,在多视几何中扮演着极其重要的角色,而单应性矩阵是校准^[1]、重构、图像配准^[2,3]、图像拼接^[4]、特征跟踪和机器人建图^[5]等应用的重要基础。

单应性矩阵的早期研究涉及代数方法和几何方法^[6-7],其基本思想是基于最小化代数或几何距离,采用线性估计或非线性迭代方法估计单应矩阵。不过,上述方法只适用于测量噪声较小的条件下,对于测量噪声较大或有外点数据的情况,会产生较大的代数或几何距离误差,导致单应矩阵估计错误。

当存在外点数据时,为了提高单应矩阵的估计性能,研究人员提出了 RANSAC (RANDOM SAMPLE CONSENSUS)^[8]、LMedS (Least Median of Squares)^[9]、HEASK^[10]等多种鲁棒单应矩阵估计方法^[8-11]。LMedS 方法将单应矩阵估计看作最小化均值误差的非线性最小化问题,采用最优化方法求解。实验表明,LMedS 方法在外点比例小于 50% 条件下具有较好的估计性能。RANSAC 方法是一种迭代方法,首先通过随机选择匹配点子集估计候选单应矩阵,然后采用检验规则判定所有匹配点内外点并统计点数目,当满足迭代结束条件时,选择内点数目最多的候选单应矩阵作为估计结果。实验表明,RANSAC 方法在外点比例大于 50% 条件下也具有较好的估计性能。另外,研究人员还提出了多种 RANSAC

变种方法^[12-16],典型方法包括:PROSAC (PROGRESSIVE SAC)方法^[12]、ARRSAC (Adaptive Real-time Random SAC)方法^[13]、M-SAC (M-estimator SAC)方法^[14]、MLESAC (Maximum Likelihood SAC)方法^[14]、MAPSAC (Maximum A Posterior estimation SAC)方法^[15]和 LO-RANSAC (Locally Optimized RANSAC)方法^[16]等,上述方法进一步提高了 RANSAC 方法的精度或鲁棒性。

随着尺度不变特征变换 (Scale-Invariant Feature Transform, SIFT)^[17]、加速鲁棒特征变换 (Speed-Up Robust Feature, SURF)^[18]等斑点特征提取方法的提出,结合局部特征和 RANSAC 的基于特征的单应矩阵估计方法得到广泛应用^[10]。由于 SIFT、SURF 等斑点特征提取方法具有旋转、尺度不变性,并能够适应一定程度的视角变化,极大地提高了匹配性能;另外,由于 RANSAC 方法具有较好的鲁棒性,因此,基于特征的单应矩阵估计方法已经成为计算视觉领域的标准方法。

在实际应用中,由于受到光照条件、噪声、特征提取算法本身等因素的影响,特征点周围的灰度分布具有一定的不确定性,从而直接影响特征点定位的稳定性,并会引入特征点定位噪声。由于特征点定位噪声与其周围的灰度分布高度相关,并且具有较强的方向性,因此其是各向异性非同分布的,导致基于特征的单应矩阵估计方法存在如下问题:一,RANSAC 方法中的残差公式没有考虑不同特征点定位噪声的差异,因此导致内点检验可能存在错误,影响估计方法的鲁棒性;

二,单应矩阵估计中采用的L-M等非线性最小二乘方法假设噪声为各向同性且独立同分布,而特征定位噪声不满足该假设条件,造成估计的单应矩阵不是最优解,从而影响单应矩阵估计精度。

针对上述问题,本文提出了一种结合特征各向异性非同分布定位噪声的高精度、鲁棒单应矩阵估计方法。首先,采用协方差矩阵表征特征定位噪声;然后,将协方差矩阵与RANSAC方法相结合,使得在内点检验中考虑特征各向异性非同分布噪声,提高内点检验的鲁棒性;最后,结合协方差矩阵重新定义L-M方法的目标函数,实现在存在各向异性非同分布噪声条件下单应矩阵的精确估计。

2 基于特征的单应矩阵估计

本文方法是一种基于特征的单应矩阵估计方法。下面对基于特征的单应矩阵估计方法基本原理及存在问题进行详细描述。

(1) 特征匹配

基于特征的单应矩阵估计方法首先从两幅图像中提取特征点,然后采用最小欧式距离等匹配测度准则进行特征匹配,得到匹配点对。

(2) 内点检测

设 (x_{1i}, y_{1i}) 和 (x_{2i}, y_{2i}) 为分别来自图像 I_1 和 I_2 的第 i 个匹配点对,其中, $i=1, 2, \dots, n$ 。记 $\mathbf{m}_{1i}=[x_{1i}, y_{1i}, 1]^T$, $\mathbf{m}_{2i}=[x_{2i}, y_{2i}, 1]^T$,则在单应几何约束条件下,两幅图像之间的匹配点对存在如下的对应关系:

$$x_{2i} = \frac{\mathbf{h}_1^T \mathbf{m}_{1i}}{\mathbf{h}_3^T \mathbf{m}_{1i}} \quad y_{2i} = \frac{\mathbf{h}_2^T \mathbf{m}_{1i}}{\mathbf{h}_3^T \mathbf{m}_{1i}} \quad (1)$$

设图像 I_1 和 I_2 之间的 3×3 单应矩阵为 $\mathbf{H}=[\mathbf{h}_1^T \mathbf{h}_2^T \mathbf{h}_3^T]^T$,其中: \mathbf{h}_j^T 表示单应矩阵 \mathbf{H} 的第 j 行,则公式(1)可写成如下的线性等式:

$$\mathbf{Z}_i \boldsymbol{\theta} = \mathbf{0} \quad (2)$$

其中,

$$\mathbf{Z}_i = \begin{bmatrix} x_{1i}, y_{1i}, 1, 0, 0, 0, -x_{2i}x_{1i}, -x_{2i}y_{1i}, -x_{2i} \\ 0, 0, 0, x_{1i}, y_{1i}, 1, -y_{2i}x_{1i}, -y_{2i}y_{1i}, -y_{2i} \end{bmatrix},$$

$$\boldsymbol{\theta} = [h_{11}, h_{12}, h_{13}, h_{21}, h_{22}, h_{23}, h_{31}, h_{32}, h_{33}] \quad (3)$$

h_{ij} 为单应矩阵 \mathbf{H} 的第 i 行第 j 列元素。

对于单个匹配点对,可建立如公式(2)所示的

两个等式,对于 n 个匹配点对,可建立如下等式:

$$\mathbf{Z}\boldsymbol{\theta} = \mathbf{0} \quad (4)$$

其中,

$$\mathbf{Z} = [\mathbf{Z}_1^T \quad \mathbf{Z}_2^T \quad \dots \quad \mathbf{Z}_n^T] \quad (5)$$

由于单应矩阵 \mathbf{H} 含有8个未知参数,因此,至少需要4个匹配点对计算 \mathbf{H} 。

基于特征的单应矩阵估计采用RANSAC方法进行内点检测,在单应性约束条件下剔除匹配对中存在的内点数据。RANSAC方法是一种迭代方法,设第 l 次($l=1, \dots, L$)迭代中随机选取 N 个($N \geq 4$)匹配点对来计算候选单应矩阵 $\mathbf{H}^{(l)}$,对于每个匹配点其计算残差为:

$$r_i^{(l)} = (x_{2i} - \hat{x}_{2i})^2 + (y_{2i} - \hat{y}_{2i})^2 \quad (6)$$

其中,

$$\hat{x}_{2i} = \frac{\mathbf{h}_1^{(l)T} \mathbf{m}_{1i}}{\mathbf{h}_3^{(l)T} \mathbf{m}_{1i}} \quad \hat{y}_{2i} = \frac{\mathbf{h}_2^{(l)T} \mathbf{m}_{1i}}{\mathbf{h}_3^{(l)T} \mathbf{m}_{1i}} \quad (7)$$

为采用单应矩阵 $\mathbf{H}^{(l)} = [\mathbf{h}_1^{(l)T} \mathbf{h}_2^{(l)T} \mathbf{h}_3^{(l)T}]^T$ 进行的重投影坐标。

若残差值满足条件 $r_i^{(l)} \leq \rho$, ρ 为内点阈值,则将该匹配点判定为内点。对所有匹配点对进行内点检验,得到第 l 次迭代的内点集合:

$$M^{(l)} = \{(m_{1k}, m_{2k})\}^{(l)}, k=1, \dots, n^{(l)} \quad (8)$$

其中 $n^{(l)}$ 为第 l 次迭代的内点数目。

RANSAC迭代结束后,选取内点数目最大的内点集合作为内点检验结果,将选取的内点集合记作 $M^{(l_{\max})}$,内点数目为 $n^{(l_{\max})}$,其对应的单应矩阵记作 $\mathbf{H}^{(l_{\max})}$ 。

(3) 单应矩阵估计

为了进一步提高单应矩阵的估计精度,基于特征的单应估计方法一般不直接将内点检测输出的单应矩阵 $\mathbf{H}^{(l_{\max})}$ 作为最后的估计结果,而是利用内点集合 $M^{(l_{\max})}$,采用L-M等优化方法重新估计单应矩阵。L-M优化时采用的常规目标函数为重投影误差平方和:

$$E = \sum_{i=1}^{n^{(l_{\max})}} [(x_{2i} - \hat{x}_{2i})^2 + (y_{2i} - \hat{y}_{2i})^2] \quad (9)$$

3 定位噪声表征及单应矩阵精确鲁棒估计

基于特征的单应矩阵估计方法由于没有考虑

各向异性非同分布的特征定位噪声,从而会影响单应矩阵估计的精度和鲁棒性。为了解决该问题,本文提出一种结合特征定位噪声表征的单应矩阵估计方法。该方法基本思想如下:(1)采用协方差矩阵来度量特征定位噪声;(2)结合协方差矩阵重新定义 RANSAC 方法的残差公式,提高内点检验的鲁棒性;(3)结合协方差矩阵重新定义单应矩阵估计目标函数,以实现单应矩阵的精确估计。

3.1 基于协方差矩阵的特征定位噪声表征

特征点定位噪声的分布形式依赖于其周围图像灰度分布、特征提取算法本身等因素,由于不同特征点周围图像灰度分布差异显著,而且具有很强的方向性,因此,特征点定位噪声并不是如图 1(a)所示的各向同性同分布噪声,而是如图 1(b)所示的各向异性且非同分布噪声。


各向异性非同分布噪声可采用一般形式的协方差矩阵 $\mathbf{\Lambda}$ 来表征:

$$\mathbf{\Lambda} = \alpha \cdot \mathbf{R}_r \cdot \begin{bmatrix} \beta & 0 \\ 0 & 1-\beta \end{bmatrix} \cdot \mathbf{R}_r^T, \quad (10)$$

其中,

$$\mathbf{R}_r = \begin{bmatrix} \cos \gamma & -\sin \gamma \\ \sin \gamma & \cos \gamma \end{bmatrix}, \quad (11)$$

其中: $\alpha \in [0, \infty)$ 称为尺度; $\beta \in (0, 1)$ 称为偏心率, $\gamma \in [0, \pi)$ 称为旋转角度。



(a)各向同性同分布噪声 (b)各向异性非同分布噪声
(a) Isotropic identical (b) Anisotropic non-identical
distributed noise distributed noise

图 1 特征定位噪声分类

Fig. 1 Classification of feature localization noise

文献[19-21]指出,特征点定位噪声可采用特征点稳定性(或不不确定性)来描述。特征稳定性越高,特征定位噪声越小,反之越大。特征稳定性 Σ 和定位噪声 $\mathbf{\Lambda}$ 存在如下关系: $\Sigma = \mathbf{\Lambda}^{-1}$ 。针对不

同的特征提取算法,可采用文献[19-21]提出的方法估计特征点的不确定性,进而实现定位噪声的估计。由于特征定位噪声估计不是本文研究内容,因此,本文假定提取的特征点及其定位噪声协方差是已知的。

3.2 CWSAC:基于协方差加权的内点检验方法

如公式(6)所示,基于特征的单应矩阵估计方法在内点检验中假定所有特征的定位误差对残差计算的影响都是相同的,即定位误差为各向同性、独立同分布的。然而,在实际应用中,特征的定位噪声是各向异性且非同分布的,不同特征点的定位噪声对残差计算的影响不同,本文在内点检验时考虑这种差异性,提出一种基于协方差加权的内点检验算法——CWSAC(Covariance Weighted ranSAC)。该方法将特征定位噪声结合到 RANSAC 方法中,以提高内点检验的鲁棒性。

特征定位噪声可采用协方差矩阵 $\mathbf{\Lambda}$ 来表征,由于协方差矩阵 $\mathbf{\Lambda}$ 是 2×2 的对称矩阵,因此,可分解成如下形式:

$$\mathbf{\Lambda} = \mathbf{U} \cdot \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix} \cdot \mathbf{U}^T, \quad (12)$$

其中: λ_1, λ_2 分别为协方差矩阵 $\mathbf{\Lambda}$ 的两个特征值; $\mathbf{U} = [\mathbf{u}_1 \ \mathbf{u}_2]$ 为其对应的特征向量,协方差矩阵 $\mathbf{\Lambda}$ 为一个椭圆,椭圆长短轴分别为 λ_1 和 λ_2 ,长短轴所在方向为特征向量 \mathbf{u}_1 和 \mathbf{u}_2 的方向。

设 $(\mathbf{m}_{1i}, \mathbf{m}_{2i})$ 为匹配点对, $\hat{\mathbf{m}}_{2i}$ 为 \mathbf{m}_{1i} 的重投影坐标,CWSAC方法定义加权残差 r_i 和归一化加权残差 \bar{r}_i 计算公式如下:

$$r_i^2 = \lambda_1 (\mathbf{u}_1^T \cdot (\mathbf{m}_{2i} - \hat{\mathbf{m}}_{2i}))^2 + \lambda_2 (\mathbf{u}_2^T \cdot (\mathbf{m}_{2i} - \hat{\mathbf{m}}_{2i}))^2, \quad (13)$$

$$\bar{r}_i = \frac{2}{\lambda_1 + \lambda_2} \cdot r_i^2. \quad (14)$$

与公式(6)给出的 RANSAC 方法残差公式不同,CWSAC方法的残差公式考虑了定位噪声的各向异性非同分布特性,其几何解释如下:首先,将重投影误差旋转到协方差矩阵 $\mathbf{\Lambda}$ 的轴向方向,体现了定位噪声的各向异性特性;然后,采用协方差矩阵 $\mathbf{\Lambda}$ 的特征值进行加权求和,体现了定位噪声的非同分布特性。

RANSAC 方法采用内点数目作为代价函数,选取使代价函数最大的模型作为最优估计模型;而 MLESAC 方法选取残差平方和作为代价函数,选取代价函数最小的模型作为最优估计模型。

相比于 RANSAC 方法, MLESAC 方法选取的代价函数更合理, 估计精度也更高, 但是 MLESAC 方法的代价函数没有考虑定位噪声的各向异性且非同分布的特性。考虑到上述因素, CWSAC 方法将考虑定位噪声特性的加权残差平方和作为代价函数 C :

$$C = \sum \rho_i^2, \quad (15)$$

其中,

$$\rho_i^2 = \begin{cases} r_i^2, & \bar{r}_i^2 \leq t^2 \\ t^2, & \bar{r}_i^2 > t^2 \end{cases}, \quad (16)$$

其中 t 为内点判定阈值。

最后, 求取使代价函数 C 最小的模型作为最优估计模型。

3.3 CW L-M: 基于协方差加权的 L-M 方法

在采用内点检验算法得到内点集合和估计模型后, 基于特征的单应矩阵估计方法通常会基于估计的内点集合, 采用 L-M 等方法重新估计模型, 进一步提高模型估计精度。

传统的 L-M 方法采用公式(9)作为目标函数来估计单应矩阵, 该方法在各向同性独立同分布噪声条件下的估计结果是最优的。然而, 在实际应用中, 由于不同特征点的定位噪声是各向异性非同分布的, 因此, 不同特征点对目标函数的贡献是不同的, 即: 特征定位噪声越小, 其对目标函数的贡献应该越大; 特征定位噪声越大, 对目标函数的贡献应该越小。因此, 本文考虑结合特征定位噪声表征, 提出一种基于协方差加权的 L-M 方法——CW L-M(Covariance Weighted L-M)。

设 $(\mathbf{m}_{1i}, \mathbf{m}_{2i})$ 为匹配点对, $\hat{\mathbf{m}}_{2i}$ 为 \mathbf{m}_{1i} 的重投影坐标, CW L-M 方法重新定义如下的目标函数来估计单应矩阵:

$$\tilde{E} = \sum_{i=1}^{n_{\max}} \left[\frac{(\mathbf{u}_i^T \cdot (\mathbf{m}_{2i} - \hat{\mathbf{m}}_{2i}))^2}{\lambda_1} + \frac{(\mathbf{u}_e^T \cdot (\mathbf{m}_{2i} - \hat{\mathbf{m}}_{2i}))^2}{\lambda_e} \right]. \quad (17)$$

对于每个特征点, 公式(17)建立的目标函数首先将重投影误差旋转到协方差矩阵特征向量方向, 然后采用特征值倒数进行加权求和, 考虑了不同特征定位误差的各向异性特性, 以及非同分布特征的定位误差对目标函数的不同贡献。

另外, 由于定位误差的各向异性非同分布特性, 公式(9)给出的目标函数不满足 L-M 方法对数据噪声的各向同性且独立同分布假设, 求解结

果不是最优的, 而公式(17)给出的目标函数可以看作是将各向异性非同分布的原始数据噪声转变为各向同性噪声, 并进行归一化后, 得到各向同性且同分布的数据噪声, 满足 L-M 求解要求, 求解结果是单应矩阵的最优估计。

3.4 结合 CWSAC 和 CW L-M 方法的单应矩阵估计

结合特征定位噪声表征的单应矩阵估计算法的主要步骤如下:

输入:

特征匹配点对集合, 特征定位噪声协方差矩阵

输出:

单应矩阵

Step1. 基于 CWSAC 方法的内点检测

1.1 随机选取 4 个匹配点对, 采用线性 DLT(Direct Linear Transform)方法求解公式(4)的线性方程组, 得到候选单应矩阵 $\mathbf{H}^{(d)}$;

1.2 对所有匹配点对, 利用候选单应矩阵 $\mathbf{H}^{(d)}$, 采用公式(13)计算协方差加权残差, 并采用公式(15)计算代价函数;

1.3 重复步骤 1.1 和 1.2, 直到满足 CWSAC 方法迭代结束条件, 输出使代价函数最小的单应矩阵和内点集合;

Step2. 基于 CW L-M 方法的单应矩阵估计

利用 Step 1 输出的内点集合, 将公式(17)作为目标函数, 采用 CW L-M 方法估计单应矩阵。

4 实验结果与分析

4.1 实验方法与步骤

本节实验的目的是验证本文方法的单应矩阵的估计精度及鲁棒性。将本文方法与典型的基于特征的单应矩阵估计方法进行了大量的对比实验, 对比方法包括: LMedS + L-M 方法、PROSAC + L-M 方法、RANSAC + L-M 方法、MSAC + L-M 方法、MLESAC + L-M 方法。本节主要进行了两类实验。

4.1.1 基于仿真数据的实验验证

基于仿真数据的实验验证通过生成具有不同噪声等级的定位噪声以及不同内点比例的匹配点对来验证算法的精确性和鲁棒性, 其主要实验步骤如下:

首先,采用公式(10)随机生成具有各向异性非同分布定位噪声的匹配点对,其中, α 、 β 和 γ 是随机产生的,分别服从均匀分布 $U(0, 2\sigma)$ 、 $U(0.5, 1)$ 和 $U(0, \pi)$,其中, σ 为噪声等级,用于控制定位噪声的尺度,本文中取值为 $[0.1, 1]$,间隔为0.1。另外,根据内点比例随机生成错误匹配点对,内点比例为 $[0.3, 1]$,间隔为0.1。

然后,使用不同内点比例、噪声等级生成的仿真数据,采用本文方法和对比方法估计单应矩阵,并选取重投影误差均方根 RMSE (Root Mean Squares of Error) 作为评价指标,评价不同噪声等级以及不同内点比例对估计精度的影响。评价指标 RMSE 计算公式如下:

$$\text{RMSE} = \sqrt{\sum_{i=1}^n \| \mathbf{m}_{2i} - \hat{\mathbf{m}}_{2i} \|_2^2 / n}, \quad (18)$$

其中: $(\mathbf{m}_{1i}, \mathbf{m}_{2i})$ 为匹配点对, $\hat{\mathbf{m}}_{2i}$ 为 \mathbf{m}_{1i} 的重投影坐标, n 为匹配点对数。

为体现对比的公平性,LMedS、PROSAC、RANSAC、M-SAC、MLE SAC 和 CWSAC 等算法均采用固定的迭代次数(1000次);为体现算法的统计特征,对于每组仿真数据都进行100次实验,然后取均值作为本组实验结果。

4.1.2 基于真实图像的实验验证

基于真实图像的仿真验证来评价真实图像条件下,本文算法与对比算法的单应矩阵估计精度,其主要步骤如下:

首先,如图2所示,选取 Mikolajczyk 文中^[21]的标准图像作为测试图像,该图像库中的图像对覆盖了尺度变化、视角变化等情况,并提供了图像对之间的单应矩阵真实值,为单应矩阵估计性能验证奠定了基础。

然后,采用 SIFT 算法提取特征,并采用文献^[21]的方法估计特征点的不确定性,利用不确定性协方差矩阵度量特征定位噪声,所采用的对比算法及评价指标与仿真数据实验相同。另外,为体现精度对比的公平性,对于每组图像对的内点检验算法均进行1000次迭代运算,L-M 和 CW L-M 均采用相同的迭代次数。为体现算法的统计特征,对于每组图像对进行100次实验,然后将计算指标均值作为结果。实验时内点比例选取为0.3。

最后,为直观显示算法性能,设 (I_1, I_2) 为待配准图像对,灰度残差 ΔI 和灰度残差均值 $\Delta \bar{I}$

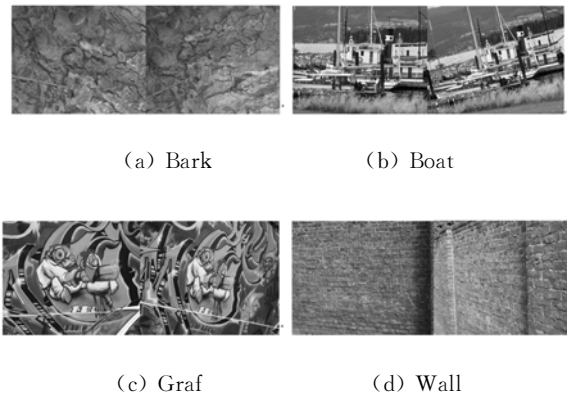


图2 标准测试图像对

Fig. 2 Image pairs for testing

(Average Gray Residuals, AGR) 定义为:

$$\Delta I = \sum_n | I_2 - I_2^{(\phi)} | \quad \Delta \bar{I} = \Delta I / n, \quad (22)$$

其中: $I_2^{(\phi)}$ 为采用单应矩阵 $\mathbf{H}^{(\phi)}$ 将图像 I_1 进行重投影得到的图像; $\mathbf{H}^{(\phi)}$ 为选取的与 RMSE 均值最接近的单应矩阵估计值; n 为图像 I_2 与 $I_2^{(\phi)}$ 重叠区域像素数目。灰度残差均值 $\Delta \bar{I}$ 越小说明估计精度越高,反之,估计精度越低。

4.2 定位噪声对估计精度的影响

表1给出了不同算法的 RMSE 指标均值随噪声等级的变化情况,表2和图3给出了不同内点条件下,不同算法的 RMSE 指标随噪声等级的变化情况。

表1 不同算法的 RMSE 误差均值随噪声等级变化情况
Tab. 1 Average RMSEs of different algorithms in different noise levels

噪声等级	LM edS	PRO SAC	RAN SAC	M-SAC	MLE SAC	CW SAC	提高/(%)
0.1	54.71	1.600	0.049	0.047	0.045	0.038	16.0
0.2	44.28	9.503	0.065	0.064	0.067	0.053	17.4
0.3	39.28	0.082	0.086	0.087	0.080	0.068	14.7
0.4	43.94	49.94	0.096	0.092	0.135	0.080	12.2
0.5	44.52	11.86	0.114	0.106	0.104	0.094	9.3
0.6	42.16	23.06	0.125	0.117	0.119	0.106	9.5
0.7	37.44	8.040	0.132	0.131	0.129	0.109	15.7
0.8	42.94	3.661	0.134	0.145	0.131	0.110	15.4
0.9	45.17	5.027	0.158	0.144	0.160	0.122	15.8
1	43.59	23.09	0.169	0.158	0.151	0.141	6.5

通过分析,得到如下结论:

(1)如表 1 所示,在不同噪声等级条件下,本文提出的 CWSAC+CWL-M 方法的 RMSE 指标均值均优于其他对比算法,与次优方法相比, RMSE 指标提高 6.5%~17.4%。分析其原因是本文方法在内点检验和单应矩阵估计中引入了特征定位噪声的协方差加权机制,从而提高了单应矩阵的估计精度;

(2)如表 2 和图 3 所示,在大多数内点比例情

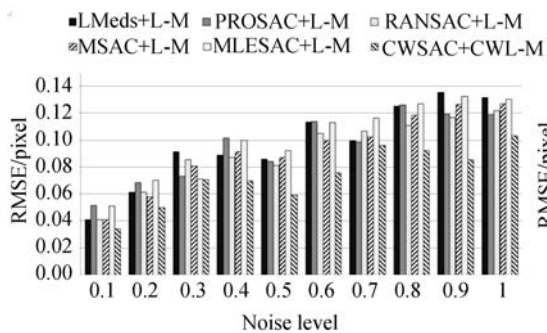
况下,本文方法估计性能优于对比方法,因此,本文算法对内点变化是鲁棒的。这主要是因为本文方法引入特征定位噪声的协方差加权机制,提高了单应矩阵估计的鲁棒性;

(3)如表 1 所示,LMedS+L-M 和 PROSAC+L-M 方法性能较差,这主要因为在内点比例较低的条件,上述算法性能较差,甚至失效,因此 RMSE 指标均值被拉低。

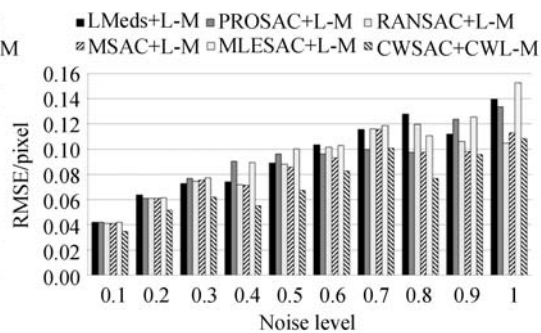
表 2 内点比例为 0.3 和 0.5 条件下,不同算法的 RMSE 指标随噪声等级的变化

Tab.2 RMSE varies with different noise levels when inlier ratios are 0.3 and 0.5


噪声等级	内点比例=0.3						内点比例=0.5					
	LM edS	PRO SAC	RAN SAC	M- SAC	MLE SAC	CW SAC	LM edS	PRO SAC	RAN SAC	M- SAC	MLE SAC	CW SAC
0.1	283.1	12.51	0.091	0.075	0.061	0.062	6.464	0.046	0.049	0.049	0.046	0.042
0.2	172.5	75.57	0.109	0.105	0.096	0.093	7.616	0.068	0.063	0.061	0.066	0.053
0.3	170.5	0.121	0.116	0.150	0.108	0.091	4.359	0.089	0.096	0.100	0.090	0.082
0.4	181.3	398.9	0.197	0.173	0.497	0.213	2.953	0.112	0.096	0.095	0.101	0.077
0.5	175.5	25.94	0.246	0.211	0.146	0.259	5.596	0.097	0.113	0.115	0.111	0.087
0.6	170.8	137.6	0.268	0.229	0.223	0.255	5.560	0.100	0.132	0.129	0.100	0.109
0.7	168.0	63.59	0.282	0.301	0.218	0.229	7.130	0.100	0.128	0.114	0.128	0.099
0.8	180.3	23.85	0.264	0.342	0.227	0.254	8.617	0.129	0.135	0.141	0.145	0.097
0.9	180.5	39.37	0.410	0.359	0.259	0.293	6.345	0.124	0.132	0.127	0.146	0.108
1	188.7	183.9	0.454	0.298	0.301	0.323	5.028	0.124	0.156	0.174	0.133	0.161



(a) 内点比例为 0.6
(a) Inlier ratio is 0.6



(b) 内点比例为 0.7
(b) Inlier ratio is 0.7



(c) 内点比例为 0.8


(d) 内点比例为 0.9

(c) Inlier ratio is 0.8

(d) Interior ratio is 0.9

图 3 不同内点比例条件下,各算法的 RMSE 指标随噪声等级的变化

Fig. 3 RMSE changing with noise level in different inlier ratios




(a) 噪声等级为 0.1

(b) 噪声等级为 0.3

(a) Noise level is 0.1

(d) Noise level is 0.3



(c) 噪声等级为 0.7

(d) 噪声等级为 1.0

(c) Noise level is 0.7

(d) Noise level is 1.0

图 4 不同噪声等级条件下,各算法的 RMSE 指标随内点比例的变化

Fig. 4 RMSE changing with interior point ratio in different noise levels

4.3 内点比例对估计精度的影响

表 3 给出了不同算法的 RMSE 指标均值(不同内点的 RMSE 指标均值)随内点比例的变化情况,图 4 给出了不同噪声等级条件下,不同算法的 RMSE 指标随内点比例的变化情况。

表 3 不同算法的 RMSE 误差均值随内点比例变化情况

Tab. 3 Average RMSE varies with inlier ratios

内点比例	LM edS	PRO SAC	RAN SAC	M-SAC	MLE SAC	CW SAC	提高 /%
0.3	187.1	96.14	0.244	0.224	0.214	0.207	3.0
0.4	156.9	12.04	0.126	0.128	0.122	0.106	13.3
0.5	5.967	0.099	0.110	0.110	0.107	0.091	7.5
0.6	0.097	0.095	0.092	0.093	0.100	0.074	19.4
0.7	0.094	0.092	0.089	0.085	0.098	0.074	13.7
0.8	0.082	0.082	0.085	0.081	0.086	0.066	19.1
0.9	0.075	0.076	0.081	0.077	0.079	0.063	16.5
1	0.072	0.072	0.076	0.072	0.077	0.056	21.5

通过分析,可得到如下结论:

(1)如表 3 所示,本文提出的 CWSAC+CW L-M 方法在不同内点比例下的 RMSE 指标均值都优于其他对比算法,与次优方法相比, RMSE 指标提高 3.0%~21.5%。另外,如图 4 所示,在大多数噪声等级下,本文方法的估计精度均优于其他对比方法,因此,本文算法对噪声等级的变化是鲁棒的。分析其原因是本文方法在内点检验和单应矩阵估计中引入了特征定位噪声的协方差加权机制,从而提高了单应矩阵的估计精度和鲁棒性;

(2)如表 3 所示,LMedS+L-M 在内点比例 ≤ 0.5 , PROSAC+L-M 在内点比例 ≤ 0.4 条件下,算法估计性能较差,说明 LMedS 和 PROSAC 方法不适用于内点比例较低的情况。相反, RANSAC+L-M、M-SAC+L-M 和 MLESAC+L-M 等方法在内点比例 ≤ 0.5 条件下也取得了较好的性能,这说明 RANSAC、M-SAC 和 MLESAC 算法适用于内点比例较低的情况。同时,随着内点比例的提高,LMedS+L-M 和 PROSAC+L-M 算法性能得到明显提高,与 RANSAC+L-M 等算法差距不明显。

综合 4.2 小节和 4.3 小节,得到如下结论:本文提出的 CWSAC+CW L-M 方法的总体性能最优;LMedS+L-M 方法总体性能最差;RANSAC 及其变种方法中,MLESAC+L-M 方法总体性能略优于其他方法或与其他方法相当。

因此,在基于真实图像的实验中,本文选取 CWSAC、LMedS、RANSAC 和 MLESAC 算法进行对比实验。

4.4 基于真实图像实验验证算法性能

表 4 给出了在真实图像的实验中,不同图像对,不同算法的 RMSE 指标的对比情况(粗体表示性能最优或相当(RMSE 差异 $< 1\%$))。

表 4 不同算法、不同图像对的 RMSE 误差均值

Tab. 4 Average RMSE of different image pairs for different algorithms

图像对	LM edS	RAN SAC	MLE SAC	CW SAC	降低 /%	
Bark	1→2	75.05	0.954	1.139	0.880	7.78
	1→3	154.0	2.102	2.121	1.926	8.37
	1→4	107.7	0.906	0.905	0.908	-0.37
	1→5	114.3	0.562	0.527	0.530	-0.58
	1→6	114.5	0.972	0.967	0.975	-0.86
	Boat	1→2	67.07	0.868	1.289	0.729
1→3		186.9	0.521	0.489	0.388	20.72
1→4		82.89	0.804	0.865	0.468	41.75
1→5		114.6	0.855	0.998	0.782	8.58
Graf	1→2	165.6	0.562	0.613	0.494	12.18
	1→3	220.7	1.334	2.619	1.344	-0.69
	1→4	220.3	3.859	2.506	1.761	29.73
Wall	1→2	9.075	1.324	1.334	1.326	-0.10
	1→3	289.5	0.937	0.904	0.880	2.67
	1→4	243.8	1.407	1.686	1.392	1.08
	1→5	260.9	1.534	1.375	1.448	-5.35
1→6	267.8	2.100	2.727	1.978	5.79	

分析表 4 可得到如下结论:

(1)与其他算法相比,本文方法的 RMSE 指标平均降低了 7%,最大降低 42%。这说明对于真实图像对,本文方法对单应矩阵估计性能提升是显著的;

(2)与其他算法相比,本文方法的 RMSE 指标最优和相当的图像对有 16 个,约占所有匹配成功图像对的 95%。这说明对于不同的真实图像对,本文方法对单应矩阵估计性能的提升是稳定的、鲁棒的;

(3)与其他方法相比,本文方法少数图像对的 RMSE 指标基本相当,且差异 $< 1\%$,分析其原因是文献[21]提出的特征不确定性并不是对定位噪声非常精确的估计,影响了本文方法单应矩阵的估计性能,导致少数情况下估计性能提升不明显。

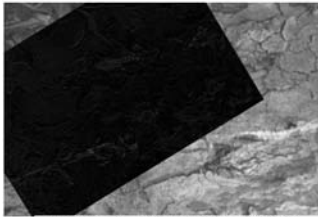
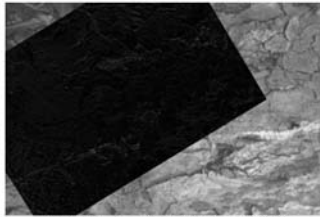
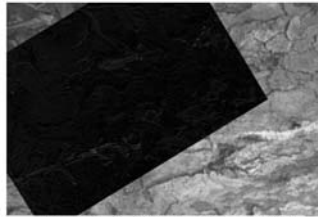





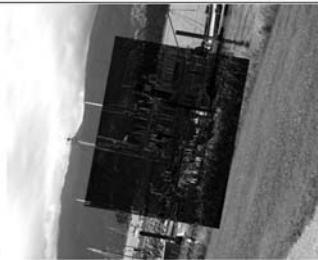
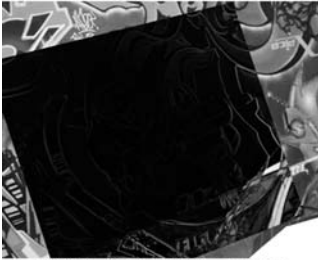





	RANSAC + L-M	MLESAC + L-M	CWSAC + CW L-M
Bark 1→2	 RMSE=0.954; AGR=10.323	 RMSE=1.139; AGR=10.676	 RMSE=0.880; AGR=10.289
Boat 1→3	 RMSE=0.521; AGR=13.169	 RMSE=0.489; AGR=12.074	 RMSE=0.388; AGR=11.819
Boat 1→4	 RMSE=0.804; AGR=22.948	 RMSE=0.865; AGR=22.729	 RMSE=0.463; AGR=22.136
Graf 1→2	 RMSE=0.562; AGR=11.342	 RMSE=0.613; AGR=11.402	 RMSE=0.494; AGR=11.023
Graf 1→4	 RMSE=3.859; AGR=26.631	 RMSE=2.506; AGR=23.788	 RMSE=1.761; AGR=22.412

图 5 典型图像对配准残差图像

Fig. 5 Comparison of RMSE and AGR of different image pairs

图5给出了采用本文方法及对比方法配准后典型图像对的残差灰度图像。可以看出本文方法的RMSE指标和图像配准后的平均灰度残差指标(AGR)是最优的,另外,从视觉上看,本文方法的配准效果也是最好的。同时也说明了RMSE指标越低,AGR指标也越低,即RMSE指标可以从客观上评价本文及对比方法用于图像配准时性能的优劣。

4.5 算法执行时间对比

表5给出了基于仿真数据实验验证的不同算法执行时间。本文所有算法程序均在VC 2010开发环境,基于OpenCV计算机视觉库编写,运行时间为多次单应矩阵估计实验求取的平均时间。

如表5所示,可得到如下结论:(1)LMedS、RANSAC和M-SAC算法的运行时间相当,且耗时最少;(2)MLESAC算法耗时约为上述方法的1.25倍,分析其原因是MLESAC方法的内点检测机制较上述方法复杂度高;(3)本文方法耗时约为对比方法的1.2~1.7倍,分析其原因是本文方法在内点检测和残差计算时引入了特征定位噪声的协方差加权机制,从而增加了算法的复杂度。

综上,虽然本文方法运行时间略高于对比方法,但是与它们仍处于同一数量级,并且考虑到本文方法对性能提升显著,运行时间在一定程度上增加是可以接受的。对于实时性要求较高的应用,可采用并行计算等方法来降低算法的运行时间。

参考文献:

- [1] DUAN Y N, CHEN W, WANG M ZH. A relative radiometric correction method for airborne image using outdoor calibration and image statistics [J]. *IEEE Transaction on Geoscience and Remote Sensing*, 2014, 52(8): 5164-5174.
- [2] 杨磊, 李桂菊, 王丽荣. 面向场景重构的多序列间配准[J]. *光学精密工程*, 2015, 23(2): 557-565.
YANG L, LI G J, WANG L R. Registration between multiple sequences for scene construction[J]. *Opt. Precision Eng.*, 2015, 23(2): 557-565. (in Chinese)
- [3] 王健博, 朱明. 基于字典描述向量的实时图像配准[J]. *光学精密工程*, 2014, 22(6): 1613-1621.
WANG J B, ZHU M. Realtime image registration

表5 不同算法运行时间比较

Tab. 5 Comparison of running time

算法	LM edS	PRO SAC	RAN SAC	M- SAC	MLE SAC	CW SAC
时间 (ms)	47.12	62.21	44.07	44.08	54.54	74.03

注:PROSAC方法统计了数据排序时间

5 结论

本文针对特征定位噪声的各向异性非同分布特性导致的基于特征的单应矩阵估计方法估计精度、鲁棒性下降的问题,提出一种基于特征定位噪声表征的高精度、鲁棒单应矩阵估计方法。该方法采用协方差矩阵来表征定位噪声,结合协方差矩阵进行内点检验,提高了单应矩阵估计的鲁棒性;采用协方差加权方法构造L-M算法的新的优化目标函数,进一步提高了单应矩阵的估计精度。基于仿真数据和真实图像的实验结果表明,本文提出的方法显著优于如LMedS + L-M、RANSAC + L-M及其变种等常用方法,单应矩阵估计性能得到显著提升。另外,相较于其他方法,在不同内点比例和不同噪声等级变化条件下,本文方法都能够实现单应矩阵的精确估计,具有较好的鲁棒性。下一步的工作是针对特征定位噪声估计精度不高的问题,开展高精度特征定位噪声估计方法的研究。

based on dictionary feature descriptor [J]. *Opt. Precision Eng.*, 2014, 22(6): 1613-1621. (in Chinese)

- [4] ZARAGOZA J, CHIN T J, TRAN Q H. As-projective-as-possible image stitching with moving DLT [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(7): 1285-1298.

- [5] 王锋, 程敏, 陈小平. 面向机器人室内建图的RGB-D图像对齐算法[J]. *机器人*, 2015, 37(2): 129-135.

WANG F, CHENG M, CHEN X P. An RGB-D image alignment algorithm for robotic mapping in indoor environments [J]. *ROBOT*, 2015, 37(2): 129-135. (in Chinese)

- [6] HARTLEY R, ZISSERMAN A. *Multiple View Geometry in Computer Vision* [M]. 2nd Edition.

- Cambridge: Cambridge University Press, 2004, 87-129.
- [7] HARTLEY R. In defense of the eight-point algorithm [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(6): 580-593.
- [8] FISCHLER M A, BOLLES R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography [J]. *Communications of the ACM*, 1981, 24(6): 381-395.
- [9] ROUSSEEUW P J. Least median of squares regression [J]. *Journal of the American Statistical Association*, 1984, 79(388): 871-880.
- [10] YAN Q, XU Y, YANG X K. HEASK: robust homography estimation based on appearance similarity and keypoint correspondences [J]. *Pattern Recognition*, 2014, 47(1): 368-387.
- [11] MOU W, WANG H, SEET G. Robust homography estimation based on nonlinear least squares optimization [J]. *Mathematical Problems in Engineering*, 2014: 372-377.
- [12] CHUM O, MATAS J. Matching with progressive sample consensus [C]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2005, 220-226.
- [13] RAGURAM R, FRAHM J M, POLLEFEYS M. A comparative analysis of ransac techniques leading to adaptive real-time random sample consensus [C]. *European Conference on Computer Vision*, 2008, 500-513.
- [14] TORR P, ZISSERMAN A. Mlesac: a new robust estimator with application to estimating image geometry [J]. *Computer Vision and Image Understanding*, 2000, 78(1): 138-156.
- [15] TORR P. Bayesian model estimation and selection for epipolar geometry and generic manifold fitting [J]. *International Journal of Computer Vision*, 2002, 50(1): 35-61.
- [16] LEBEDA K, MATAS J, CHUM O. Fixing the locally optimized RANSAC [C]. *Proceeding of the British Machine Vision Conference, Guildford, ENGLAND*, 2012.
- [17] LOWE D. Distinctive image features from scale-invariant keypoints [J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.
- [18] BAY H, TUYTELAARS T. SURF: Speeded Up Robust Features [C]. *European Conference on Computer Vision, Graz, Austria*, 2006: 404-417.
- [19] STEELE R MATT, CHRISTOPHERh JAYNES. Feature uncertainty arising from covariant image noise [C]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Diego, CA*, 2005: 1063-1070.
- [20] ABDEL-HAKIM A E, FARAG A A. Farag. A novel stability quantification of detected interest points in scale-space [C]. *International Conference on Pattern Recognition, Tampa, FL*, 2008, 124-127.
- [21] BEMHARD Z, PIERRE F G, FLORIAN S, et al.. Estimation of location uncertainty for scale invariant feature points [C]. *British Machine Vision Conference, London, United Kingdom*, 2009, 1-12.

作者简介:



赵春阳(1980—),男,辽宁锦州人,博士研究生,副研究员,2002年、2005年于东北大学分别获得学士、硕士学位,主要从事目标识别与跟踪方面的研究。E-mail: zcyneu@sina.com, zhaocy@sia.cn

导师简介:



赵怀慈(1974—),男,山东潍坊人,博士研究生,研究员,博士生导师,1996年、1999年于山东大学分别获得学士、硕士学位,2003年于中国科学院沈阳自动化研究所获得博士学位,主要从事复杂系统建模与仿真,指挥、控制、通信与信息处理技术以及图像处理等方面的研究。E-mail: hczhao@sia.cn