

低秩和稀疏分解的立体影像匹配错误点检测

张正鹏¹, 张 强²

(1. 辽宁工程技术大学 测绘与地理科学学院, 辽宁 阜新 123000;

2. 珠海欧比特宇航科技股份有限公司, 广东 珠海 519000)

摘要: 提出一种基于低秩和稀疏分解的立体影像匹配错误点检测方法. 以正确匹配点的运动结构相似性和错误匹配点的稀疏性为约束条件, 考虑局部最近邻匹配点间的运动低秩特征, 引入图拉普拉斯约束项来表达这种局部低秩性, 在此基础上构建影像间匹配点的低秩和稀疏优化模型. 采用自适应惩罚的线性化交替方向法推导并完成模型的低秩和稀疏分解. 统计稀疏矩阵奇异值特征, 以此为判断条件进行正确与错误匹配点的检测. 实验选择具有高度纹理重复特征的立体像对, 分别对比和分析不同转角下影像错误匹配点的检测精度. 结果表明: 在高纹理重复特征、高重叠度下, 提出的方法较经典方法能更好的区分正确与错误匹配点, 在正确率、召回率、精度和 F 值(F-measure)指标评价方面表现占优.

关键词: 低秩; 稀疏分解; 运动结构特征; 影像匹配

中图分类号: P 237 **文献标志码:** A **文章编号:** 1000-1964(2020)03-0595-07

Image matching error point detection based on low-rank and sparse decomposition

ZHANG Zhengpeng¹, ZHANG Qiang²

(1. School Geomatics, Liaoning Technical University, Fuxin, Liaoning 123000, China;

2. Zhuhai Orbita Aerospace Science & Technology Co., Ltd., Zhuhai, Guangdong 519000, China)

Abstract: A method of stereo image matching error point detection based on low rank and sparse decomposition was proposed. Based on the constraints of the similarity of motion structure and the sparsity of error matching points, and considering the low rank feature of motion between local nearest matching points, the constraint term of laplacian eigenmaps was introduced in order to express this local low rank property, on this basis, a low rank and sparsity optimization model of image matching points were constructed. Linearized alternating direction method with adaptive penalty was used to derive and complete the low rank and sparse decomposition of the model. The feature of singular value of sparse matrix was counted to complete the detection of correct and wrong matching points. The experiment choosed stereo image pairs with high texture repetition characteristics, and compared and analysed the detection accuracy of image error matching points under different rotation angles. The results show that under the condition of high texture repetition and high overlap, the proposed method could distinguish correct and wrong matching points better than the classical method, and is superior in accura-

收稿日期: 2019-03-09

基金项目: 国家自然科学基金项目(41801294); 辽宁省自然科学基金项目(20180551209)

通信作者: 张正鹏(1981-), 男, 河南省信阳市人, 副教授, 工学博士, 从事遥感影像解译、视觉 SLAM 等方面的研究.

E-mail: zhangzhengpeng2004@126.com Tel: 0418-5110052

引用格式: 张正鹏, 张 强. 低秩和稀疏分解的立体影像匹配错误点检测[J]. 中国矿业大学学报, 2020, 49(3): 595-601.

ZHANG Zhengpeng, ZHANG Qiang. Image matching error point detection based on low-rank and sparse decomposition[J]. Journal of China University of Mining & Technology, 2020, 49(3): 595-601.

cy, recall, accuracy and F-measure index evaluation.

Key words: low-rank; sparse decomposition; moving structural feature; image matching

目前立体影像的匹配方法主要有基于像方的灰度相关和光流跟踪法. 但受光照、尺度变化、深度不连续以及重复纹理等影响, 匹配后仍存在大量的错误匹配点. 因此, 基于几何约束的错误匹配点检测方法被陆续提出, 可分为全局法和局部法两大类.

全局法认为立体影像间满足全局几何一致性, 如对极几何、投影几何等, 通过在像方和物方构建全局几何一致性模型实现错误匹配点的检测. 文献[1-2]分别提出了基于随机抽样最大似然(MLESAC)和抽样一致性的极几何模型估计方法. 但当低内点率、场景中存在多个几何模型变换时, 上述方法往往无法精确求解模型, 造成错误匹配点检测失败或仅保留显著场景的正确匹配点; 文献[3-6]提出了基于极线、平移量、角度、尺度等约束条件的错误匹配点检测方法; 另外在摄影测量领域, 通常建立像方和物方的多视匹配约束关系来检测错误匹配点[7], 但该方法通常需要已知外参, 或依赖于高精度的外参估计. 局部法认为立体影像间满足局部几何一致性, 通过在像方和物方构建局部几何一致性模型实现错误匹配点的检测; 文献[8]提出了一种光流特征聚类辅助极几何约束的方法, 较好地克服了低内点率情况下极几何模型估计不准确的问题, 但该方法受限于聚类半径与精度的影响; 文献[9]提出了一种基于位置邻接关联和拓扑关系一致性约束的错误匹配点检测方法, 但该方法依赖 RPC 参数, 且邻接关系约束受直线匹配精度影响; 另一类方法是在物方建立局部几何约束条件, 在像方进行错误匹配点的检测[10]. 该类方法虽然增加了物方对像方匹配点的几何约束, 但该方法同样需要已知外参, 或依赖于高精度的外参估计.

综上, 全局法的优点是模型统一简单, 在目标单一场景且较高内点率的条件下, 可以较好的检测出错误匹配点; 缺点是当低内点率情况下, 模型的求解效率降低. 局部法的优点是允许场景中存在多模型的几何变换, 错误匹配点的检测效率较高; 缺点是不易表达局部特征和作用域范围. 本文综合全局法和局部法的优点, 以低秩和稀疏分解理论为基础, 提出一种低秩稀疏模型的错误匹配点检测方法.

1 低秩稀疏分解

如果数据采用一个矩阵表示, 并且各行或各列间存在一定的相关性, 即矩阵的秩远小于矩阵的大小, 那么这个数据矩阵就是低秩的. 对于低秩和近似低秩的数据矩阵 D , 伴随着随机幅值的任意增大, 往往会产生分布稀疏的误差, 从而破坏数据矩阵原有的低秩性, 如含有噪声的视频影像, 其视频序列的背景为低秩特征, 而噪声为稀疏特征[11]. 在实际应用中可以利用这种低秩和稀疏特征来完成视频的降噪[11]、多模型拟合[12]、视频分割[13]等任务.

为了恢复数据矩阵的低秩结构(去除噪声), 将矩阵 D 分解为两个矩阵之和, 即 $D = A + E$, 其中矩阵 A 表示数据矩阵中的低秩组成(如视频背景), 矩阵 E 表示数据矩阵中的稀疏组成(如噪声). 采用鲁棒的主成分分析法[14](RPCA), 则低秩和稀疏优化模型 $f(A, E)$ 可表示为

$$f(A, E) = \underset{A, E}{\operatorname{argmin}} \|A\|_* + \lambda \|E\|_1, \quad (1)$$

$$\text{s. t. } D = A + E,$$

式中: $\|A\|_*$ 为矩阵 A 的秩; λ 为正则化参数.

2 低秩与稀疏分解的错误匹配点检测方法

2.1 运动结构相似度

采用尺度不变特征(SIFT)方法[3]进行初始匹配, 从全局和局部角度分析匹配结果的结构特征(图 1), 为了更清晰的表达, 我们分离正确与错误匹配点, 图 1c, 1d 为在左视图上显示的全局匹配点和线分布特征; 图 1e 为在左右视图间显示的局部匹配点和线分布特征. 通过分析可得如下结论:

1) 从图 1a, 1b 可以看出, 左右视图初始匹配点的几何分布整体上满足全局结构的相似性特征(错误匹配点除外);

2) 从图 1c, 1d 可以看出, 正确匹配点从左视图到右视图的运动矢量大致满足全局的相似性, 而错误匹配点的运动矢量在大小和方向上与正确匹配点的运动矢量有较大的差异;

3) 从图 1e 可以看出, 正确匹配点(图 1e2)的运动矢量在一定范围内满足局部的高度相似性(即方向和幅度一致), 而错误匹配点(图 1e3)的运动矢量, 在方向和幅度上均和正确匹配点有差异, 而且正确匹配点的数量往往占优(即特征匹配通常内点率高于外点率).



图 1 立体影像初始匹配运动结构特征分析

Fig. 1 Motion structural features analysis of initial matching for stereo images

综上,正确匹配点在局部范围内满足运动矢量的几何一致性(或相似性),可以认为正确匹配点具备了运动矢量的低秩性,而错误匹配点表现为运动矢量的随机性和稀疏性特征.因此可以将低秩和稀疏分解理论引入错误点匹配检测中,基本方法描述如下:

1) 将立体影像的 m 个初始匹配点,按横纵坐标 x, y 组成一个 $m \times 2$ 的坐标矩阵 X ,记第 i 个初始匹配点在左影像和右影像上的坐标向量分别为 $X_{i1} = (x_{i1}, y_{i1}), X_{i2} = (x_{i2}, y_{i2})$,并构成坐标矩阵 X 的一个行向量为 $(x_{i1}, y_{i1}, x_{i2}, y_{i2})$.

2) 利用匹配点间光流运动矢量来表达式(1)中的数据矩阵 D ,称为影像间运动结构的相似度矩阵,则其 r 行 c 列表示为

$$D(r, c) = \exp\left(\frac{-d_D(r, c)^2}{\sigma}\right), \quad (2)$$

$$d_D(r, c) = 1 - \frac{\langle \Phi^r, \Phi^c \rangle}{\|\Phi^r\|^2 + \|\Phi^c\|^2 - \langle \Phi^r, \Phi^c \rangle},$$

$$\langle \Phi^r, \Phi^c \rangle = \text{tr}(\Phi^r (\Phi^c)^T),$$

$$\Phi^r = (X_{r1} - X_{r2}),$$

$$\Phi^c = (X_{c1} - X_{c2}),$$

式中: Φ^r, Φ^c 分别为第 r 个和第 c 个匹配点的运动矢量; $d_D(r, c)$ 为每两对匹配点运动矢量间的 Tanimoto 相似性度量^[12]; σ 为标准差.

3) 对运动结构的相似度矩阵 D 进行低秩和稀疏分解建模,由式(1)可知,分解后的 A 为满足运动结构相似性的低秩矩阵, E 为错误匹配点的稀疏矩阵.

2.2 图拉普拉斯矩阵

由式(1)可知,低秩稀疏模型分解的 A 为全局低秩矩阵,即要求正确匹配点间满足全局运动矢量的一致性.而从上述分析可知,实际匹配点间往往表现为全局近似一致、局部高度一致特征.因此在式(1)的基础上,引入图拉普拉斯约束项^[15]来表达这种局部低秩性,则模型 $f(A, E)$ 表示为

$$f(A, E) = \underset{A, E}{\text{argmin}} \|A\|_* + \lambda \|E\|_1 + \beta \text{tr}(A^T P A), \quad (3)$$

$$A_{t+1} = \underset{A}{\text{argmin}} \|A\|_* + q(A, E, Z, Y_1, Y_2, \mu) =$$

$$\text{s. t. } D = A + E,$$

$$P = H - W, \quad (4)$$

$$W_{rc} = \frac{1}{1 + d_W(r, c)^2},$$

$$d_W(r, c) = 1 - \frac{\langle \Psi^r, \Psi^c \rangle}{\|\Psi^r\|^2 + \|\Psi^c\|^2 - \langle \Psi^r, \Psi^c \rangle}, \quad (5)$$

$$\Psi = X_{i1},$$

式中: β 为局部低秩约束的正则化参数; P 为图拉普拉斯矩阵; λ 默认为 $[\text{size}(D)]^{-0.5}$ ($\text{size}(D)$ 为矩阵 D 的列数,即匹配点的个数 m); H 为对角矩阵, $H_{rr} = \sum_{c=1}^m W_{rc}$; W 为距离相似度矩阵; W_{rc} 为矩阵 W 的 r 行 c 列元素; $d_W(r, c)$ 为每两个特征点间距离的 Tanimoto 相似性度量^[12]; Ψ 为左影像特征点坐标组成的向量.

2.3 算法求解

由于式(3)中增加了图拉普拉斯约束项,采用 RPCA 方法无法直接求解 A . 采用文献[14]方法,引入一个辅助变量 Z , 令 $A = Z$, 则式(3)的增广拉格朗日函数 $L(A, E, Z, P, Y_1, Y_2, \mu)$ 可表示为

$$L(A, E, Z, P, Y_1, Y_2, \mu) = \|A\|_* + \lambda \|E\|_1 + \beta \text{tr}(Z^T P Z) + q(A, E, Z, Y_1, Y_2, \mu) - \frac{1}{2\mu} (\|Y_1\|_F^2 + \|Y_2\|_F^2), \quad (6)$$

$$q(A, E, Z, Y_1, Y_2, \mu) =$$

$$\frac{\mu}{2} \left(\left\| D - A - E + \frac{Y_1}{\mu} \right\|_F^2 + \right.$$

$$\left. \left\| A - Z + \frac{Y_2}{\mu} \right\|_F^2 \right).$$

式(6)存在 A, E, Z 等多个变量,可采用交替方向法进行低秩和稀疏分解.然而交替方向法在求解式(6)时每次迭代都需要矩阵求逆操作.因此采用具有自适应惩罚的线性化交替方向法^[14]求解,即将式(6)中的 q 替换为其上一次迭代时的一阶近似函数加上一个近似项的形式,固定其它变量,求解低秩矩阵 A , 则其第 $t+1$ 次迭代可表示为

$$\begin{aligned} & \operatorname{argmin} \| \mathbf{A} \|_* + \langle \nabla_{\mathbf{A}} q(\mathbf{A}_t, \mathbf{E}_t, \mathbf{Z}_t, \mathbf{Y}_{1,t}, \mathbf{Y}_{2,t}, \mu_t), \mathbf{A} - \mathbf{A}_t \rangle + \frac{\eta \mu_t}{2} (\| \mathbf{A} - \mathbf{A}_t \|_{\mathbb{F}}^2) = \\ & \operatorname{argmin} \| \mathbf{A} \|_* + \frac{\eta \mu_t}{2} \left(\left\| \mathbf{A} - \mathbf{A}_t + \left[- \left(\mathbf{D} - \mathbf{A}_t - \mathbf{E}_t + \frac{\mathbf{Y}_{1,t}}{\mu_t} \right) + \left(\mathbf{A}_t - \mathbf{Z}_t + \frac{\mathbf{Y}_{2,t}}{\mu_t} \right) \right] / \eta \right\|_{\mathbb{F}}^2 \right) = \\ & \Theta_{(\eta_t)}^{-1} \left(\mathbf{A}_t + \left[\mathbf{D} - 2\mathbf{A}_t - \mathbf{E}_t + \mathbf{Z}_t + (\mathbf{Y}_{1,t} - \mathbf{Y}_{2,t}) / \mu_t \right] / \eta \right), \end{aligned} \quad (7)$$

式中: $\nabla_{\mathbf{A}} q$ 表示 q 对 \mathbf{A} 取一阶导数操作; $\Theta_{(\cdot)}(\cdot)$ 表示软阈值操作^[16]; η 为大于 0 的正数。

固定其它变量,采用交替方向法^[14]求解式(6)中的稀疏矩阵 \mathbf{E} ,则其第 $t+1$ 次迭代可表示为

$$\begin{aligned} \mathbf{E}_{t+1} &= \operatorname{argmin} \lambda \| \mathbf{E} \|_1 + \operatorname{tr}(\mathbf{Y}_{1,t}^T (\mathbf{D} - \mathbf{A}_{t+1} - \mathbf{E})) + \frac{\mu_t}{2} \| \mathbf{D} - \mathbf{A}_{t+1} - \mathbf{E} \|_{\mathbb{F}}^2 = \\ & \operatorname{argmin} \frac{\lambda}{\mu_t} \| \mathbf{E} \|_1 + \frac{1}{2} \left\| \mathbf{E} - \left(\mathbf{D} - \mathbf{A}_{t+1} + \frac{\mathbf{Y}_{1,t}}{\mu_t} \right) \right\|_{\mathbb{F}}^2 = \Omega_{\lambda/\mu_t}^{-1} \left(\mathbf{D} - \mathbf{A}_{t+1} + \frac{\mathbf{Y}_{1,t}}{\mu_t} \right), \end{aligned} \quad (8)$$

式中 $\Omega_{(\cdot)}(\cdot)$ 表示软阈值操作^[16]。

固定其它变量,对式(6)中的辅助变量 \mathbf{Z} 求导并等于 0,则 \mathbf{Z} 的第 $t+1$ 次迭代为

$$\mathbf{Z}^{t+1} = (\beta(\mathbf{P} + \mathbf{P}^T) + \mu_t \mathbf{I})^{-1} (\mathbf{Y}_{2,t} + \mu_t \mathbf{A}_{t+1}), \quad (9)$$

式中 \mathbf{I} 为单位矩阵。

更新 $\mathbf{Y}_1, \mathbf{Y}_2$ 的第 $t+1$ 次迭代为

$$\mathbf{Y}_{1,t+1} = \mathbf{Y}_{1,t} + \mu_t (\mathbf{D} - \mathbf{A}_{t+1} - \mathbf{E}_{t+1}), \quad (10)$$

$$\mathbf{Y}_{2,t+1} = \mathbf{Y}_{2,t} + \mu_t (\mathbf{A}_{t+1} - \mathbf{Z}_{t+1}), \quad (11)$$

$$\mu_{t+1} = \rho \mu_t, \quad (12)$$

式中 ρ 为步长。

2.4 错误匹配点的检测

采用上述方法分解模型 $f(\mathbf{A}, \mathbf{E})$,可知分解后的 \mathbf{E} 为错误匹配点的稀疏矩阵,因此,通过统计稀疏矩阵 \mathbf{E} 的奇异值特征来判定错误匹配点,具体方法为:

- 1) 计算稀疏矩阵 \mathbf{E} 中每个列向量的奇异值,并组成一个奇异值向量 ζ ,计算其奇异值均值 $\bar{\zeta}$;
- 2) 计算 ζ 的标准差 σ_{ζ} ;
- 3) 判断某列向量奇异值 ζ_i 与 $\bar{\zeta}$ 之差是否大于 k 倍奇异值向量标准差 σ_{ζ} ,即 $\zeta_i - \bar{\zeta} > k\sigma_{\zeta}$,如果是,则该列向量对应的匹配点为错误匹配点,否则,该列对应的匹配点为正确匹配点。

3 实验结果与讨论

实验选择具有高度纹理重复性的城堡数据共 3 组,分别为水平方向小转角立体像对 00-01、垂直方向倾斜立体像对 06-07、水平方向大转角小重叠度立体像对 08-11。首先采用 SIFT 算法对立体影

像进行初始匹配(最近邻距离与次近邻距离的比率设置为 0.6),然后采用本文方法进行错误匹配点的检测,对比分析经典方法 MLESAC^[1],并采用正确率、召回率、精度和 F 值 4 个评价指标^[17]对检测结果进行定量评价。其中 MLESAC 方法采用默认参数,即迭代次数为 500 次,Sampson 距离阈值为 0.01,由于受极几何模型求解精度的影响,错误匹配点的检测结果是变化的,因此采用算法运行 10 次中对错误匹配检测点数最少(MLESAC_min)和最多的结果(MLESAC_max)作为 MLESAC 的实验结果。本文方法的实验参数统一设置为: $\sigma = 0.2, \mu_0 = 0.01, \rho = 1.5$ 。

3.1 水平方向小转角立体像对(00-01 数据)

第 1 组数据为水平方向小转角的立体像对,图 1a,1b 为左右视图初始匹配点,共计 2 256 对,可以看出立体影像对具有高度的纹理重复性,如墙体、窗户等,SIFT 匹配方法受纹理重复性的影响,初始匹配结果中含有大量的错误匹配点(图 1d),共计 100 对。

3.1.1 随 β 变化匹配检测结果分析

固定奇异值倍率 $k=1$,随模型 β 变化,本文方法检测结果如图 2 所示,与图 1d 对比可以发现,本文方法可以较好地检测出错误匹配点,其中图 2a,2b 和真实数据非常接近。由式(3)可知, β 为局部低秩约束的正则化参数,可以看出随着 β 的增大,即增强局部低秩性的约束,减弱了错误匹配点的稀疏约束,导致检测出的错误匹配点的点数逐渐减少,但检测的精度逐渐增加,如图 2f。



图 2 随 β 变化本文方法检测结果

Fig. 2 Gross error detection results with variation of parameters β

表 1 为随 β 变化本文方法检测结果评价。利用真实数据(图 1d)分别统计本文方法随 β 变化检测结果的真阳性(TP , 代表检测出的错误匹配点数量)、假阳性(FP , 代表误检测为错误匹配点数量)、假阴性(FN , 代表未检测出的错误匹配点数量)和真阴性(TN , 代表检测出的正确匹配点数量)。然后计算正确率等 4 个评价参数。从表 1 可以看出, 随 β 的增大, 检测错误点数量、正确率、召回率、 F 值逐渐减小, 而精度逐渐提高。精度的增加、召回率的减小, 表明随 β 的增大, 被判定为错误的匹配点为真实错误匹配点的精度更高, 同时也有更多的真实错误匹配点没有检测出。因此为了达到二者的平衡, 一般采用 F 值进行综合评价。当 $\beta = 0$ 和 $\beta = \lambda/2$ 时, 既满足了较高的召回率, 也满足了较高的精度。而实际应用中, 更希望检测方法能尽可能的判断出更多的错误匹配点的同时, 减少正确匹配点的误判。获得更多的正确匹配点, 即 TN 更大, 显然 $\beta = 0$ 和 $\beta = \lambda/2$ 时, 本文算法表现较好。

表 1 随 β 变化检测结果评价
Table 1 Evaluation of gross error detection results with variation of β

β	错误点/个	匹配点/个				正确率	召回率	精度	F 值
		TP	FP	FN	TN				
0	95	77	18	23	2 138	0.982	0.770	0.811	0.790
$\lambda/2$	101	78	23	22	2 133	0.980	0.780	0.772	0.776
λ	87	69	18	31	2 138	0.978	0.690	0.793	0.738
2λ	66	57	9	43	2 147	0.977	0.570	0.864	0.687
0.5	51	48	3	52	2 153	0.976	0.480	0.941	0.636
1.0	43	42	1	58	2 155	0.974	0.420	0.977	0.587

3.1.2 随 k 变化匹配检测结果分析

固定 $\beta = \lambda/2$, 分析奇异值的倍率 k 的变化对匹配结果的影响。图 3 为随着 k 的变化($k = 0.2, 0.5, 1.0, 3.0$)本文方法检测结果, 与图 1d 对比可以发现, 本文方法随着 k 的增大, 检测出的错误匹配点精度变高, 但数量变少。

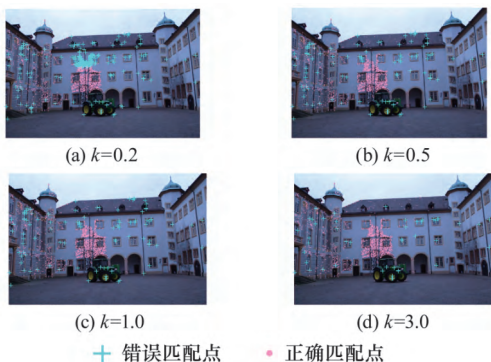


图 3 随 k 变化本文方法检测结果
Fig. 3 Gross error detection results with variation of k

表 2 为随 k 变化本文方法检测结果评价。从表

2 可以看出, 随 k 的增大, 检测错误点数量、召回率逐渐减小, 但正确率、精度和 F 值逐渐增大, 说明 k 同样影响本文方法的检测结果。从 F 值可以看出, $k = 0.5$ 和 1.0 时综合评价指数最优。

表 2 随 k 变化检测结果评价
Table 2 Evaluation of gross error detection results with variation of k

k	错误点/个	匹配点/个				正确率	召回率	精度	F 值
		TP	FP	FN	TN				
0.2	343	83	260	17	1 896	0.877	0.830	0.242	0.375
0.5	103	79	24	21	2 132	0.980	0.790	0.767	0.778
1.0	101	78	23	22	2 133	0.980	0.780	0.772	0.776
3.0	47	41	6	59	2 150	0.971	0.410	0.872	0.558

3.1.3 不同方法对比分析

根据以上模型参数的变化对匹配结果的影响分析, 本文方法设置最优参数为 $k = 1.0, \beta = \lambda/2$, 与经典 MLESAC 方法进行对比实验。从图 4 可以看出, 立体匹配数据具有极高纹理重复性, 且场景中地物存在尺度的变化。MLESAC 方法受极几何模型求解精度的影响, 检测结果十分不稳定(图 4c, 4d)。而本文方法可较好地场景中的正确和错误匹配点区分开(图 4a)。

表 3 为不同方法检测结果的定量评价。从表 3 可以看出, 本文方法在正确率、召回率、精度和 F 值指标中均表现最优。




图 4 不同方法匹配点检测结果(00-01 数据)
Fig. 4 Gross error detection results by different methods

表 3 不同方法匹配点检测结果评价(00-01 数据)
Table 3 Evaluation of gross error test results by different methods

方法	错误点/个	匹配点/个				正确率	召回率	精度	F 值
		TP	FP	FN	TN				
MLESAC_min	45	44	1	56	2 155	0.975	0.440	0.978	0.607
MLESAC_max	157	80	77	20	2 079	0.957	0.800	0.510	0.623
本文方法	128	79	49	21	2 107	0.969	0.790	0.617	0.693

3.2 垂直方向倾斜立体像对(06-07 数据)

第 2 组数据为垂直方向倾斜立体像对。图 5a, 5b 为左右视图初始匹配点, 共计 2 086 对。从图 5c

可以看出,该组立体像对间具有上下、远近方向上的运动,但正确匹配点间整体上满足向中心运动的结构相似性、错误匹配点间满足运动结构的不一致性和稀疏性.初始匹配结果中含有错误匹配点共计 145 对.图 5d 为本文方法检测结果,参数 $k = 1.0$,




图 5 不同方法匹配点检测结果(06-07 数据)

Fig. 5 Detection results of matching gross errors by different matching methods

表 4 为不同方法匹配点检测结果的定量评价,从表 4 可以看出,本文方法在各项指标中均最优.

表 4 不同方法匹配点检测结果评价(06-07 数据)

Table 4 Evaluation of matching gross error detection results by different matching methods

方法	错误点/个		匹配点/个				正确率	召回率	精度	F 值
	TP	FP	FN	TN						
MLESAC_min	34	32	2	113	1 939	0.945	0.221	0.941	0.358	
MLESAC_max	120	117	3	28	1 938	0.985	0.807	0.975	0.883	
本文方法	131	129	2	16	1 939	0.991	0.890	0.985	0.935	

3.3 水平方向大转角小重叠度立体像对(08-11 数据)

第 3 组数据为水平方向大转角小重叠度立体



图 6 不同方法匹配点检测结果(08-11 数据)

Fig. 6 Detection results of matching gross errors by different matching methods

表 5 为不同方法的匹配点检测结果的定量评价.

表 5 不同方法匹配点检测结果评价(08-11 数据)

Table 5 Evaluation of matching gross error detection results by different matching methods

方法	错误点/个		匹配点/个				正确率	召回率	精度	F 值
	TP	FP	FN	TN						
MLESAC_min	32	32	0	17	119	0.899	0.653	1.000	0.790	
MLESAC_max	42	42	0	7	119	0.958	0.857	1.000	0.923	
本文方法	38	38	0	11	119	0.935	0.776	1.000	0.874	

从表 5 可以看出,本文方法表现不如 MLESAC_max,分析原因,本文方法是建立在运动结构相似性原则基础上,并且至少需要保证正确匹配点占优且局部运动的相似性,对于大转角低重叠度的立体像对,其匹配点数量减少.因此局部运动的相似性约束减弱是导致本文方法各项指标下降的主要原因,而这种情况在具有大量密集正确匹配

$\beta = \lambda/2$.对比真实数据(图 5c)可以看出,本文方法检测出的错误匹配点与真实数据非常相近,图 5e, 5f 为 MLESAC 方法的检测结果,可以看出受纹理重复性和垂直方向尺度变化的影响,检测结果并不稳定.

像对.图 6a,6b 为左右视图初始匹配点,共计 168 对.从图 6c 可以看出该组立体像对间呈现左右方向上的运动,左侧正确匹配点间向斜下方,右侧正确匹配点间向斜上方的局部运动结构相似性,错判匹配点间运动结构依旧呈现不一致性和稀疏性.初始匹配结果中含有错误匹配点共计 49 对.图 6d 为本文方法检测结果,参数 $k = 1.0, \beta = \lambda/2$.对比真实数据(图 6c)可以看出,本文方法检测出的错误匹配点与真实数据相近,图 6e,6f 为 MLESAC 方法的检测结果,可以看出受纹理重复性和水平方向尺度变化的影响,检测结果并不稳定.

点分布的数据 00-01 和 06-07 中并没有出现.

4 结 论

本文研究了一种局部运动相似性的影像错误匹配点检测方法.由于结合了运动结构相似性的几何一致性约束条件,利用低秩和稀疏理论进行模型表达.因此可实现稳健的错误匹配点检测,尤其对高重复性纹理、高重叠度的立体像对具有非常好的检测效果,可以有效克服 MLESAC 方法在错误匹配点检测中表现的不稳定性,为立体影像匹配错误点的检测提供了一种新的思路和方法.

由于局部低秩性要求正确匹配点占优且运动结构需要满足相似性,而错误匹配点呈现离散的稀疏性.因此对于大转角低内点率的立体匹配情况,本文方法往往不能得到最优的效果,而且该方法受

相关参数的影响. 研究参数的自适应性、以及混合其它几何结构相似性(如极几何、单应性等)的低秩匹配方法是今后研究的方向.

参考文献:

- [1] TORR P H S, ZISSERMAN A. MLESAC: A new robust estimator with application to estimating image geometry[J]. *Computer Vision & Image Understanding*, 2000, 78(1): 138-156.
- [2] HARTLEY R, ZISSERMAN A. Multiple view geometry in computer vision[M]. Cambridge: Cambridge University Press, 2003: 43-45.
- [3] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.
- [4] 张正鹏, 江万寿, 张 靖. 车载立方体全景影像匹配点的粗差检测方法[J]. *武汉大学学报(信息科学版)*, 2014, 39(10): 1208-1213.
ZHANG Zhengpeng, JIANG Wanshou, ZHANG Jing. A gross error detection method of vehicle-borne cubic panoramic image sequence[J]. *Geomatics and Information Science of Wuhan Univers*, 2014, 39(10): 1208-1213.
- [5] ZHAO W L, WU X, NGO C W. On the annotation of web videos by efficient near-duplicate search [J]. *IEEE Transactions on Multimedia*, 2010, 12(5): 448-461.
- [6] WANG J, TANG J, JIANG Y G. Strong geometrical consistency in large scale partial-duplicate image search[C]//ACM International Conference on Multimedia. Huangshan: ACM, 2013: 633-636.
- [7] 王 密, 杨 博, 李德仁, 等. 资源三号全国无控制整体区域网平差关键技术及应用[J]. *武汉大学学报(信息科学版)*, 2017, 42(4): 427-433.
WANG Mi, YANG Bo, LI Deren, et al. Technologies and applications of block adjustment without control for ZY-3 images covering China[J]. *Geomatics and Information Science of Wuhan Univers*, 2017, 42(4): 427-433.
- [8] 张正鹏, 江万寿, 张 靖. 光流特征聚类的车载全景序列影像匹配方法[J]. *测绘学报*, 2014, 43(12): 1266-1273.
ZHANG Zhengpeng, JIANG Wanshou, ZHANG Jing. An image match method based on optical flow feature clustering for vehicle-borne panoramic image sequence[J]. *Acta Geodactica et Cartographica Sinica*, 2014, 43(12): 1266-1273.
- [9] 杜春鹏, 李景山. 一种结合拓扑信息和 SIFT 特征的多源遥感影像自动匹配方法[J]. *测绘通报*, 2017(10): 115-119.
DU Chunpeng, LI Jingshan. A multi-sensor remote sensing image automatic matching method based on topological information and SIFT features[J]. *Bulletin of Surveying and Mapping*, 2017(10): 115-119.
- [10] 李智强. 资源卫星影像匹配粗差剔除算法设计与实现[J]. *测绘科学*, 2017, 42(6): 202-206.
LI Zhiqiang. Design and implementation of the algorithm for eliminating image matching gross errors of resource satellite image[J]. *Science of Surveying and Mapping*, 2017, 42(6): 202-206.
- [11] LU X, WANG Y, YUAN Y. Graph-regularized low-rank representation for destriping of hyperspectral images[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2013, 51(7): 4009-4018.
- [12] MAGRI L, FUSIELLO A. Robust multiple model fitting with preference analysis and low-rank approximation [C]//British Machine Vision Conference. Swansea: BMVA Press, 2015: 1-20.
- [13] LI C, LIN L, ZUO W, et al. An approach to streaming video segmentation with sub-optimal low-rank decomposition[J]. *IEEE Transactions on Image Processing*, 2016, 25(5): 1947-1960.
- [14] LIN Z, LIU R, SU Z. Linearized alternating direction method with adaptive penalty for low-rank representation [C]//Advances in Neural Information Processing Systems. Spain: Curran Associates, 2011: 612-620.
- [15] BELKIN M, NIYOGI P. Laplacian eigenmaps and spectral techniques for embedding and clustering [J]. *Advances in Neural Information Processing Systems*, 2001, 14(6): 585-591.
- [16] CAI J F, CANDE S, EMMANUEL J, et al. A singular value thresholding algorithm for matrix completion[J]. *Siam Journal on Optimization*, 2008, 20(4): 1956-1982.
- [17] GRISHMAN R. Information extraction: Techniques and challenges [C]//International Summer School on Information Extraction: A Multidisciplinary Approach to an Emerging Information Technology. London: Springer-Verlag, 1997: 10-27.

(责任编辑 邓 群)