

文章编号 1004-924X(2024)20-3071-14

变分近似解算 KL 散度红外可见光遥感图像配准

王佳¹, 吴昊^{2*}, 傅瑞罡³, 孔玲爽¹, 左毅¹

(1. 长沙学院 电子信息与电气工程学院, 湖南 长沙 410022;

2. 合肥综合性国家科学中心 数据空间研究院, 安徽 合肥 230000;

3. 国防科技大学 电子科学学院, 湖南 长沙 410073)

摘要:为解决基于传统的距离相似性度量函数在异源遥感图像配准任务中抗噪性能差的问题,提出基于变分近似解算 KL 散度的红外/可见光遥感图像配准方法。首先,对红外实时图像和可见光基准图像分别提取边缘特征,得到异源图像共性特征;然后,利用成像位姿信息对红外图像边缘特征点集进行正射校正,并对红外/可见光图像特征点集分别构建高斯混合模型;接着,将两个高斯混合模型之间的 KL(Kullback-Leibler)散度值作为图像相似性度量函数,并引入带约束的变分参量,利用拉格朗日乘数法解算出变分参量,实现近似求解 KL 散度值的目标;最后,采用粒子群优化算法搜索最佳配准参数,实现图像配准。在遥感图像对比实验结果中,本文方法的配准参数均方根误差平均值为 2.5,平均运行时间为 1.5 s;在高斯噪声方差和椒盐噪声系数为 0.07 时,仍能实现正确配准。表明本文方法具有较强的鲁棒性和运算效率。

关键词:变分近似法;KL 散度;图像配准;遥感图像

中图分类号:TP751 文献标识码:A doi:10.37188/OPE.20243220.3071

Infrared-visible remote sensing image registration method based on Kullback-Leibler divergence using variational approximation

WANG Jia¹, WU Hao^{2*}, FU Ruigang³, KONG Lingshuang¹, ZUO Yi¹

(1. School of Electronic Information and Electrical Engineering, Changsha University,
Changsha 410022, China;

2. Institute of Dataspace, Hefei Comprehensive National Science Center, Hefei 230000, China;

3. College of Electronic Science and Technology, National University of Defense Technology,
Changsha 410073, China)

* Corresponding author, E-mail: wuhao@idata.ah.cn

Abstract: To solve the problem of poor robustness of distance-based metrics in multi-sensor remote sensing image registration methods, an image registration algorithm based on Kullback-Leibler divergence using variational approximation was proposed. First, edge features were extracted from the infrared image and visible image, respectively. Second, the infrared image features were orthorectified using imaging poses, and Gaussian Mixture Models (GMMs) were constructed for the feature point sets of the infrared and visible images, respectively. Third, the Kullback-Leibler divergence between the two GMMs was calcu-

收稿日期:2024-05-13;修订日期:2024-07-22.

基金项目:国家自然科学基金项目(No. 62201092);湖南省自然科学基金(No. 2023JJ30085);湖南省教育厅基金(No. 22A0599);

lated using the variational approximation method, in which variational parameters were introduced and the Lagrange multiplier was utilized. Finally, the Particle Swarm Optimization (PSO) algorithm was applied to search for the optimal registration parameters. In the remote sensing image registration experiments, the proposed method's average Root Mean Square Error of registration parameters is 2.5, and the average runtime is 1.5 seconds. Additionally, the proposed method still achieves correct registration when the variance of Gaussian noise and the salt-and-pepper noise coefficient is 0.07, respectively. These results validate the robustness and high computational efficiency of our method.

Key words: variational approximation; kullback-leibler divergence; image registration; remote sensing

1 引言

异源遥感图像配准是国土资源监测^[1]、成像匹配制导^[2]等领域中的关键技术;它是指将不同成像波段、时间、视角等条件下获取的两幅图像在同一坐标系下对齐的过程。异源遥感图像配准^[3]属于计算机视觉领域底层技术,它通常包含以下三个步骤:(1)图像特征提取;(2)相似性测度计算;(3)配准参数最优化。其中,图像特征通常采用边缘、轮廓、局部结构张量等对不同波段成像具有稳定响应的特征。但是,异源图像间的信息鸿沟仍会导致共性特征点集中包含较多的噪声和外点等退化特征。消除这些退化特征的影响,要有能对抗退化特征的相似性度量函数。传统的相似性度量函数通常采用欧氏空间^[4]、希尔伯特空间^[5]下的距离作为度量函数,此类函数内蕴了硬性指派策略,因此对抗噪声干扰的能力较弱。此外,传统的配准参数最优化算法通常采用求解偏微分方程^[6]的迭代解算方法,由于偏微分方法通过计算局部搜索空间的斜率来指导寻优方向,因此容易陷入局部最优陷阱;同时,对于存在透视畸变的遥感图像配准任务而言,其相似性度量函数的偏微分方程计算复杂度高,且成像过程存在空间维数坍塌,导致解具有二义性,因此偏微分方法难以适用于透视畸变下的图像配准。因此,设计一个能有效对抗退化特征的相似性度量函数且能快速搜索最优参数的图像配准算法,仍是异源遥感图像配准任务面临的难题。

现有的异源图像配准算法可以分为两大类:基于模型驱动的方法、基于数据驱动的方法。

基于模型驱动的方法又可细分为:基于区域和基于特征的方法。基于区域的方法采用人工

设计的相似性度量函数来判断两幅图像的局部或全局区域之间是否配准。经典的方法包括直接在图像空域上计算的归一化互相关、互信息等方法。其中互信息方法采用了统计相关的策略,具有更强的相似性评价能力,可更有效地对抗异源图像间信息鸿沟。基于互信息的改进型方法包括: Xu 等人^[7]提出的将 Jeffrey 散度作为图像间的相似性度量; Ye 等人^[8]提出的基于稠密局部自相似性描述符的方法。基于区域的方法还可在频域上计算,利用傅里叶变换的某些性质巧妙地避开空域中的某些难题。Chen 等人^[9]提出傅里叶-梅林不变量描述符配准方法,该方法可将旋转和缩放表示为参数空间中的平移,同时描述符的匹配巧妙地使用了对称相位匹配滤波,从而提升运算效率;姚永祥等人^[10]提出 CoFSM 则利用共现滤波器设计尺度空间,同时通过巴特沃斯滤波器优化图像梯度以增强多模态图像描述的鲁棒性,减少非线性辐射差异的干扰。

基于特征的方法采用先提取异源图像共性特征,然后再进行配准的策略。因此,共性特征的优劣直接决定了配准算法的性能。最近,郭璠等人^[2]提出基于聚合特征点及线型描述符分段统计的方法实现了红外航空图像配准;伍朗等人^[11]将相位一致性融入 ORB 算法得到了较高效的配准算法;向俞明等人^[12]提出基于图像共性密集特征及其降采样后逐像素匹配的光学/SAR 图像配准方法;徐海洋等人^[13]提出基于边缘结构特征的红外/可见光图像配准算法,利用了相位一致性得到稳定的边缘特征。姜迈等人^[14]提出基于 SURF-HOG 描述符与红外显著性特征的图像配准融合算法,利用了 SURF 特征点来构建 HOG 描述符,并利用了最近邻距离比值完成了

红外/可见光匹配。许凯凯等人^[15]提出了二值化的辐射不变性特征,通过利用了图像的相位一致性,在汉明距离度量函数下得到了较好的配准效果。

现有的基于模型驱动的方法通常在相似性度量函数鲁棒性和配准参数寻优效率上难以同时达到较好的性能。

基于数据驱动的方法又可分为:基于模块化和基于端到端的方法。基于模块化的方法利用深度学习技术得到一个能替代传统图像配准方法中的功能模块;例如特征描述符提取模块、配准参数估计模块、图像误匹配剔除模块等。Xiang 等人^[16]提出基于孪生网络的图像特征描述符匹配方法;Wang 等人^[17]提出基于三元网络的图像描述符匹配方法。前述描述符提取模块的输入为局部图像块,而 Revaud 等人^[18]提出的 R2D2 则可以直接在全图上提取特征点和特征描述符。深度学习方法替代传统的配准参数估计模块方法有:Rocco 等人^[19]提出的几何匹配法,Zhou 等人^[20]提出的 SfMLearner 等。此外,深度学习方法替代误匹配剔除方法有:Yi 等人^[21]等人提出的 LFGC, Ma 等人^[22]提出匹配剔除分类网络等。但是,基于模块化的方法大多采用了传统的特征作为标签,因而容易受制于传统特征。

基于端到端的图像配准算法则采用直接预测图像间的几何变换参数的思路。Wang 等人^[23]通过学习匹配对的映射关系得到图像配准变换参数;Li 等人^[24]提出语义模板匹配端到端框架,采用了两幅图之间的空间位置概率映射计算变换参数,得到了较高效的配准算法。但是端到端的配准方法对训练数据集的规模和质量要求较高,目前主要集中在医学图像配准领域^[25]。

以上分析可知,基于数据驱动的图像配准方法需要大量的训练样本,而异源遥感图像训练样本获取难度较大。同时,训练好的端到端模型大多只适用于同波段下的图像,导致算法适用范围窄。而基于模型驱动的方法可以通过提取异源图像间的共性特征,从而将图像配准任务视为点集配准任务,实现计算模型与成像波段的隔离。同时,可以将冗余的特征建模成噪声、外点等退化特征,而只要能找到对噪声、

外点等退化特征鲁棒的相似性度量函数以及快速的寻优策略,就能实现可适用于任何波段的异源图像配准方法。

KL (Kullback-Leibler divergence) 散度^[26]是一种测量两个概率分布之间相似程度的函数,它的三个重要性质确保其可作为图像配准相似性度量函数(详见 2.1 节)。但是,两个高斯混合模型之间的 KL 散度无解析解。因此,本文提出变分近似解算 KL 散度的方法,从而实现基于 KL 散度的异源图像配准方法。本文主要创新体现在以下几个方面:(1)对异源图像间的共性特征构建高斯混合模型,从而使两图像的相似性测度从基于传统距离的硬指派变为基于概率的软指派问题;(2)提出将 KL 散度作为图像相似性测度,通过度量特征点集高斯混合模型之间的相似程度,达到有效对抗退化特征干扰的目的。同时,对红外实时图像特征点集,先正射校正,再构建高斯混合模型,从而大大缩小配准参数搜索范围;(3)提出变分近似解算 KL 散度的方法,通过引入带约束的变分参量,再利用拉格朗日乘数法,解出所有变分参量,从而逼近 KL 散度值,避免了基于采样近似的方法精度差的问题;(4)提出基于成像位姿正射校正+粒子群优化算法的配准参数寻优方法,实现从粗到精的配准参数寻优过程,避免了局部最优陷阱。

2 KL 散度及变分近似解算方法

2.1 KL 散度及其性质

KL 散度是一种度量两个概率分布之间差异的方法,其定义如下所示:

$$D(f\|g) = \int_{\mathcal{R}^d} f(x) \log_a(f(x)/g(x)) dx, \quad (1)$$

其中: $f(x)$ 和 $g(x)$ 是两个概率密度函数, $x \in \mathcal{R}^d$ 表明概率密度函数的变量为 d 维。此外,对数底数 a 大于1,表明 KL 散度是一个凸函数,它具有如下三个重要性质:

$$(1) \text{ 自相似性: } D(f\|f) = 0;$$

$$(2) \text{ 自辨识性: } D(f\|g) = 0, \text{ (当且仅当 } f = g \text{);}$$

$$(3) \text{ 非负性: } D(f\|g) \geq 0, \text{ (对任意的 } f, g \text{)}.$$

以上三个性质是 KL 散度可作为图像配准相似性度量函数的重要依据:(1)自相似性和自辨

识性能有效地判断两个概率分布是否相同;而图像配准是将两幅图像在同一坐标系下对齐的过程,当两幅图像对齐时,两幅图像的概率模型的KL散度在理想条件下会趋于0;(2)非负性表明该函数存在下确界,它可作为判断图像配准收敛的依据;即使图像受到噪声和外点等的干扰,当两幅图像完全对齐时,图像概率模型间的KL散度值仍是最小值。而传统的基于距离相似性测度的方法可能导致最优解处的度量函数值并非最大/小值。因此,KL散度非常适用于图像配准相似性度量函数。

本文首先提取红外和可见光图像的边缘共性特征,从而消除异源图像间的信息鸿沟。但是得到的边缘特征点集中仍存在噪声和外点,而传统的基于距离的度量函数难以对抗这些干扰。因此,本文采用对图像的特征点集进行高斯混合

模型(Gaussian Mixture Model, GMM)建模,然后再计算其KL散度的方法,得到图像的相似性度量函数。

对于红外和可见光图像的特征点集,其高斯混合模型分别建模为 $f(x)$ 和 $g(x)$,其表达式如下:

$$f(x) = \sum_{m=1}^M \omega_m f_m(x) = \sum_{m=1}^M \omega_m N(x|\mu_m, \Sigma_m), \quad (2)$$

$$g(x) = \sum_{n=1}^N v_n g_n(x) = \sum_{n=1}^N v_n N(x|\mu_n, \Sigma_n), \quad (3)$$

其中: ω_m, v_n 为各个高斯函数权重, $N(x|\mu_m, \Sigma_m)$, $N(x|\mu_n, \Sigma_n)$ 表示均值为 μ_m, μ_n ,协方差矩阵为 Σ_m, Σ_n 的二维高斯函数。而 μ_m 表示某个特征点的像素坐标值, Σ_m 则决定了在这个特征点处建模的单个高斯函数的形状。其建模过程如图1所示。

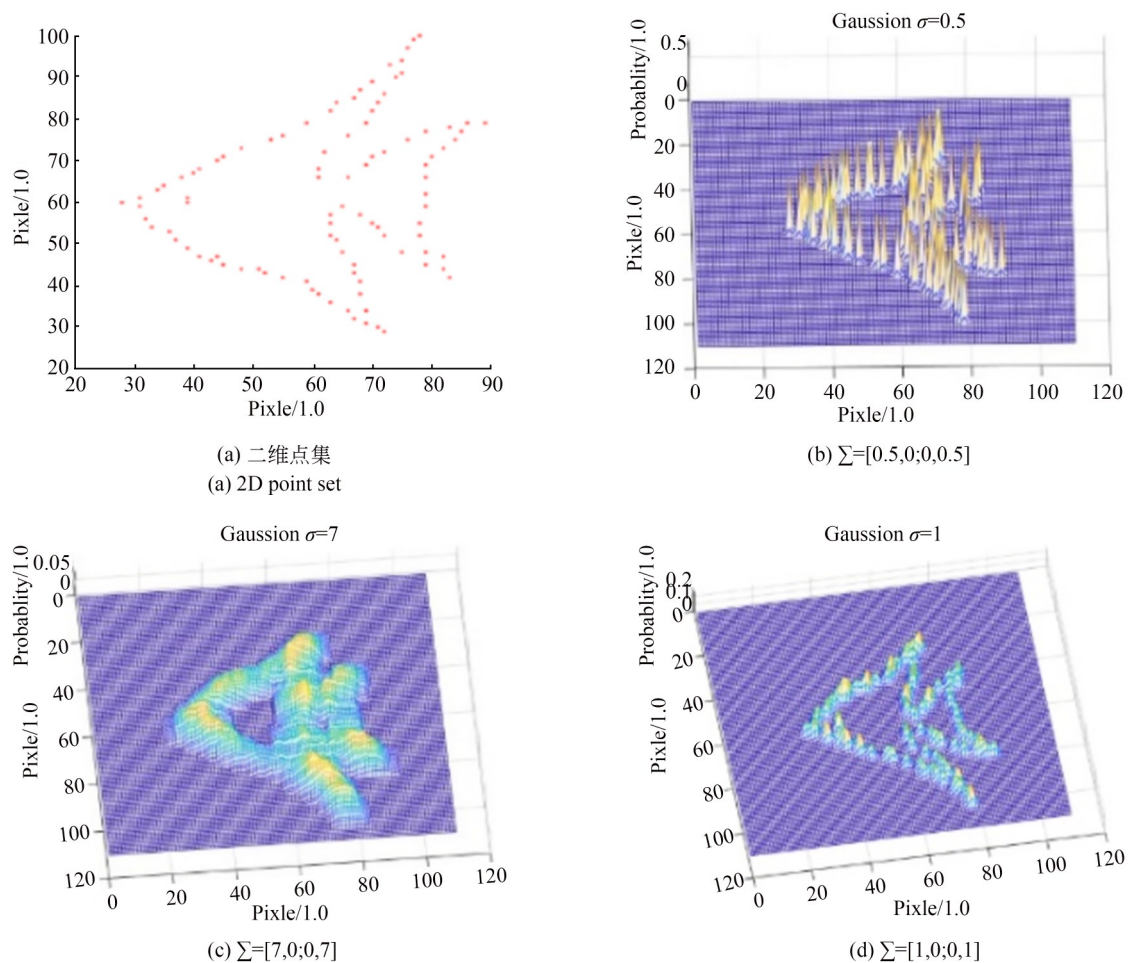


图1 不同协方差矩阵下的高斯混合模型

Fig. 1 GMMs with different covariance matrix values

从图 1 的 GMM 可视化效果可以看出,需要合理地设置单个高斯函数的协方差矩阵值,从而避免高斯混合模型分辨率太低,或者每个单峰相互之间独立的现象。本文将其设置为 $\Sigma = [1, 0; 0, 1]$ 。这样,根据正态分布的 $\pm 3\sigma$ 原理,每个特征点的概率分布除了自身所在的位置有值,其 3×3 像素的邻域内也存在一定的概率值,从而在计算相似性测度值时,有利于对抗各种退化特征的干扰。

以上步骤将图像间的相似性测度转化为特征点集 GMM 之间的 KL 散度值。但是,两个 GMM 之间的 KL 散度并无解析解,而传统的基于采样的近似解法精度较差。本文提出变分近似解算 KL 散度的方法,通过引入变分参量,并利用拉格朗日乘数法,最终逼近 KL 散度值。

2.2 变分近似法解算 KL 散度

根据 KL 散度的表达式:

$$D(f \| g) = \int_{R^d} f(x) \log_a(f(x)) dx - \int_{R^d} f(x) \log_a(g(x)) dx. \quad (4)$$

将式(4)右边两部分式子分别定义如下:

$$L_f(g) = \int_{R^d} f(x) \log_a g(x) dx, \quad (5)$$

$$\Gamma_f(f) = \int_{R^d} f(x) \log_a f(x) dx. \quad (6)$$

将式(2)和式(3)定义的 $f(x)$ 和 $g(x)$ 代入式(5)得到:

$$L_f(g) = \sum_{m=1}^M w_m \int f_m(x) \log_a \left(\sum_{n=1}^N v_n g_n(x) \right) dx. \quad (7)$$

引入带约束的变分参量 $\phi_{n|m}$, ($\sum_{n=1}^N \phi_{n|m} = 1$),

则有:

$$L_f(g) = \sum_{m=1}^M w_m \int f_m(x) \log_a \left(\sum_{n=1}^N \phi_{n|m} \frac{v_n g_n(x)}{\phi_{n|m}} \right) dx. \quad (8)$$

根据 Jensen 不等式,当函数 $h(u)$ 为凸函数时,有 $h(E[u]) \geq E[h(u)]$ 。因此,将式(8)中的对数函数移到求和符号里面,可得到如下不等式:

$$\begin{aligned} \sum_{m=1}^M w_m \int f_m(x) \log_a \left(\sum_{n=1}^N \phi_{n|m} \frac{v_n g_n(x)}{\phi_{n|m}} \right) dx &\geq \\ \sum_{m=1}^M w_m \int f_m(x) \left(\sum_{n=1}^N \phi_{n|m} \log_a \frac{v_n g_n(x)}{\phi_{n|m}} \right) dx. & \end{aligned} \quad (9)$$

将式(9)中的后者定义为 $L_f(g, \phi)$, 即:

$$L_f(g, \phi) = \sum_{m=1}^M w_m \int f_m(x) \left(\sum_{n=1}^N \phi_{n|m} \log_a \frac{v_n g_n(x)}{\phi_{n|m}} \right) dx. \quad (10)$$

若能最大化 $L_f(g, \phi)$, 则可向上逼近 $L_f(g)$ 。因此,问题转化为寻找合适的 $\phi_{n|m}$ 使 $L_f(g, \phi)$ 最大化。求解 $L_f(g, \phi)$ 最大值的方法就是典型的求导法,由于本文引入了带约束的变分参量 $\phi_{n|m}$, 因此需要采用拉格朗日乘数法:

$$\begin{aligned} \frac{\partial}{\partial \phi_{n|m}} \sum_{m=1}^M w_m \int f_m(x) \left(\sum_{n=1}^N \phi_{n|m} \log_a \frac{v_n g_n(x)}{\phi_{n|m}} \right) dx + \\ \lambda \left(\sum_{n=1}^N \phi_{n|m} - 1 \right) = 0, \end{aligned} \quad (11)$$

$$\begin{aligned} \frac{\partial}{\partial \lambda} \sum_{m=1}^M w_m \int f_m(x) \left(\sum_{n=1}^N \phi_{n|m} \log_a \frac{v_n g_n(x)}{\phi_{n|m}} \right) dx + \\ \lambda \left(\sum_{n=1}^N \phi_{n|m} - 1 \right) = 0. \end{aligned} \quad (12)$$

对式(11)中的变量逐个求偏导数后,可得到多个关于变分参量 $\phi_{n|m}$ 和 λ 的方程,对式(12)求导后可得到约束方程。最终联立以上方程,消除 λ , 得到 $\phi_{n|m}$ 的表达式:

$$\phi_{n|m} = \frac{v_n \exp(-D(f_m \| g_n))}{\sum_{n'=1}^N v_{n'} \exp(-D(f_m \| g_{n'}))}. \quad (13)$$

将式(13)带回式(10),则可逼近 $L_f(g)$ 。

同理,将式(2)和式(3)中定义的 $f(x)$ 和 $g(x)$ 代入式(6)中可得到:

$$\Gamma_f(f) = \sum_{m=1}^M w_m \int f_m(x) \log_a \left(\sum_{m'=1}^M w_{m'} f_{m'}(x) \right) dx. \quad (14)$$

引入带约束的变分参数 $\varphi_{m'|m}$, ($\sum_{m'=1}^M \varphi_{m'|m} = 1$) 则有:

$$\begin{aligned} \Gamma_f(f) = \\ \sum_{m=1}^M w_m \int f_m(x) \log_a \left(\sum_{m'=1}^M \varphi_{m'|m} \frac{w_{m'} f_{m'}(x)}{\varphi_{m'|m}} \right) dx. \end{aligned} \quad (15)$$

根据 Jensen 不等式,将对数函数移到求和符号里面后,定义 $\Gamma_f(f, \varphi)$:

$$\Gamma_f(f, \varphi) = \sum_{m=1}^M \omega_m \int f_m(x) \left(\sum_{m'=1}^M \varphi_{m'|m} \log_a \frac{\omega_{m'} f_{m'}(x)}{\varphi_{m'|m}} \right) dx. \quad (16)$$

得到不等式: $\Gamma_f(f) \geq \Gamma_f(f, \varphi)$ 。同样地, 采用拉格朗日乘数法, 可解出变分参数 $\varphi_{m'|m}$:

$$\varphi_{m'|m} = \frac{\omega_{m'} \exp(-D(f_m \| f_{m'}))}{\sum_{m''=1}^M \omega_{m''} \exp(-D(f_m \| f_{m''}))}. \quad (17)$$

将式(17)带回式(16)则可以逼近 $\Gamma_f(f)$ 。得到变分近似计算两个高斯混合模型的KL散度表达式:

$$D_{VA}(f \| g) = \Gamma_f(f, \phi) - L_f(g, \varphi). \quad (18)$$

式(18)的具体数值解算表达式如下:

$$D_{VA}(f \| g) = \sum_{m=1}^M \omega_m \log_a \left(\sum_{m'=1}^M \omega_{m'} e^{-D(f_m \| f_{m'})} - \sum_{n=1}^N v_n e^{-D(f_m \| g_n)} \right). \quad (19)$$

式(19)中的两个高斯函数之间的KL散度 $D(f_m \| g_n)$ 存在解析表达式:

$$D(f_m \| g_n) = \frac{1}{2} \left[\log_a \left(\frac{|\Sigma_{g_n}|}{|\Sigma_{f_m}|} \right) + \text{Tr}(\Sigma_{g_n}^{-1} \Sigma_{f_m}) + (\mu_{f_m} - \mu_{g_n})^T (\Sigma_{g_n}^{-1}) (\mu_{f_m} - \mu_{g_n}) - d \right], \quad (20)$$

其中: d 为高斯函数的维度, μ_{f_m} 和 Σ_{f_m} 为 f_m 的均值和协方差矩阵, μ_{g_n} 和 Σ_{g_n} 为 g_n 的均值和协方差矩阵, Tr 则是求矩阵的迹。至此, 图像的相似性度量函数已有数值解算方法, 下一步就是要设计合理的最优化算法。

2.3 配准参数最优化算法

图像配准最优化算法就是使相似性度量函数(目标函数)在搜索空间(解空间)上达到最小值的方法, 其数学描述如下:

$$\hat{\theta} = \arg \min_{\theta} D_{VA}(f, g, \theta), \quad (21)$$

其中, θ 为待解算的配准参数。对于式(21), 通常可以采用偏微分方程法迭代求解, 但是遥感图像成像位姿参数包括三个距离参数(东、北、天)和三个角度参数(偏航、俯仰、滚转), 它是六维搜索空间; 要从二维的图像信息中解算出六维的配准

参数, 其结果存在二义性; 此外, 两个GMM之间的KL散度偏微分运算复杂度较高, 不利于实时计算。

为有效地降低搜索空间维度、提高运算效率, 本文提出基于成像位姿参数正射校正^[27] + 粒子群优化算法^[28]的策略, 实现由粗到精解算最优配准参数。虽然红外探测器的成像位姿参数和遥感卫星可见光图像都存在一定的误差, 但是经过正射校正后的红外图像特征点集与可见光图像特征点集之间可视为只存在二维旋转、平移外加一维的尺度残差, 这将大大降低搜索空间的维数。

接下来, 采用粒子群优化算法实现精配准。粒子群优化算法是一种高效的全局优化算法, 它无需求解偏微分方程, 其数学描述如下: 设在 d 维搜寻空间中有 m 个粒子组成的种群 $X \in R^{m \times d}$; 第 i 个粒子的当前位置为 $x_i(t)$, 当前速度为 $v_i(t)$, 它的个体极值为 $p_i(t)$, t 表示粒子的迭代次数。而群体的全局极值为 $p_g(t)$, g 为最好粒子编号。这里的“粒子”就是搜索空间中的一个“解”, 它的“位置”就是解空间中的一个具体坐标, 即为一个配准参数的值, 则粒子群优化算法的寻优过程如下:

$$v_i(t+1) = \lambda v_i(t) + c_1 r_1 (p_i(t) - x_i(t)) + c_2 r_2 (p_g(t) - x_i(t)), \quad (22)$$

$$x_i(t+1) = x_i(t) + v_i(t+1), \quad (23)$$

其中: λ 是惯性权重, c_1 和 c_2 是加速因子, r_1 和 r_2 是每个元素为 0~1 之间随机数的 d 维向量。惯性权重类似模拟退火中的温度, 较大的惯性权重具有较强的全局搜索能力, 而较小的惯性权重则具有较强的局部收敛能力。因此随着迭代次数增加, 惯性权重应不断减少, 从而使算法在初期具有较强的全局搜索能力, 而在后期具有较强的局部收敛能力。本文采用权重线性递减策略: $\lambda(t) = 0.9 - 0.4t/G$; 其中, G 为最大迭代次数, 本文设置为 1 000, 粒子数 m 设置为 200。本文方法具体流程如表 1 所示。

表 1 本文方法流程

Tab. 1 Processing steps of our method

Step 1: 对红外/可见光图像分别提取 Sobel 边缘特征点集;
Step 2: 对红外图像特征点集进行正射校正;
Step 3: 对红外/可见光特征点集分别构建高斯混合模型;
Step 4: 采用变分近似法解算两个 GMM 的 KL 散度值;
Step 5: 采用粒子群优化算法对配准参数进行迭代寻优;
Step 6: 重复 Step 5, 直到满足终止条件, 输出配准参数。

3 实验结果及分析

为验证本文方法的有效性,下面通过模拟数据和真实数据进行对比实验,同时对本文方法进行多轮噪声方差测试。本文所有对比实验均在 Xeon CPU 2.4 GHz, RAM 16 GB, Nvidia Quadro P5000 16 GB 环境下运行。

3.1 模拟数据实验

模拟实验采用开源数据库[29]中的鱼轮廓点集 (<https://www.cise.ufl.edu/~anand/students/chui/tps-rpm.html>)。首先,将原始鱼轮廓作为参考点集 $M \in R^{I \times d}$, 然后对 M 引入外点、缺失等退化特征, 并对其进行坐标变换, 得到场景点集 $S \in R^{J \times d}$ 。配准的过程就是对 M 进行变换, 从而与 S 对齐的过程。由于变换参数是已知的, 因此 M 的真值 M^* 是已知的。配准算法可以得到 M 的估计值 \hat{M} , 则可以采用真值 M^* 与估计值 \hat{M} 之间的点集配准均方根误差 (PointRMSE) 来评估配准效果, 其表达式如下:

$$\text{PointRMSE} = \left[\sum_{i=1}^I |x_i^* - \hat{x}_i| / I \right]^{1/2}, \quad (24)$$

其中: x_i^* 是 M^* 中各个点的坐标, \hat{x}_i 是配准算法得到的 \hat{M} 中各个点的坐标。

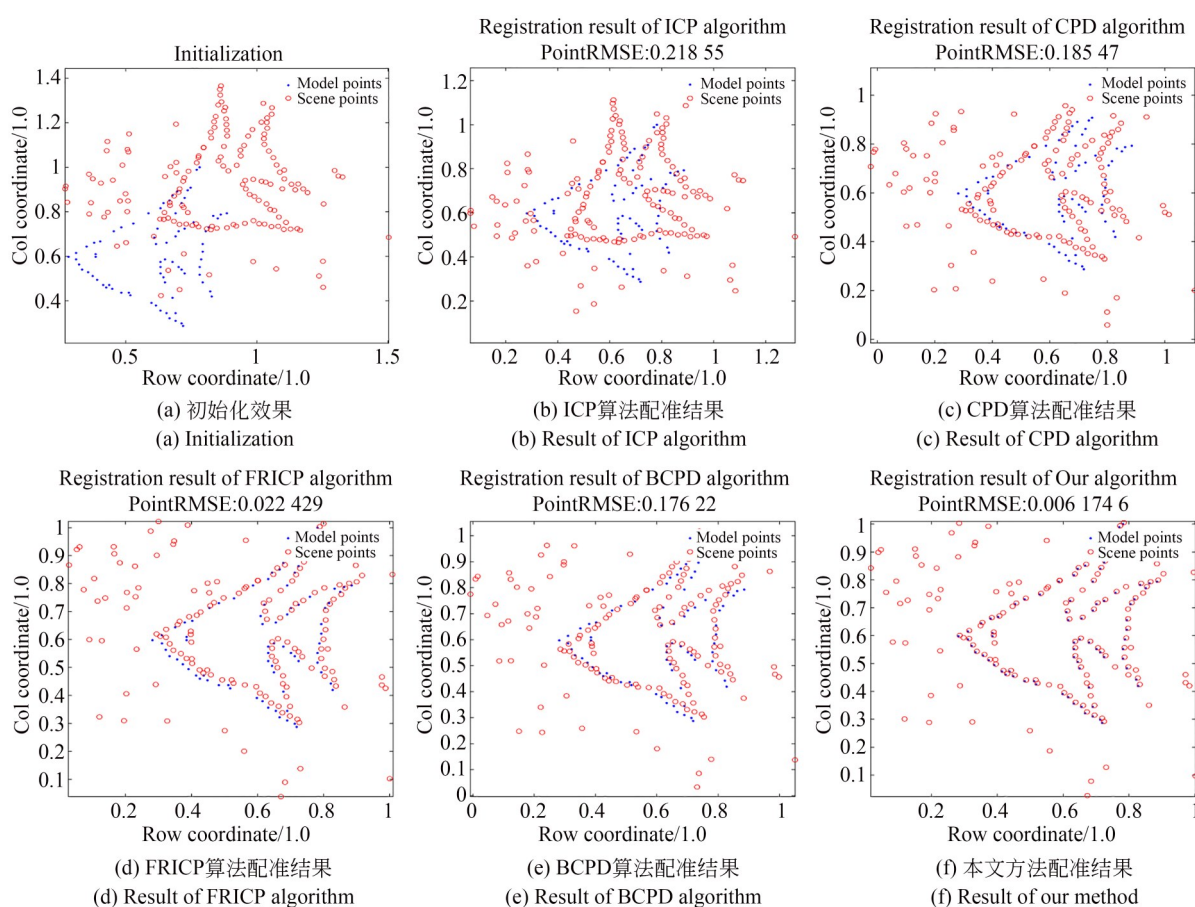


图 2 仿真数据实验结果

Fig. 2 Experimental results on synthetical dataset

将本文方法与经典的 ICP^[30], CPD^[31]方法进行对比, 同时与这两种方法的最新改进版本 FRICP^[32]和 BCPD^[33]进行对比。ICP 和 FRICP 是典型的硬指派方法, CPD 和 BCPD 则是基于概率相似性度量的软指派方法。ICP 是经典的最近邻迭代方法, 其最新的改进版本 FRICP 利用了 Welsch 函数度量误差, 并采用 Anderson 加速法从而提高了算法鲁棒性和效率。CPD 方法采用解偏微分方程法迭代估计配准参数, BCPD 是其最近的优化版, 它引入了变分法和贝叶斯估计法, 从而提升了算法的效率。实验效果如图 1 所示, 其中, 子图的标题处列出了各算法对应的 PointRMSE 值。从实验结果可以看出, ICP 算法无法实现配准, 这是由于它严重依赖初始值; 由

于受到了退化特征的干扰, CPD 算法并未准确地估算出旋转畸变。FRICP 和 BCPD 是改进型的配准算法, 因此它们的配准效果均优于 ICP 和 CPD。本文方法配准效果最佳, 且点集配准均方根误差值: $\text{PointRMSE}=0.006\ 17$, 显著优于对比方法。

3.2 真实数据实验

下面采用航拍红外图像与可见光卫星遥感图像进行对比实验。其中, 可见光遥感图像源自高分 2 号卫星; 红外图像为多视角、多高度下的航拍图像。由于不同航拍高度下的红外图像空间分辨率差异较大, 而卫星遥感图像的分辨率通常优于 $1\ \text{m}/\text{pixel}$ 。因此, 先调整可见光遥感图像的分辨率, 使其与红外航拍图像分辨率接近, 如图 3 所示。

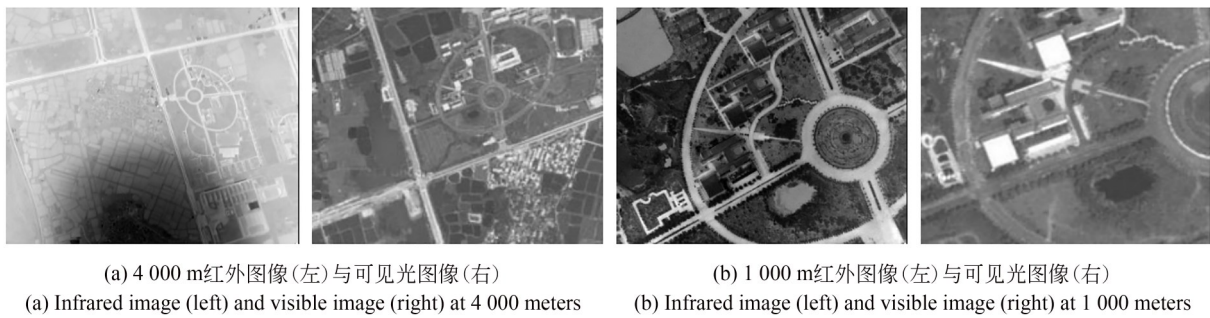


图 3 红外/可见光图像示意图

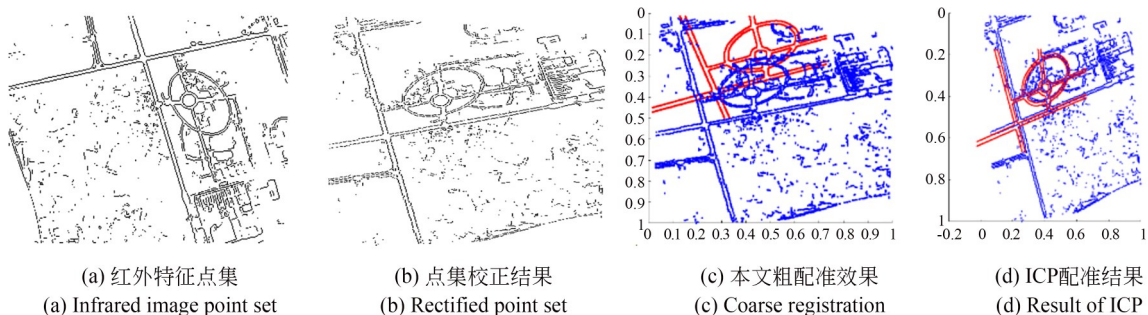
Fig. 3 Infrared and visible image pairs

将本文方法与 ICP、CPD、FRICP 和 BCPD 进行对比。图 4(a)~图 4(c)分别为 4 000 m 红外图像特征点集、正射校正后的红外图像特征点集、本文方法的粗配准效果。利用成像外方位参数将红外图像特征校正为正下视, 校正后的红外图像特征与可见光图像特征存在少量平移、旋转和缩放畸变, 图 4(c)中, 正射校正后的红外探测图像特征点集为蓝色, 可见光遥感基准图像特征

点集为红色, 这为后续粒子群优化算法迭代寻优创造了有利条件。图 4(d)~图 4(h)是各个算法的配准效果图(彩图见期刊电子版)。

同图 4 类似, 图 5 是 1 000 m 高度下的红外图像与可见光遥感图像的配准结果示意图。

从图 4 和图 5 的可视化效果可知, 本文方法配准精度最高, 图 6 展示了部分图像配准棋盘格示意图。



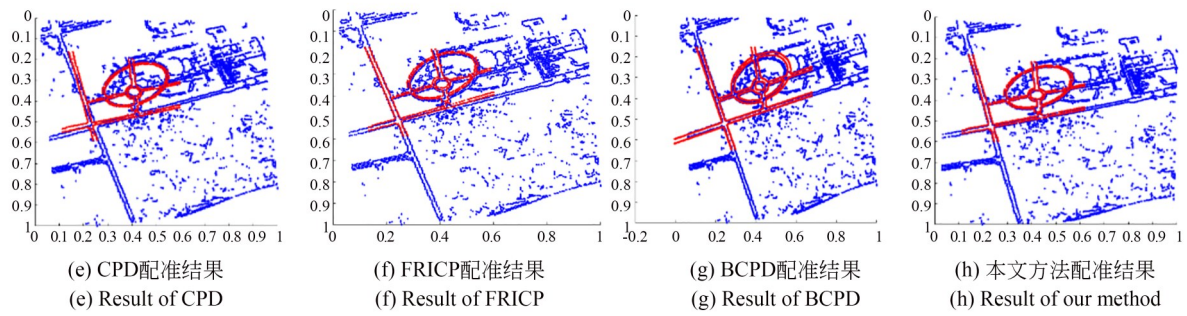


图 4 4 000 m 高度航拍图像配准效果

Fig. 4 Registration of aerial image at 4 000 meters

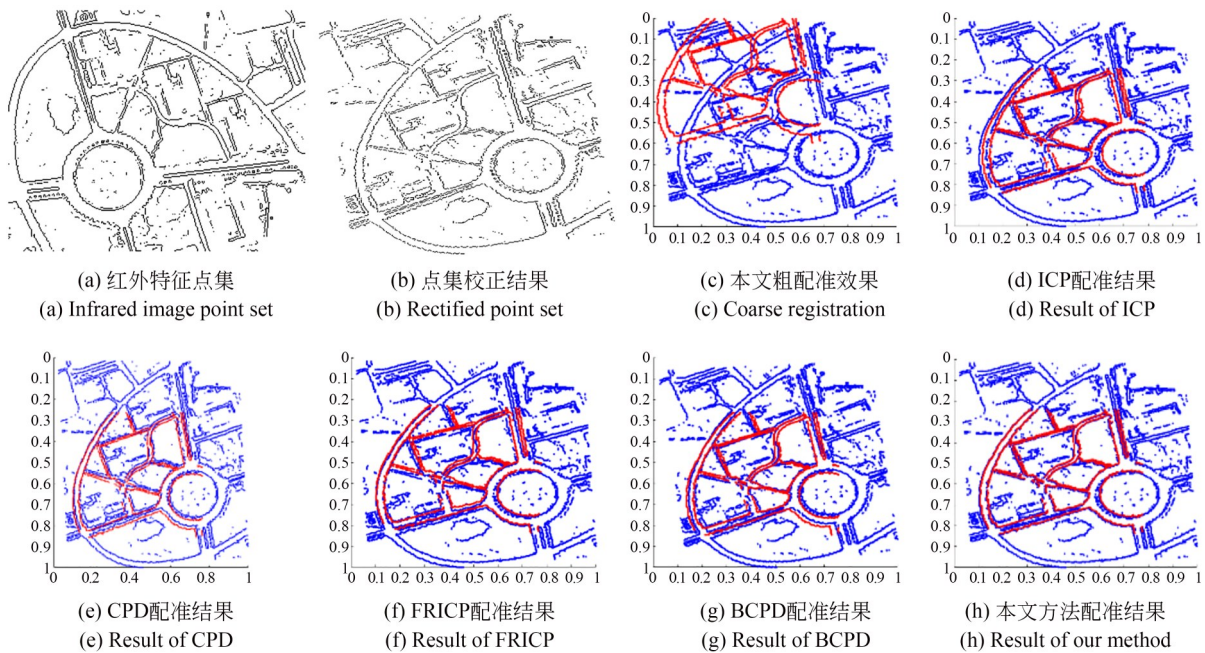


图 5 1 000 m 高度航拍图像配准效果

Fig. 5 Registration of aerial image at 1 000 meters

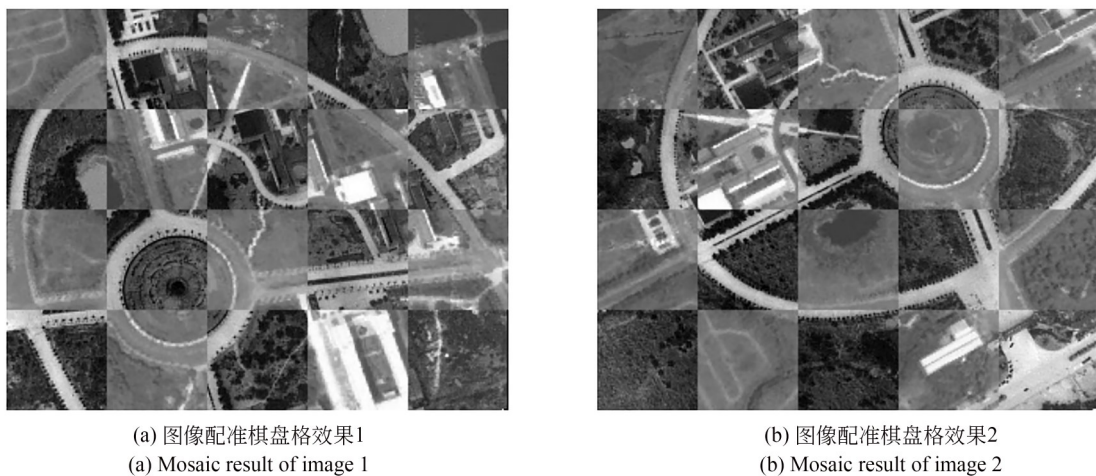


图 6 红外和可见光图像配准的棋盘格效果图

Fig. 6 Mosaic of infrared and visible images

3.3 噪声方差测试

为测试本文方法的抗噪能力,分别在红外图像中加入高斯噪声和椒盐噪声测试本文方法。其中,高斯噪声取均值为0,逐渐增加噪声方差,其Matlab代码为:outIm=imnoise(inIm,'gaussian', 0,0.01);。最后一个下划线参数是噪声方差值,下面是以0.02为步长对红外图像添加高斯噪声

的测试结果。

下面对红外图像添加椒盐噪声,其Matlab代码为: outIm=imnoise(inIm, 'salt & pepper', 0.1);。最后一个下划线参数是椒盐噪声比例系数,下面是以0.02为步长对红外图像添加椒盐噪声的测试结果。

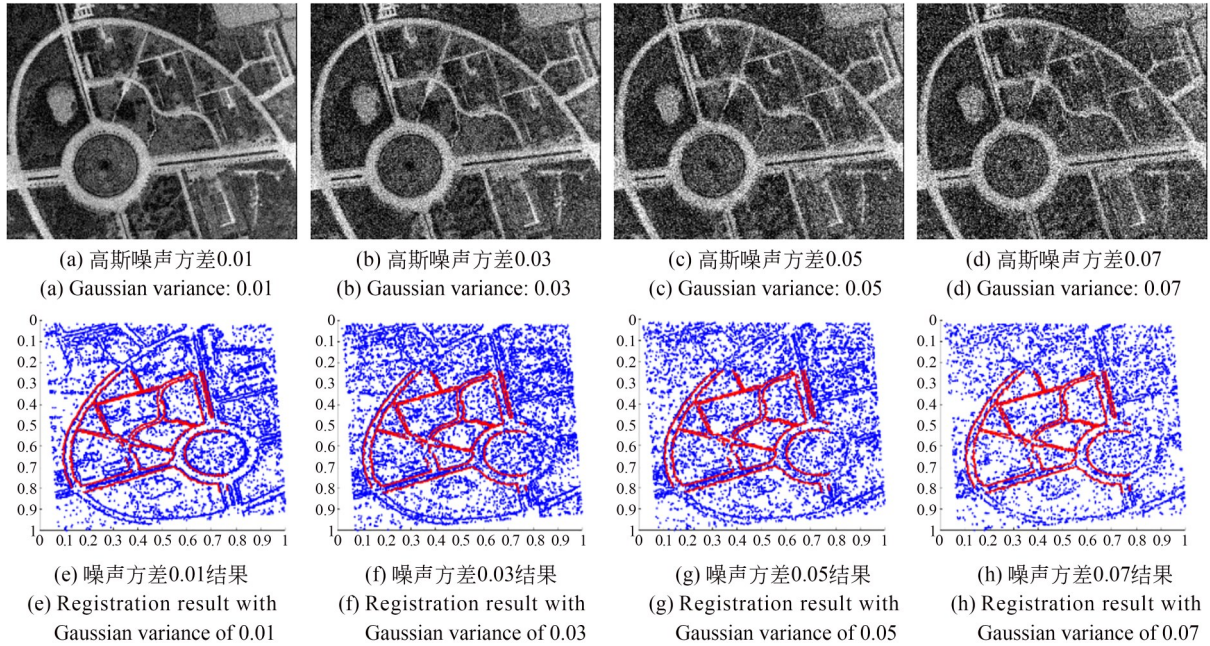


图7 本文方法高斯噪声压力测试结果

Fig. 7 Registration results on Gaussian noise

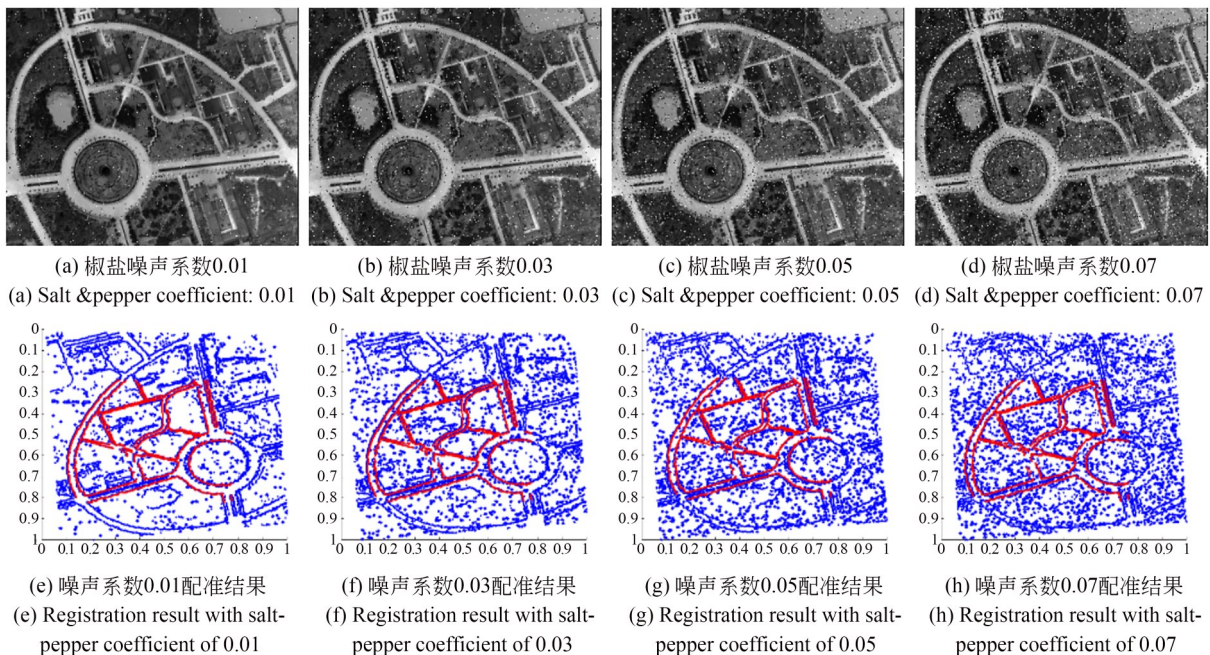


图8 本文方法椒盐噪声压力测试结果

Fig. 8 Registration results of salt & pepper noise

从以上两组噪声测试结果可知,本文方法在高斯噪声方差或椒盐噪声系数为 0.07 时,仍能正确配准图像,这表明本文方法具有较强的抗噪性能。

3.4 结果分析

遥感图像变换需要精确的成像位姿参数,而不同的两组成像位姿参数的成像效果可能十分接近,若用仿真数据实验中的点集配准均方根误差指标(PointRMSE),可能导致配准参数评估错误。因此对于遥感图像数据的配准,本文采用如下两种评价指标:(1)配准参数均方根误差(Parameters Root of Mean Square Error, Param-

RMSE);(2)运行时间(Runtime)。其中,配准参数均方根误差定义为:

$$\text{ParamRMSE} = \left[\sum_{i=1}^d |\theta_i^* - \hat{\theta}_i| / d \right]^{1/2}, \quad (25)$$

其中: $d=6$ 为配准参数的维度, θ^* 和 $\hat{\theta}$ 分别为配准参数真值和估计值。在对 300 组不同场景、高度和视角下的红外/可见光异源遥感图像进行实验后,将结果统计为箱线图,如图 9 所示(彩图见期刊电子版)。其中,左边为各个算法的配准参数均方根误差(ParamRMSE)统计结果,右边为运行时间(Runtime)统计结果。箱线图中间红线表示数据的均值,蓝色矩形长短表示数据方差的大小。

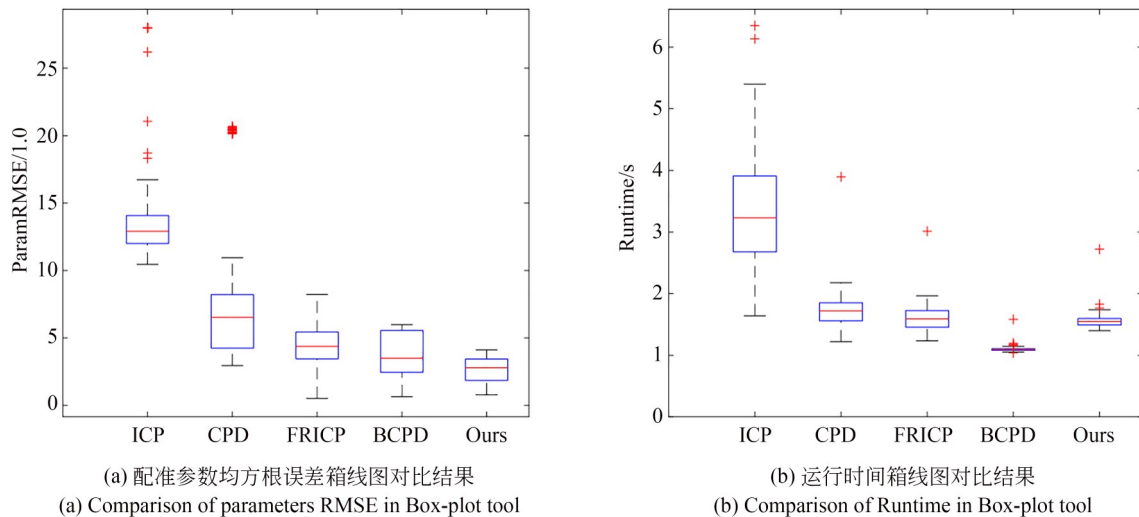


图 9 对比实验结果箱线图

Fig. 9 Box-plot of comparative experiments

从图 9 显示结果可知,ICP 方法得到的配准参数均方根误差存在较多的异常值,同时它的均值也是所有对比方法中最大的,说明该方法对抗退化特征的能力较弱。此外,ICP 方法在运算效率上也表现出耗时较长且稳定性不高的特点,说明其搜索能力较弱,受初始值的影响较大。基于概率模型的 CPD 算法在各项指标上均领先于 ICP 算法,同时 CPD 的改进版本 BCPD,由于利用了变分法和贝叶斯估计模型,其配准参数均方根误差和运行时间指标均相较于 CPD 有了较大幅度的提升。ICP 算法的改进版本 FRICP 的各项性能指标均处于 CPD 和 BCPD 方法之间。BCPD 方法是所有对比方法中运行效率最高的,同时其运行时长的方差值也较小;这说明该方法

对搜索的终止条件限制得比较宽松,从而产生更小的运行时长波动。但是,这就导致了 BCPD 算法对配准参数寻优的稳定性较差,具体表现在它的配准参数均方根误差较大,而本文方法虽运行时长均值比 BCPD 大,但是配准参数均方根误差更小。下面将所有对比算法的评价指标的均值和方差统计在表 2 中(最优结果用黑体表示)。

从表 2 中可以看出,BCPD 方法的整体运算速度最快,它平均领先本文方法 0.5 s;本文方法的配准参数均方根误差平均值优于 BCPD 算法 1.2,同时在该值的方差上优于 BCPD 算法 0.7,这说明本文方法在抗噪能力、配准精度以及稳定性上优于对比方法。

表 2 对比实验统计结果

Tab.2 Statistic result of comparative experiments

评价指标		对比方法				
		ICP ^[30]	CPD ^[31]	FRICP ^[32]	BCPD ^[33]	Ours
配准参数均方根误差	均值	13.616	7.506	4.499	3.714	2.501
	方差	3.279	4.765	1.482	1.724	1.014
运行时间/s	均值	3.326	1.715	1.602	1.096	1.557
	方差	0.952	0.258	0.192	0.041	0.115

4 结 论

本文提出了一种基于KL散度的红外/可见光异源遥感图像配准方法。通过提取红外/可见光图像的共性特征并分别建模为高斯混合模型,然后将两个高斯混合模型之间的KL散度值作为图像的相似性度量函数;从而消除了异源图像间的信息鸿沟,并且利用KL散度的三个重要性质,达到有效抵抗噪声和外点等退化特征的干扰的目的。由于两个高斯混合模型之间的KL散度值无解析解,因此

本文提出了变分近似解算方法,通过引入带约束的变分参量,然后利用拉格朗日乘法,实现了对KL散度值的近似解算。由于遥感图像配准搜索空间为六维空间,本文利用成像位姿参数对实时图特征点集进行正射校正,从而将搜索空间降低为四维,然后采用粒子群优化算法搜索最优配准参数,从而实现了配准参数由粗到精的寻优方法,提高了算法效率。在多组对比实验以及噪声方差测试实验中,本文方法均表现优异,这表明所提方法具有较强的抗噪性、鲁棒性以及运算效率。

参考文献:

- [1] 李德仁. 利用遥感影像进行变化检测[J]. 武汉大学学报(信息科学版), 2003, 28(S1): 7-12.
LI D R. Change detection from remote sensing images[J]. *Geomatics and Information Science of Wuhan University*, 2003, 28(S1): 7-12. (in Chinese)
- [2] 郭璠, 李小虎, 朱洪, 等. 基于sMLD特征的远红外航空图像配准算法[J]. 红外与毫米波学报, 2023, 42(4): 558-567.
GUO F, LI X H, ZHU H, *et al.* Registration method of far infrared aerial images based on sMLD feature[J]. *Journal of Infrared and Millimeter Waves*, 2023, 42(4): 558-567. (in Chinese)
- [3] 朱柏, 叶沅鑫. 多模态遥感图像配准方法研究综述[J/OL]. 中国图象图形学报, 2024. DOI: : 10.11834/jig.230737.
ZHU B, YE Y X. Multimodal remote sensing image registration: A Survey[J/OL]. *Journal of Image and Graphics*, 2024, DOI: : 10.11834/jig.230737. (in Chinese)
- [4] 孙明超, 马天翔, 宋悦铭, 等. 基于相位特征的可见光和SAR遥感图像自动配准[J]. 光学精密工程, 2021, 29(3): 616-627.
SUN M C, MA T X, SONG Y M, *et al.* Automatic registration of optical and SAR remote sensing image based on phase feature [J]. *Opt. Precision Eng.*, 2021, 29(3): 616-627. (in Chinese)
- [5] 李新春, 闫振宇, 林森, 等. 基于邻域特征点提取和匹配的点云配准[J]. 光子学报, 2020, 49(4): 0415001.
LI X C, YAN Z Y, LIN S, *et al.* Point cloud registration based on neighborhood characteristic point extraction and matching [J]. *Acta Photonica Sinica*, 2020, 49(4): 0415001. (in Chinese)
- [6] HIROSE O. Geodesic-based Bayesian coherent point drift[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(5): 5816-5832.
- [7] XU X C, LI X, LIU X P, *et al.* Multimodal registration of remotely sensed images based on Jeffrey's divergence [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 122: 97-115.
- [8] YE Y X, SHEN L, HAO M, *et al.* Robust optical-to-SAR image matching based on shape properties [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(4): 564-568.
- [9] CHEN Q S, DEFRISE M, DECONINCK F. Symmetric phase-only matched filtering of Fourier-Mellin transforms for image registration and recogni-

- tion [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1994, 16 (12) : 1156-1168.
- [10] 姚永祥, 张永军, 万一, 等. 顾及各向异性加权力矩与绝对相位方向的异源影像匹配[J]. *武汉大学学报(信息科学版)*, 2021, 46(11): 1727-1736.
YAO Y X, ZHANG Y J, WAN Y, *et al.* Heterologous images matching considering anisotropic weighted moment and absolute phase orientation [J]. *Geomatics and Information Science of Wuhan University*, 2021, 46 (11) : 1727-1736. (in Chinese)
- [11] 伍朗, 易诗, 陈梦婷, 等. 基于融合式 PC-ORB 的异源图像配准算法[J]. *红外技术*, 2024, 46(4): 419-426.
WU L, YI S, CHEN M T, *et al.* Heterogeneous image registration algorithm based on fusion PC-ORB [J]. *Infrared Technology*, 2024, 46 (4) : 419-426. (in Chinese)
- [12] 向俞明, 滕飞, 王林徽, 等. 基于快速异源配准的高分辨率 SAR 影像海岛区域正射校正[J/OL]. *雷达学报*, 2024. doi: 10.12000/JR24022.
XIANG Y M, TENG F, WANG L H, *et al.* Orthorectification of high-resolution SAR images in island regions based on fast multimodal registration [J/OL]. *Journal of Radars*, 2024, doi: 10.12000/JR24022. (in Chinese)
- [13] 徐海洋, 赵伟, 刘建业. 基于边缘结构特征的红外与可见光图像配准算法[J]. *红外技术*, 2023, 45(8): 858-862.
XU H Y, ZHAO W, LIU J Y. Infrared and visible image registration algorithm based on edge structure features[J]. *Infrared Technology*, 2023, 45(8): 858-862. (in Chinese)
- [14] 姜迈, 郑岩. 基于 SURF-HOG 与显著性特征的红外可见光图像配准融合[J]. *激光与红外*, 2023, 53(2): 261-270.
JIANG M, ZHENG Y. Infrared and visible light images registration and fusion based on SURF-HOG and saliency feature [J]. *Laser & Infrared*, 2023, 53(2): 261-270. (in Chinese)
- [15] 许凯凯, 郭鹏程, 王晶晶. BRIFT: 一种基于二值描述符的多模态图像匹配方法[J]. *航空兵器*, 2023, 30(4): 115-122.
XU K K, GUO P C, WANG J J. BRIFT: A binary descriptor for multi-modal image registration [J]. *Aero Weaponry*, 2023, 30(4): 115-122. (in Chinese)
- [16] XIANG D L, XU Y H, CHENG J D, *et al.* Progressive keypoint detection with dense Siamese network for SAR image registration[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2023, 59(5): 5847-5858.
- [17] WANG C W, XU L L, XU R T, *et al.* Triple Robustness Augmentation Local Features for multi-source image registration [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 199: 1-14.
- [18] REVAUD J, WEINZAEPFEL P, DE SOUZA C, *et al.* R2D2: repeatable and reliable detector and descriptor [EB/OL]. 2019: *arXiv*: 1906.06195. <http://arxiv.org/abs/1906.06195>
- [19] ROCCO I, ARANDJELOVIC R, SIVIC J. Convolutional neural network architecture for geometric matching[C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, HI, USA. IEEE, 2017: 39-48.
- [20] ZHOU T H, BROWN M, SNAVELY N, *et al.* Unsupervised learning of depth and ego-motion from video[C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, HI, USA. IEEE, 2017: 6612-6619.
- [21] YI K M, TRULLS E, ONO Y, *et al.* Learning to find good correspondences [C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, UT, USA. IEEE, 2018: 2666-2674.
- [22] MA J Y, JIANG X Y, JIANG J J, *et al.* LMR: learning a two-class classifier for mismatch removal [J]. *IEEE Transactions on Image Processing*, 2019, 28(8): 4045-4059.
- [23] WANG S, QUAN D, LIANG X F, *et al.* A deep learning framework for remote sensing image registration [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 145: 148-164.
- [24] LI L Z, HAN L, DING M T, *et al.* A deep learning semantic template matching framework for remote sensing image registration [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 181: 205-217.
- [25] ZHU B, ZHOU L, PU S M, *et al.* Advances and challenges in multimodal remote sensing image registration[J]. *IEEE Journal on Miniaturization for Air and Space Systems*, 2023, 4(2): 165-174.

- [26] ZHANG Y F, PAN J L, LI K L. On the properties of kullback-leibler divergence between multivariate gaussian distributions [C]. *Advances in Neural Information Processing Systems*, 2024, 36.
- [27] 林旭东, 张旭. 基于透视畸变矫正的高精度相机标定方法[J]. *激光与光电子学进展*, 2023, 60(16): 3788/LOP222259.
LIN X D, ZHANG X. Accurate camera calibration method based on perspective distortion correction[J]. *Laser & Optoelectronics Progress*, 2023, 60(16): 3788/LOP222259. (in Chinese)
- [28] NAYAK J, SWAPNAREKHA H, NAIK B, *et al.* 25 years of particle swarm optimization: flourishing voyage of two decades[J]. *Archives of Computational Methods in Engineering*, 2023, 30(3): 1663-1725.
- [29] CHUI H L, RANGARAJAN A. A new algorithm for non-rigid point matching [C]. *Proceedings IEEE Conference on Computer Vision and Pattern Recognition. CVPR 2000 (Cat. No. PR00662). Hilton Head, SC, USA. IEEE*, 2002: 44-51.
- [30] ZHANG J Y, YAO Y X, DENG B L. Fast and robust iterative closest point [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(7): 3450-3466.
- [31] MYRONENKO A, SONG X B. Point set registration: coherent point drift [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(12): 2262-2275.
- [32] ZHANG J Y, YAO Y X, DENG B L. Fast and robust iterative closest point [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(7): 3450-3466.
- [33] HIROSE O. Geodesic-based Bayesian coherent point drift [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(5): 5816-5832.

作者简介:



王 佳(1987—),男,湖南郴州人,博士,讲师。2011年获湖南师范大学学士学位,2016年和2022年分别获国防科技大学硕士和博士学位。曾在国防科技大学ATR重点实验室从事目标识别算法设计工作,参与多个型号项目研制。主要从事目标识别、计算机视觉等方面的研究。E-mail: wangj_cs04@ccsu.edu.cn

通讯作者:



吴 昊(1993—),男,江苏金坛人,博士,副研究员。2015年获南京航空航天大学学士学位,2017年和2022年分别获国防科技大学硕士和博士学位。主要从事极化雷达成像及信息处理、光学图像处理等方面的研究。E-mail: wuhao@idata.ah.cn