

· 图像处理 ·

基于改进 RANSAC 算法的雾天自动驾驶汽车视觉图像配准方法

李佳奇^{1,2}, 聂婷¹, 毕国玲¹, 黄良¹¹中国科学院长春光学精密机械与物理研究所, 长春 130033;²中国科学院大学, 北京 100049

摘要: 针对雾天中依靠视觉 SLAM 的自动驾驶车辆图像匹配率较低的问题, 通过模拟不同雾天中的行车场景, 对三种特征点检测和描述算法进行了性能测试, 得出采用 SURF 检测子结合 SIFT 描述子在雾天中鲁棒性和配准率较强, 并通过 FLANN 算法完成粗匹配。同时对 RANSAC 算法进行了改进, 通过设立测试集和自适应降低阈值的方法改善错误单应矩阵造成的运算效率较低, 并采用自适应采样次数的方法解决算法迭代次数的上限问题, 完成图像配准。在 DAIR-V2X 数据集上的实验结果表明: 改进的 RANSAC 算法能够相对最优地得到正确匹配点对, 且相较于 PROSAC 和传统的 RANSAC 算法, 运行速度分别提升了 18.5% 与 42.7%。

关键词: 交通安全; 自动驾驶; 图像匹配; 自适应参数

中图分类号: TN209 文献标识码: A doi: 10.14016/j.cnki.jgzz.2023.11.054

Visual image registration method of autonomous vehicle in fog based on improved RANSAC algorithm

LI Jiaqi^{1,2}, NIE Ting¹, BI Guoling¹, HUANG Liang¹¹Changchun Institute of Optics and Mechanical Sciences, Changchun 130033, China;²University of Chinese Academy of Sciences, Beijing 100049, China

Abstract: Aiming at the low matching rate of automatic driving vehicle image relying on visual SLAM in fog days, three feature point detection and description algorithms are tested by simulating driving scenes in different fog days. It is concluded that SURF detector combined with SIFT descriptor has better robustness and registration rate in fog days, and rough matching is completed by FLANN algorithm. At the same time, it improves the RANSAC algorithm, improves the low operational efficiency caused by error homography matrix by setting test set and adaptive lowering threshold, and uses the method of adaptive sampling times to solve the problem of upper limit of iteration times and complete image registration. The experimental results on DAIR-V2X data set show that the improved RANSAC algorithm can obtain the correct matching point pairs relatively optimally, and the running speed is increased by 18.5% and 42.7% respectively compared with PROSAC and traditional RANSAC algorithm.

Key words: traffic safety; autopilot; image registration; adaptive parameters

1 引言

雾天尤其是浓雾天气对以视觉 SLAM 为主的自动驾驶汽车影响很大, 由于能见度较低而造成的交通

事故屡见不鲜。图像配准算法是视觉 SLAM 中的初始环节, 对于后续的跟踪和位姿估计, 以实现视觉里程计的作用来说至关重要^[1]。

图像去雾成为重要的技术方向^[2], 然而去雾算法普遍计算量较大, 部分图像特征也容易被消除。部分学者采用了先去雾, 再进行特征点提取与匹配的方法^[3-4], 但会提高算法的复杂度且仍未能解决去雾算法的弊端。对于雾天行车场景中的特征点提取与匹配算法研究主要有杜晶晶^[5]采用了双向精度匹配的加速稳健特征算法(speed-up robust features, SURF),

收稿日期: 2023-05-13

基金项目: 国家自然科学基金项目(No.62105328)

作者简介: 李佳奇(2000-), 硕士研究生, 研究方向: 红外遥感、图像处理。E-mail: 1970626178@qq.com

通讯作者: 黄良(1986-), 博士, 研究员, 研究方向: 航天遥感成像电子学及图像处理。E-mail: hezqxfk9@162.com

http://www.laserjournal.cn

但缺乏了将车辆和行人进行针对性的测试。对于随机样本一致性算法 (random sample consensus, RANSAC) 的改进,主要有邵进达等^[6]通过 KNN 的方法筛选单应矩阵,但没有对阈值和采样次数进行更好的约束,会导致大量重复计算。Liu 等^[7]将匹配点间的欧氏距离进行排序和剔除,虽然减少了迭代次数,但运行时间仍较长。

提出了一种在雾天自动驾驶行车场景中,准确性和鲁棒性较强的图像配准算法。算法以 SURF 作为检测符,充分发挥其抗雾干扰的鲁棒性和较好的快速性,结合经典的 SIFT 算法生成尺度不变描述矢量,通过高效的快速最近邻搜索包 (fast library for approximate nearest neighbors, FLANN) 匹配算法进行初步配准,最后利用自适应最低阈值和自适应采样次数改进 RANSAC 算法,高效且最优的剔除误匹配点对,根据剩余的匹配点对完成配准,同时一定程度上提高了算法的快速性。

2 图像配准算法

2.1 特征点提取与匹配算法

在视觉 SLAM 中,为了获取前后图像的对应关系,需要在图像间进行特征点提取与匹配,按顺序可分为以下 3 个步骤^[8]。

(1) 特征点检测。识别感兴趣的点。

(2) 特征点描述。为了保持算法在平移、尺度、光照和旋转等变化下的鲁棒性,算法描述了每个特征点周围的局部特征,为每个特征点提供描述符向量。

(3) 特征点匹配。通过比较图像中的描述符来识别相似的特征。对于 2 幅图像,可以得到 1 组匹配对 $(x_i, y_i) \rightarrow (x'_i, y'_i)$, 其中 (x_i, y_i) 是待匹配图像的特征, (x'_i, y'_i) 是基准图像的特征。

David^[9]于 2004 年首次提出了高效的尺度不变特征变换 (scale-invariant feature transform, SIFT) 算法,被广泛应用于机器视觉领域。SIFT 算法的精度很高,具有较强的尺度不变特性,这对于自动驾驶过程中移动物体的配准至关重要,但由于计算的复杂性,工作速度较慢。Bay^[10]于 2006 年对 SIFT 算法进行了改进,提出了 SURF 算法,提高了特征提取的效率。SURF 算法的运行速度较 SIFT 算法有所提高,对于模糊变换的稳定性很好,这一特性对于雾天中的特征提取较为重要。Rublee 等^[11]于 2011 年提出了一种快速特征点提取和描述的算法 (oriented fast and rotated brief, ORB), 它的实时性非常好,运行速度远快于 SIFT。但 ORB 算法提取的特征点没有尺度不变特性,当目标发生距离变化,或者运动过程中发生抖动

等图像尺度变化时,ORB 算法的匹配率和准确度都会有一定的降低。

ORB、SIFT 和 SURF 这 3 种算法,它们既能单独作为关键点检测器又能配合其他检测器生成关键点描述符。目前经典的特征点提取与匹配算法并不能同时兼备快速性、准确性和鲁棒性,高速度和高精度之间并不能两全,下面对本算法进行简单介绍。

SURF 算法的核心步骤是采用 Hessian 矩阵检测特征点,对于图像 $f(x, y)$, 尺度为 σ 的点 (x, y) 处的 Hessian 矩阵见式 (1)。

$$A = \begin{bmatrix} L_{xx}(x, y, \sigma) & L_{xy}(x, y, \sigma) \\ L_{xy}(x, y, \sigma) & L_{yy}(x, y, \sigma) \end{bmatrix} \quad (1)$$

式中: L_{xx} 、 L_{xy} 和 L_{yy} 为经过高斯二阶微分后图像 $f(x, y)$ 在点 (x, y) 处的卷积。SURF 使用了盒式滤波器,进一步求得矩阵 A 判别式的近似值 A_{app} 见式 (2)。

$$\det(A_{\text{app}}) = D_{xx}D_{yy} - (\omega D_{xy})^2 \quad (2)$$

式中 D_{xx} 、 D_{yy} 和 D_{xy} 为不同尺寸盒式滤波与图像的卷积; ω 为补偿参数一般取 0.9。

而 SIFT 算法以图像局部的梯度方向为基础,分配给每个关键点位置 1 个或多个方向。从而确保在对于关键点的方向、尺度和位置进行变换时的不变性。

蛮力匹配算法 (brute force, BF) 通过将所有特征点相互比较寻找对应匹配对,特点是比较直接,但效率较低,消耗的时间较长。Muja 和 Lowe^[12]于 2009 年提出 FLANN 匹配算法,该算法构建了非常有效的数据结构 kd 树来搜索匹配对,避免了 BF 的穷举搜索。算法的核心为使用欧式距离来寻找目标点的最临近点 2 个 d 维向量 $X(X_1, X_2, \dots, X_d)$ 与 $Y(Y_1, Y_2, \dots, Y_d)$ 之间的欧式距离 $D(X, Y)$ 的定义如式 (3) 所示。

$$D(X, Y) = \left[\sum_{i=1}^d (X_i - Y_i)^2 \right]^{1/2} \quad (3)$$

2.2 RANSAC 算法改进

Fischler 等^[13]提出了鲁棒性较强的 RANSAC 算法进行参数估计,被常用于剔除误匹配点对。其核心思想为迭代算法,通过小样本数据计算模型参数,以得到理想的参数使得模型包含尽可能多的内点。RANSAC 算法的基本原理如下:

1) 通过对 4 对粗匹配点的随机采样计算出初始单应矩阵 $H(i)$, 并通过 $B_i = H(i) A_i$ 进行图像间坐标变换,计算公式如式 (4) 所示:

$$\begin{bmatrix} x_b \\ y_b \\ 1 \end{bmatrix} = \begin{bmatrix} h_0 & h_1 & h_2 \\ h_3 & h_4 & h_5 \\ h_6 & h_7 & 1 \end{bmatrix} \begin{bmatrix} x_a \\ y_a \\ 1 \end{bmatrix} \quad (4)$$

式中 (x_a, y_a) 为初始坐标; (x_b, y_b) 为变换后坐标; h_0

$-h_7$ 8 个参数需要通过选取的 4 对采样点进行计算才能确定。

2) 遍历计算其余匹配点对与 H 的投影误差 E_i , 如果误差小于设定的阈值 $k=4$, 则认为该匹配点为内点, 其余的被称为外点而剔除。计算公式如式(5)所示:

$$E_i = \sum_{i=0}^n \left(x_i - \frac{h_0 x_i + h_1 y_i + h_3}{h_6 x_i + h_7 y_i + 1} \right)^2 + \left(y_i - \frac{h_3 x_i + h_4 y_i + h_5}{h_6 x_i + h_7 y_i + 1} \right)^2 \quad (5)$$

3) 统计所有的内点个数完成 1 次迭代, 并重新开始进行下一次采样和迭代直到得到最优解为止。

传统 RANSAC 算法存在 2 个问题, 首先是每次迭代都需遍历计算每个点的投影误差, 可能会因为随机抽取的点为外点计算出错误的单应矩阵, 从而进行大量的无用计算, 导致时间的浪费。针对单应矩阵错误计算带来的影响, 采用了自适应最低阈值的方法, 具体流程如下:

1) 初始时设定最低正确匹配率 $P_{\min} = 98\%$, 失败采样次数 $n=0$ 。

2) 随机抽取 4 个采样点, 判断是否共线并计算单应矩阵 $H(i)$, 在剩余的匹配点集合中随机抽取 1/4 作为测试集, 其余作为验证集。

3) 从测试集中筛选出内点 $S_1(i)$, 得出内点率 $P_1(i)$ 。

若 $P_1(i) > P_{\min}$, 说明得到了合适的单应矩阵, 并继续计算验证集的投影误差, 得出内点 $S_2(i)$, 并计算该集合的全部内点 $S(i) = S_1(i) + S_2(i)$, 及总内点率 $P(i)$, 并将失败采样次数 n 归零。

若 $P_1(i) < P_{\min}$, 且失败采样次数 $n < 20$, 则失败采样次数加 1, 重新进行步骤 2。

若 $P_1(i) < P_{\min}$, 且失败采样次数 $n > 20$, 则说明设定的最低正确匹配率过高, P_{\min} 降低 2%, 失败采样次数 n 归零重新开始计数, 并进入到步骤 2。此处 P_{\min} 、失败采样次数 n 和每次降低的阈值可以根据算法整体内点率进行更改, 如 $P_{\min} = 90\%$, $n = 100$, 单次降低 10%, 本算法的整体正确匹配率较高, 所以下降阈值设置较小。

其次, 传统 RANSAC 算法没有很好地设置迭代次数的上限, 虽然迭代次数越多可能会得到更好的参数, 但随之消耗的时间也会大大增加, 也可能会导致大量的重复计算, 效率不高, 而如果上限次数设置较少, 可能得不到最优结果, 甚至使得结果出现错误。针对迭代次数上限设置的问题, 接着的具体流程如下:

4) 采用了自适应采样次数 i_{\max} 的方法, 公式如式(6)所示。

$$i_{\max} = \frac{\log(1 - P_n)}{\log[1 - (1 - P)^m]} \quad (6)$$

式中: 置信度 $P_n = 0.95$; P 为当前最优的内点率, 初始值置为 0; $m = 4$ 。

若总内点率 $P(i) > P$, 将 P 的值更新, 迭代次数 i 归零, 并重新进行步骤 2) 到 4)。

若总内点率 $P(i) < P$, 且 $i < i_{\max}$, 则重新进行步骤 2) 到 3)。

若总内点率 $P(i) < P$, 且 $i > i_{\max}$, 则迭代结束, 得到最优的单应矩阵和内点集。

改进的 RANSAC 算法的流程图如图 1 所示。

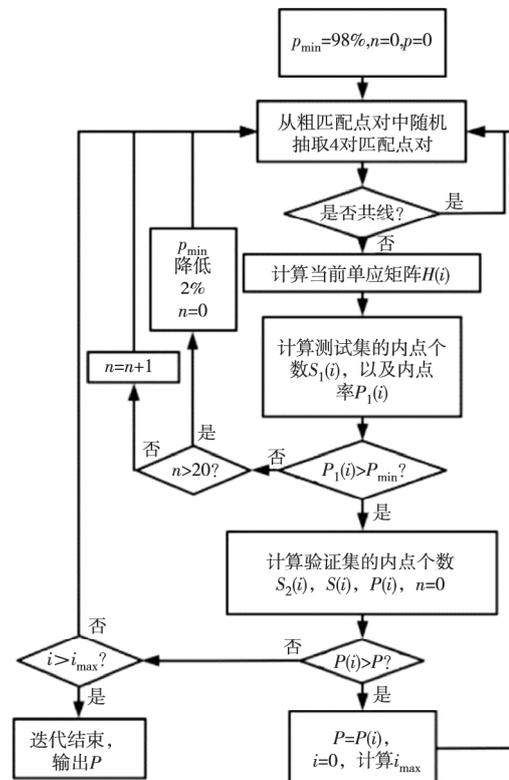


图 1 改进的 RANSAC 算法流程图

3 实验及结果分析

3.1 实验平台与数据集

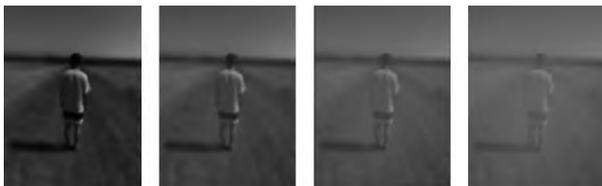
使用的硬件平台为笔记本电脑, 其运行内存为 16 GB, 操作系统为 Win10, CPU 采用的是 Intel(R) Core(TM) i5-1135G7@2.40 GHz, 锐炬显卡。运用的编程语言为 python, 库管理器为 Anaconda, 解释器为 python3.6, 编辑器为 Pycharm, 调用了 OPENCV 中的函数。

根据国家现行的《雾的预报等级》^[14], 将雾根据能见度不同分为了五个等级, 结合实际的行车场景,

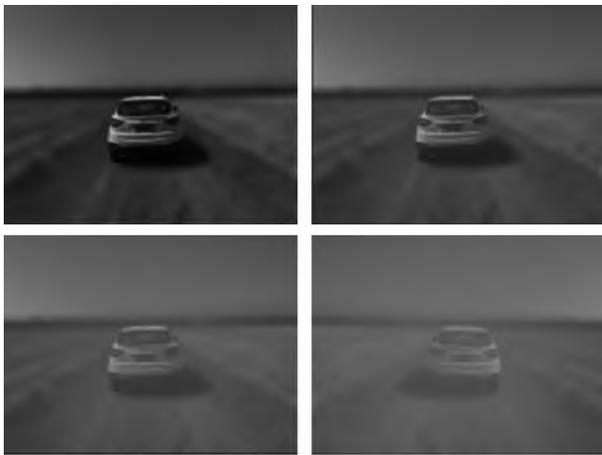
将雾天分为了无雾、雾、大雾和浓雾四类。常见用来训练去雾网络的数据集如 RESIDE、NYU2、D-HAZY 大多数为室内合成雾的图片,而部分室外图片也不太能满足对于不同浓度雾天和不同目标距离行车场景的需求,所以自制了模拟雾天行车场景数据集。

首先在无雾的天气下实地拍摄了不同距离、不同方位车辆和行人的图像,利用加雾算法,调节 beta 为 0.3、0.6、0.9 模拟了不同等级的雾天,并利用能见度等级检测算法进行了测试^[15],共形成 60 种不同场景,其中车辆图像的分辨率为 600×450,行人图像的分辨率为 600×800,部分模拟场景见图 2 所示。

并采用清华大学在真实场景采集的车路协同自动驾驶 DAIR-V2X 数据集对本算法进行验证,随机选取了其中的一些场景并对其同样进行不同程度的加雾处理,图像分辨率为 480×270,部分图像见图 3 所示。



(a) 不同浓度雾中的行人



(b) 不同浓度雾中车辆

图 2 模拟雾天实地拍摄图像



图 3 模拟雾天 DAIR-V2X 图像

3.2 特征点检测算法选择

为更好地比较不同特征点检测算法受到雾天干扰和距离变化的影响,对数据进行了归一化处理,再

绘制出折线图,如图 4 所示。

从整体来看,3 种算法随着拍摄距离和雾气浓度的增大,检测出的特征点数量基本呈现下降趋势。ORB 算法对于同一位置拍摄的图片,不论是行人还是车辆,随着雾气的加重,特征点数量减少程度都很大,折线图呈现出四条折线比较松散。这说明 ORB 算法检测特征点的能力受到雾天的干扰较大,相较于其他 2 种算法来说鲁棒性不是非常的强,不适合作为在雾天中的特征点检测算法进行使用。SURF 和 SIFT 这 2 种算法,对应物体间折线图的紧密程度和变化趋势基本一致。

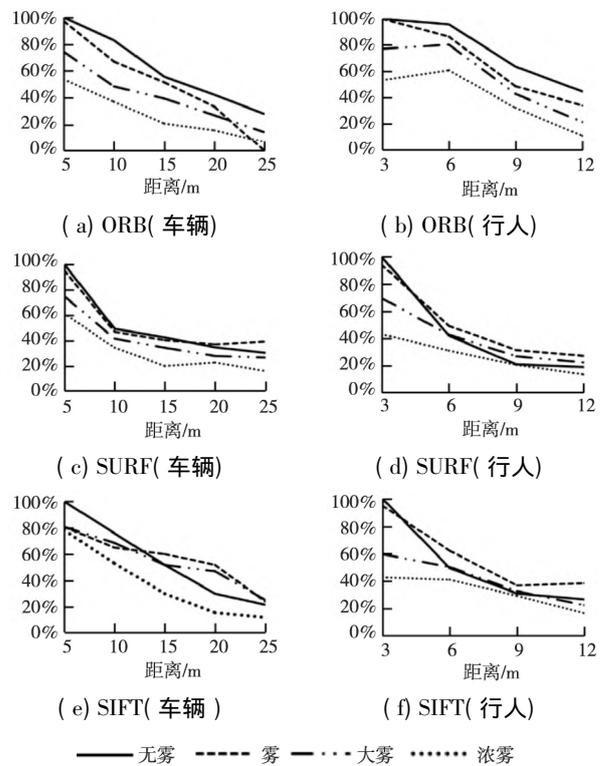


图 4 特征点检测算法鲁棒性比较

进一步将 SURF 和 SIFT 在雾天中检测特征点所消耗的时间进行比较,结果见表 1 所示。在对于尺度变化和可见距离变化的鲁棒性差异不大的前提下,雾天中 SURF 算法检测行人和车辆的特征点速度更快,更适合雾天中的特征点检测算法。

表 1 特征点检测算法运行时间比较

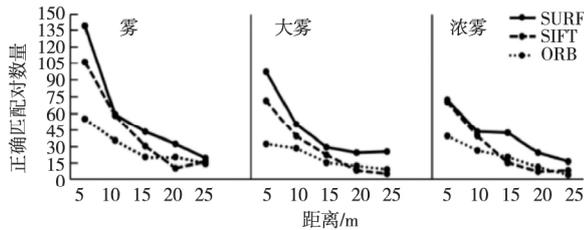
	检测算法	特征点数量	时间/ms	单个点时间/ms
车辆	SURF	141.75	152	1
	SIFT	42.5	65.6	1.5
行人	SURF	201.5	186	0.9
	SIFT	48.6	117	2.4

3.3 特征点描述算法选择

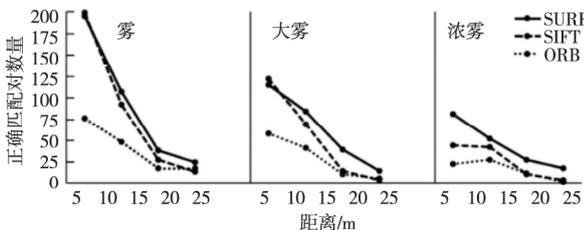
上文确定以 SURF 作为特征点检测算法,下面以

配准结果作为依据进行特征点描述算法的选择。此处开展了 2 个实验,分别是车辆和行人对于距离变化的匹配和对于三目相机不同方位的匹配。

在同一距离尺度内,将每个加雾程度不同的图像都与无雾图像进行逐一匹配,根据距离尺度变化和对应正确匹配对数量得出的折线图见图 5 所示,平均正确匹配率见表 2 所示,平均运行时间见表 3 所示。



(a) 对于车辆的正确匹配对数量



(b) 对于行人的正确匹配对数量

图 5 不同描述符尺度范围匹配结果

表 2 特征点描述算法平均正确匹配率比较

	描述算法	雾/1%	大雾/1%	浓雾/1%
车辆	SIFT	93.5	96.7	97.0
	SURF	82.0	81.7	88.1
	ORB	80.0	74.6	71.0
行人	SIFT	95.8	89.9	100.0
	SURF	94.5	80.5	84.4
	ORB	79.4	75.5	47.6

表 3 特征点描述算法平均运行时间比较

	描述算法	雾/ms	大雾/ms	浓雾/ms
车辆	SIFT	45.9	47.8	38.9
	SURF	28.0	26.9	25.0
	ORB	16.0	19.0	16.9
行人	SIFT	60.9	68.0	57.0
	SURF	38.9	48.9	42.9
	ORB	29.0	30.0	28.9

从图 5 可以看出不同的描述算法, SURF 的正确匹配点数最多, SIFT 仅次, 而 ORB 对于雾天干扰的鲁棒性最差。在雾天, SURF 和 SIFT 在近距离的正确匹配对数量非常多而随着距离的增大, 又快速减少, 且随着雾气程度的加重, 折线斜率变化逐渐变小, 说明尺度变化的鲁棒性逐渐增强。从表 2 可以看出, SIFT

的平均正确匹配率远高于 SURF 和 ORB, 综合正确率在 95% 以上, 能够很好地实现雾天下车辆和行人的特征检测。本质原因可能是 SIFT 描述算法, 采用了邻域方向性信息联合的方法, 对每个特征点生成 128 维的特征向量, 增强了算法抗噪声的能力, 同时对于含有定位误差的特征匹配也提供了较好的容错性, 而 SURF 只有 64 维, ORB 则采用的是二进制描述, 所以 SIFT 特征描述符具有很强的匹配能力。虽然从表 3 中得出, 快速性方面 SIFT 并不占优, 但平均落后的时间并不大, 基本保持在同一量级。

进一步模拟自动驾驶车辆的三目摄像头, 从距离为 5 m 的地方分别拍摄了行人和车辆的左、中、右 3 个方位的图像, 并进行不同程度的加雾处理。将同一加雾程度左、右 2 个方位的图像分别与中间方位的图像进行匹配, 得出的正确匹配率见图 6 所示。

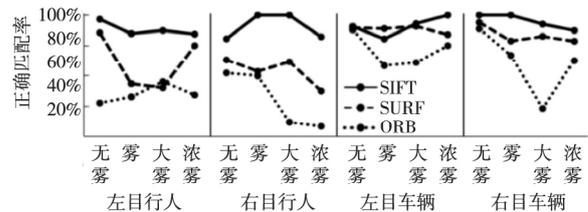


图 6 三目相机不同方位正确匹配率

从图 6 可以得出, 对于行人的正确匹配率, SIFT 描述算法远高于其他 2 个, 而对于车辆的正确匹配率, SIFT 的领先不是非常明显。可能是由于行人目标相对较小, 对其进行特征点匹配可以充分发挥 SIFT 描述算法尺度不变的特性。

3.4 改进的 RANSAC 算法测试

为测试改进的 RANSAC 算法的性能, 从 DAIR-V2X 数据集中选取了 10 张街景进行了不同程度的加雾处理, 选取上文得出综合性能最佳的特征点提取与匹配算法进行粗匹配, 之后分别采用改进的 RANSAC 算法, PROSAC 算法^[16], 以及经典 RANSAC 算法进行错误匹配对的剔除, 得到的精匹配结果如表 4 所示。

表 4 改进的 RANSAC 算法性能对比

		雾	大雾	浓雾
粗匹配数量	改进算法	266.7	135.3	84.4
	改进算法	93.2	94.3	88.1
	正确匹配率/%	PROSAC	93.5	93.1
筛选时间/ms	RANSAC	80.9	86.0	81.0
	改进算法	254.7	139.3	82.0
	PROSAC	306.2	178.0	102.0
RANSAC	402.7	218.3	123.0	



图7 配准结果

从表4可以得出,改进算法与PROSAC算法的正确匹配率基本一致,而原始的RANSAC算法得到的正确匹配率偏低,说明采用自适应采样次数的方法满足得到最优解的要求,而固定采样次数的方法并不能得到最优解。改进算法的筛选速度相对较快,得到一个正确匹配点对平均耗时1ms左右,相对于PROSAC和RANSAC筛选速度分别提升了18.5%与42.7%,说明自适应阈值的方法大大提升了算法的效率,且针对粗匹配算法的初始阈值和固定下降阈值设置也比较合理。观察到筛选时间与粗匹配的数量有较强的线性关系,符合随着匹配对数量增加,遍历计算消耗时间也随之增加的理论。本算法在大雾场景的配准结果如图7所示。

4 结束语

通过模拟不同浓度雾天下的行车场景,得出最适合在雾天中进行特征点提取与匹配的算法为SURF检测符结合SIFT描述符,并采用FLANN进行粗匹配。改进的RANSAC算法能够在较短的时间内得到最优的筛选结果,完成图像配准。通过与PROSAC算法、传统RANSAC算法进行性能比较,得出改进的RANSAC算法的筛选速度分别提升了18.5%和42.7%。本算法的运行时间略长,下一步的研究是提升配准算法的效率。改进的RANSAC算法仍可能存在一些外点,可以在计算单应矩阵之前加上初步的斜率筛选。

参考文献

- [1] Taheri H, Xia Z C. SLAM definition and evolution [J]. *Engineering Applications of Artificial Intelligence*, 2021, 97: 1–25.
- [2] He K M, Sun J, Tang X O. Single image haze removal using dark channel prior [J]. *IEEE transactions on pattern analysis and machine intelligence* 2011, 33(12): 2341–2353.
- [3] Ancuti C, Ancut C O. Effective contrast-based dehazing for robust image matching [J]. *IEEE geoscience and remote sensing letters* 2014, 11(11): 1871–1875.
- [4] 李骥,莫小锋,王威,等.一种基于雾天图像增强的SURF图像匹配方法[J].*计算机工程与应用*,2015,51(14): 141–145.
- [5] 杜晶晶.交通图像去雾方法及应用研究[D].西安:长安大学,2019.
- [6] 邵进达,杨帅,程琳.改进SIFT算法结合两级特征匹配的无人机图像匹配算法[J].*计算机科学*,2019,46(6): 316–321.
- [7] Liu J L, Bu F L. Improved RANSAC features image-matching method based on SURF [J]. *Journal of Engineering - Joe* 2020, 2019(23): 9118–9122.
- [8] 张迁,王剑,楚瑞博,等.基于BRISK-BEBLID特征的无人机图像快速配准方法[J/OL].*激光杂志*: 1–10 [2023-01-04].
- [9] David G. Lowe. Distinctive image features from scale-invariant keypoints [J]. *International Journal of Computer Vision*, 2004, 60(2): 91–110.
- [10] Bay H, Ess A, Tuytelaars T, et al. SURF: Speeded up robust features [C]//9th European Conference on Computer Vision, Graz, Austria; *Adv Comp Vis* 2006.
- [11] Rublee E, Rabaud V, Konolige K, et al. ORB: an efficient alternative to SIFT or SURF [C]//2011 IEEE International Conference on Computer Vision, Barcelona, Spain: IEEE, 2011.
- [12] Muja M, Lowe D G. Fast approximate nearest neighbors with automatic algorithm configuration [C]//Proceedings of IEEE Conference on Computer Vision Theory and Applications, Lisbon, Portugal: IEEE Computer Society, 2009.
- [13] Fischler M, Bolles R. 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.
- [14] 中国气象局.雾的预报等级:GB/T 27964–2011[S].邢台:中华人民共和国国家质量监督检验检疫总局,2011.
- [15] 胡平,杨旭东.高速公路能见度快速检测算法[J].*公路交通科技*,2017,34(4): 115–122.
- [16] Chum O, Matas J. Matching with PROSAC – progressive sample consensus [C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Diego, American: IEEE, 2005.