

上海交通大学硕士学位论文

基于视觉惯性里程计的无人机室内定位研究

硕 士 研 究 生：李忠威

学 号：116413910042

导 师：敬忠良教授

申 请 学 位：工程硕士

学 科：航空工程

所 在 单 位：航空航天学院

答 辩 日 期：2019 年 1 月

授予学位单位：上海交通大学

Dissertation Submitted to Shanghai Jiao Tong University
for the Degree of Master

**RESEARCH ON INDOOR POSITIONING
OF UAV BASED ON VISUAL INERTIAL
ODOMETRY**

Candidate:	LI Zhongwei
Student ID:	116413910042
Supervisor:	Prof.JING Zhongliang
Academic Degree Applied for:	Master of Engineering
Speciality:	Aeronautical Engineering
Affiliation:	School of Aeronautics and Astronautics
Date of Defence:	Jan, 2019
Degree-Confering-Institution:	Shanghai Jiao Tong University

基于视觉惯性里程计的无人机室内定位研究

摘 要

由于传统 GPS 导航系统无法实现无人机室内定位,新型的室内定位技术成为无人机领域热门的研究方向。惯性测量单元(Inertial Measurement Unit, IMU)能够测量元件本身的角速度和角加速度,但是都存在明显的漂移,使得积分两次得到的位姿数据非常不可靠,而视觉传感器基本不会漂移,但具有由于短时间快速运动出现运动模糊以至于无法进行特征匹配的问题。综上,IMU 能为快速运动提供较好的解决方式,而视觉传感器又能在慢速运动下解决 IMU 漂移问题,因而二者具有明显的互补性。传感器受到外界特殊环境或者本身故障的影响会使输出数据出现不可靠的“野值”情况。将量测噪声协方差矩阵建模为逆 Wishart (Inverse Wishart, IW) 分布时,根据变分贝叶斯可推导出其量测噪声近似服从 t 分布,因此可以模拟噪声野值的重尾特性。本文主要工作内容如下:

(1) 本文首先针对具体的多旋翼姿态解算模型提出了一种基于量测噪声协方差矩阵为 IW 分布的多旋翼姿态解算方法用于处理重尾噪声情况,通过采集的 IMU 的陀螺仪和加速度计数据进行仿真,并设置两组重尾噪声存在与否的实验和基于扩展卡尔曼滤波(Extended Kalman Filter, EKF)的姿态解算方法进行对比,实验结果显示所提姿态解算方法在重尾噪声条件下具有鲁棒性。

(2) 将视觉里程计和 IMU 采用松耦合的方式进行融合,使用 IMU 数据进行预测,然后在更新过程时只采用视觉里程计的输出作为量测值来矫正 IMU 积分的漂移。为处理视觉输出数据可能出现重尾噪声情况,故采用 IW 量测噪声协方差矩阵模型提出一种针对重尾噪声的视觉惯性组合导航方法。基于开源数据集,设置两组实验,将融合

后的实验结果与单视觉里程计的实验结果进行对比，验证了融合算法的有效性，然后设置量测噪声出现重尾噪声情况，将融合结果与基于EKF融合框架结果进行比较，验证了本文提出的融合算法对重尾噪声处理的鲁棒性。

关键词：视觉惯性融合；鲁棒姿态解算；量测野值；重尾噪声

RESEARCH ON INDOOR POSITIONING OF UAV BASED ON VISUAL INERTIAL ODOMETRY

ABSTRACT

Indoor positioning technology has become a hot research topic in the field of Unmanned Aerial Vehicle (UAV). In low speed condition, the angular velocity and acceleration of the component itself measured by Inertial Measurement Unit (IMU) has obvious drift, which causes the obtained position and attitude of UAV has deviation from the actual one, while visual sensor performs well. On the other hand, in high speed condition visual sensor has motion blurring due to fast motion, and IMU does not have such a problem. In the thesis, IMU will be used for fast motion measurement and visual sensor will be adopted in slow motion condition. For the "outliers" produced by sensors, the measurement noise covariance matrix will be modeled based on the inverse Wishart (IW) distribution, which makes the measured noise follow the t-distribution. Then the heavy-tailed characteristic of the outliers noise can be simulated. The main work of this paper is demonstrated as follows:

Firstly, an attitude measurement method for multi-rotor system will be proposed based on IW distribution. Then the simulation will be performed with input from the collected data of IMU gyro and accelerometer. For comparison, the simulation with noise "outliers" as input will also be carried out. The results based on Extended Kalman Filter(EKF) and the proposed attitude method will be compared to show the robustness to heavy-tailed noise.

Additionally, the visual odometer and the IMU will be fused in a loosely coupled manner. The IMU data will be used as input to predict the states of UAV, and then the output of the visual odometry will be adopted to correct such states. In order to deal with the heavy-tailed noise of visual

output data, a visual inertial integrated navigation method for heavy-tailed noise will be proposed by using IW distribution. Based on the dataset collected on-board a Micro Aerial Vehicle (MAV), the experiment result will be used to verify the effectiveness of the fusion algorithm and the single visual odometry. Then the outliers of the measurement noise will be introduced, and the fusion result will be compared with the result of EKF fusion framework to show the robustness of the proposed fusion algorithm for heavy-tailed noise.

KEYWORDS: Visual inertial fusion; Robust attitude measurement; Measurement outlier; Heavy-tailed noise

目 录

基于视觉惯性里程计的无人机室内定位研究	I
摘 要	I
ABSTRACT	III
第一章 绪论	1
1.1 研究背景与意义	1
1.2 研究现状	2
1.2.1 惯性导航发展现状	2
1.2.2 视觉里程计发展现状	3
1.2.3 惯性视觉组合导航发展现状	6
1.3 论文结构	7
第二章 视觉惯性组合导航基础知识	9
2.1 惯性系统位姿描述方法	9
2.1.1 坐标系定义	9
2.1.2 姿态表示方法	10
2.2 惯性系统位姿描述方法	11
2.2.1 姿态解算方法	11
2.2.2 速度位移解算方法	12
2.3 相机投影模型	13
2.3.1 坐标系	13
2.3.2 投影模型	13
2.4 基于稀疏直接法的视觉里程计 ^[24]	15
2.4.1 基于稀疏点亮度的位姿预估	15
2.4.2 基于图像块的特征点匹配	16
2.4.3 基于特征位置的位姿再优化	17
2.4.4 地图构建	17
2.5 本章小结	18
第三章 针对重尾噪声的鲁棒姿态解算方法	20
3.1 问题提出	20

3.2 针对重尾噪声的鲁棒姿态解算方法	21
3.2.1 测量噪声建模	21
3.2.2 多旋翼姿态解算模型建立	23
3.2.3 针对重尾噪声的鲁棒姿态解算算法	24
3.3 实验与分析	25
3.3.1 不存在重尾的高斯噪声环境	26
3.3.2 量测噪声存在重尾环境	28
3.3.3 结果与分析	29
3.4 本章小结	30
第四章 针对重尾噪声的鲁棒视觉惯性组合导航算法	31
4.1 问题提出	31
4.2 组合导航模型建立	31
4.2.1 系统状态方程 ^[52]	31
4.2.2 系统观测方程 ^[52]	34
4.2.3 量测噪声建模	35
4.3 针对重尾噪声的视觉惯性组合导航算法	36
4.4 实验与分析	37
4.5 本章小结	42
第五章 总结与展望	44
5.1 主要工作与创新点	44
5.2 后续研究工作	45
参 考 文 献	46
致 谢	50
攻读硕士学位期间已发表或录用的论文	51

图 录

图 1-1 几种商用的室内定位无人机	1
图 3-1 无人机真实姿态角度	26
图 3-2 高斯噪声下俯仰角误差对比	27
图 3-3 高斯噪声下横滚角误差对比图	27
图 3-4 高斯噪声下航向角误差对比	28
图 3-5 重尾噪声下俯仰角误差对比	28
图 3-6 重尾噪声下横滚角误差对比	29
图 3-7 重尾噪声下航向角误差对比	29
图 4-1 融合算法流程图	37
图 4-2 融合算法与 VO 及数据集参考值位置对比	39
图 4-3 融合算法与 VO 及数据集参考值姿态对比	39
图 4-4 融合算法计算的相对于世界坐标系速度	40
图 4-5 融合算法计算的角速度及加速度偏差	40
图 4-6 IMU 线加速度变化	41
图 4-7 IMU 角加速度变化	41
图 4-8 重尾噪声下 FUSION 与 EKF 位置对比	42
图 4-9 重尾噪声下 FUSION 与 EKF 姿态对比	42

表 录

表 3-1 针对重尾噪声的鲁棒姿态解算方法流程表	25
表 4-1 针对重尾噪声的鲁棒视觉惯性组合导航算法流程	36

第一章 绪论

1.1 研究背景与意义

最近几年无人机(Unmanned Aerial Vehicle, UAV)技术得到了很大发展,并广泛应用于航拍、植保、安防等和众多领域。但对于复杂的未知环境,无人机实现独立自主飞行仍存在很多难题。只有解决了基本的导航问题,无人机才可以完成诸如集群飞行、大规模的轨迹规划等高级任务。对于室外环境飞行,全球定位系统(Global Positioning System, GPS)能够提供精确的定位服务,可以满足无人机独立飞行需求。但对于室内飞行场景,比如当无人机在室内执行拍摄和救援任务时,由于导航信号受到遮挡和屏蔽,这就使得广泛应用于室外飞行导航中依赖于卫星导航的算法失效,并且室内环境相对狭小复杂,这样更增加了无人机自主作业的难度,因此新型可靠的 UAV 室内导航定位算法是个重要的研究方向。目前对于室内定位,国内外提出了一些室内定位方法,比如基于超声波和无线网等。但是这些定位技术都需要外部环境的支持使得无人机飞行并不具备“自主”功能,而必须依赖于外部的信标。对于只依赖于无人机本身携带的传感器实现导航定位,比如基于惯性元件、激光雷达、相机等的室内定位算法具有更大的优势。



图 1-1 几种商用的室内定位无人机
Fig. 1-1 Several commercial indoor positioning UAVs

基于视觉的室内定位在近几年来得到了很大发展并且部分得到了商用,比如大疆 MAVIC、AR.DRONE 无人机和 PARROT MAMBO 无人机等,但是存在定位精度较低、稳定性较差的缺点,很大程度上影响了飞行精度和可控性。惯性导航系统(Inertial Navigation System, INS)的定位利用传感器经过积分计算出位置、速度、姿态等,速度更新率比较高、短期精度与稳定性较好,但是定位误差会随时间积累。依赖于视觉里程计的导航技术是目前比较新颖且研究火热的一种室内定位方法。但是视觉里程计会有很大的空间漂移,因为由位姿积分而来的。这恰与惯性测量单元(Inertial Measurement Unit, IMU)存在的时间漂移问题存在互补。因

无人机板载计算能力有限,利用视觉传感器和 IMU 信息实现融合低计算量的组合定位算法受到了广泛关注。

1.2 研究现状

1.2.1 惯性导航发展现状

惯性导航系统是不需要外界传感器的无源式独立导航系统^{[1][2]},因为其不依赖于外界信息、并且受外部环境影响较低,因此具有很强的独立性和隐秘性,因为惯性传感器不仅不受外界影响而且价格便宜,所以小到儿童玩具大到飞机、火箭、潜艇、轮船等均采用惯性元件,INS 工作原理是根据传感器的输出进行对时间的积分,然后通过坐标系的转化得到最终导航信息。根据已知初始位置不断地通过实时累加传感器所测得的加速度和角速度从而计算出下一时刻的姿态和位置,故属于航位推算方式。

常见的惯性导航系统根据传感器不同的特点分为机械^{[3][4]}、光学等陀螺仪,或者根据使用方法的差异又分为平台式^{[5][6]}和捷联式^{[7][8]}惯导系统。所谓平台式惯导系统就是将传感器直接固连到运动物体上,即传感器姿态于运动载体姿态一致,而捷联式惯性导航系统中传感器直接得到的姿态与运动物体之间不是一致的,故需要进行坐标系转化,通过旋转矩阵,最终将传感器测得的姿态转化为运动载体的姿态。相比于平台式系统,捷联式现在无人机中用的较为广泛,但是其姿态解算过程比平台式要复杂,比如当今常用到的 Mahony、基于四元数的还有比如用的很广泛的基于扩展卡尔曼滤波(Extended Kalman Filter, EKF)的姿态解算方法等。虽然解算方法比平台式要复杂并且精度没有平台式高,但是相比于平台式需要昂贵的价格和复杂的制造工艺及特定场景的要求,捷联式受到追捧。

惯导系统的发展是由上世纪开始逐渐兴起,上世纪 30 年代之前的阶段属于第一阶段,主要是牛顿定律的诞生为惯性导航的原理推导提供了可能。从 1940 年以后,随着制造工艺的进步和材料科学的发展,新的传感器被制造出来,并且随着第一次工业革命及一战的影响,促进了火箭等武器的发展,使得惯性导航成为了研究热点,这段时间内逐步出现了液浮陀螺平台导航系统、挠性和气浮式等,1960 年激光技术的出现为接下来的激光式惯性导航基础提供了可能,这属于第二阶段。1970 年之后,由于新的传感器的出现,比如激光式和光纤式传感器,使得惯性导航的精度得到的大幅度的提升,并且应用也随之更为广泛。汽车、船舶、航空器

和航天器的发展也离不开惯导技术的进步,进而开启了第三阶段。进入 1980 年后,由于半导体材料和技术的发展,新型的基于半导体的微机机械式的微机电系统得以出现。进而更加提高了惯性导航的精度及应用领域。现在,我们所处于的是第四阶段,当今各项技术得到了前所未有的高速发展,比如微机技术、材料技术、电子信息技术等的发展,使得惯导系统向着高精密度、高稳定性及鲁棒性和数字化的方面发展。

虽然惯导系统性能随着惯导元件和惯导理论技术的发展已经得到了很大提升,但是由于其原理本身的缺陷型,单独的依靠惯性元件数据积分得到的精度已无法满足当今社会的需求,比如惯性导航系统会由于时间的推移,使得积分结果漂移增大,将会低于所需的结果。人们为克服这个难题,一方面继续提升惯导本身精度,另一方面试图增加其他类型的传感器,通过数据融合得到更好的导航精度。目前对于室外有 GPS 信号的使用环境下,采用 GPS/INS 组合导航成为了主流的技术,使用惯导进行位姿估计,然后采用 GPS 输出的数据来矫正惯导的估计值,从而减小漂移误差。姿态方位参考系统(Attitude and Heading Reference System, AHRS)是另一种组合导航系统,仍然采用惯导进行航姿估计,然后分别采用磁力计和加速度计对姿态角进行矫正。

综上,惯性技术通过近百年的发展已经得到了很大的进步,但是人存在自身漂移误差累计的缺点,通过融合其他传感器数据进行组合导航进而减小甚至消除累积误差成为了更加可靠的导航方式。

1.2.2 视觉里程计发展现状

视觉里程计(Visual Odometry, VO)指通过图像传感器输出的图像数据作为输入来估计自身位姿信息的过程。VO 首先是由 Nister 这个人提出来的,概念听起来和轮式的里程计类似,都是通过增量式的叠加计算出位移,但是 VO 还能够解算出相机的运动姿态,这点是轮式里程计无法得到的,并且 VO 不受地面打滑的影响,故能提供高精度的位姿估计,但是需要具有足够纹理的静态图像作为运动特征提取。

上世纪八十年代,随着火星探测事业的发展,传统的导航系统受到限制,视觉里程计首次应用到火星探测车中,结果证明了 VO 不仅能够克服复杂的太空环境,并且对于复杂路面的适应性较强,即使不平坦的路面仍能提供很好的位姿估计,这是传统的轮式里程计无法比拟的。1980 年, Moravec 等人^[9]第一次将视觉系统作为机器人避障和导航使用,他们使用一个桌面大小的移动机器人作为实验

载体，并配备无线通讯模块、相机及发射模块。通过外部的计算机实时计算图像输入，从而进行导航定位与避障，实验表明了机器人能够自主避障导航并能规划路径，但是由于当时计算机计算能力的低下，使得计算速度较慢，因此机器人在获取图像后进行很久的计算才能解算出导航信息，因此机器人运动速度较慢。

基于 Moravec 的工作，2003 年 Matthies 和 Shafer^[10]提出了立体相机导航的误差模型，之前的基于视觉的导航算法精度并不高，原因是单纯采用三角测量法测量时的误差较大，他们提出一种将三角测量误差建模为三维高斯分布，讨论了如何根据图像关系来计算误差模型，实验仿真表明三维的高斯模型降低了机器人位姿估计的方差，更好的区分了平移和旋转运动，验证了将误差建模为高斯分布模型的有效性。Olson^[11]提出了几种由单目和双目相机序列计算观察者的方法。然而在长距离运动中，需要更加鲁棒的算法来提高定位精度，文中证明了由于方向误差的增加使得行程累计的超线性误差，并引入了一种融合绝对航向传感器，在长距离运动中，使得误差变为了线性增长，并且实验验证了该方法使得运动误差减少到总的运动距离的百分之一，文中提出该方法已应用到了火星探测车上，说明了该方法解决实际问题的有效性。Lacroix^[12]等人在文中分析了火星探测器的各种功能，然后提出了一种依靠像素跟踪和立体视觉来跟踪估计探测车的六个位姿参数，他们没有用 Forstner 角点检测而是通过分析峰值处的相关函数^{[13][14]}选取候选关键点，并通过探测车采集的实际数据验证了算法的可行性，最后文中简要的介绍了解决探测车上基于对象环境模型的定位功能。

Cheng^{[15][16]}等人将最大似然估计应用到三维偏移量的计算估计上，从而产生两对之间车辆运动的最终矫正估计，文中主要解决了由于火星上复杂的地形使得导航算法精度下降的问题，比如当在斜坡上运动时，则需要额外的辅助传感器来保证更加准确的位姿估计。最后介绍了视觉里程计应用于火星探测的重要意义，并总结了视觉方法对于火星研究的重要性。视觉里程计中也运用到了也采用了迭代最近点算法^[17] (Iterative Closest Points, ICP)来去除误差较大的点从而得到运动位姿的估计，是一种通用的、独立于表示的方法。而点云融合解决相对运动问题，Nister 创造性地提出“视觉里程计”的概念并且实现了实时长距离鲁棒性的离群点去除算法。

VO 根据相机类型分为单目、双目和深度相机里程计三类。双目虽然能够较为简单的根据双相机图像序列计算出位姿信息，但是其效果在短距离物体时具有很高的精度，但是对于长距离物体时，其优势将会消失。而基于长距离的单目视觉里程计将会拥有更高的精度。视觉里程计方法主要分成特征点法和直接法，其

区别是直接利用图像灰度信息还是使用特征点。基于特征的方法是提取每一帧图像特征中的稀疏信息集合,比如直线、点等,然后根据这些信息提取连续描述子进而进行匹配,然后在进行重投影到前一帧坐标系中进行误差优化,最终解算出最优位姿。此方法优点能够用允许大的帧间运动时依然能匹配成功,但缺点是运动估计中的漂移必须通过多次特征检测来补偿。

Michael^[18]等人第一次将视觉里程计应用到无人机中,文中提出了一种新的基于视觉的车辆定位方法,基于最先进的视觉地图与构建(Simultaneous Localization And Mapping, SLAM)算法跟踪相机的角度,同时,创建周围地区的增量地图。基于这种姿态估计将车辆稳定在期望的设定点,使得无人机执行简单的飞行动作,例如起飞、悬停、设定点跟随或着陆。实验数据表明,该方法能有效地控制直升机在未知、非结构化环境下航行。它能够仅使用单个相机作为外感传感器在未探索的环境中进行导航飞行。Stephan^[19]等人提出了一种视觉惯性融合的框架并且在实际飞行中进行测试,证明了该框架在 70 米到 360 米高度变化时导航飞行测试。他们讨论了无人机上视觉导航的挑战,并从车载估计、传感器融合策略和系统状态估计及自校准方面进行了分析,最终证明了算法的可行性。Compaot 等人^[20]在文中提出了基于图像的立体摄像机对六自由度轨迹跟踪方式。所提出的技术通过执行立体参考对的图像之间的密集空间匹配,来估计序列中的时间图像对之间的姿态,以及随后的密集像素匹配。该方法直接使用立体图像对内可用的所有灰度信息,从而拥有非常鲁棒和精确的结果。文中度量 3D 结构约束是通过一致地扭曲相应的立体图像来施加,以在每次立体图像采集时生成新的视点。基于立体像对的相邻视图内的图像强度之间的四焦点关系,提出一种迭代非线性轨迹估计方法,并且使用鲁棒的估计方法用于处理场景中的离群点,例如遮挡和光照变化时所产生的。将该技术应用于复杂是时间图像中运动车辆的轨迹恢复。

Tykkala^[21]基于 RGB-D 相机使用图像和距离测量,通过最小化强度误差的方法来估计相机的运动姿态。文中将深度相机输出的深度信息结合直接光强成本函数推导出一种新的测量方法,通过双目标成本函数优化产生 3D 相机的运动参数,当具有足够的帧速率时,推导的公式不需要任何预定的时间对应或者是特征提取,算法在图像纹理缺乏和表面信息不足时,具有较强的优越性。Kerl^[22]等人阐述了鲁棒的基于深度图像(RGB-D)的视觉里程计算法,通过测光误差最小化,将两个连续帧直接彼此寄存使用非线性最小化方法结合粗到精的方案估计相机状态。为了考虑图像的噪声和离群点,他们使用鲁棒误差函数,以减少残差的影响。另外所提公式允许包含一个运动模型,可以基于先验知识和时间滤波或者与其他传感

器融合。Engel^[23]提出了一种信息的直接稀疏法视觉里程计方法，算法包括直接概率模型与一致性和多参数联合优化方法，然后进行包括几何推导和相机姿态解算。这是通过省略其他直接法的平滑度来实现的，相比采用均匀的像素采集方式，该方法不依赖关键点检测和角点描述，因此可以自然的从具有强度梯度的所有图像区域进行像素均匀采样，这些图像区域包括边缘或平滑强度变化。该模型继承了全光度校准，考虑了曝光时间等和非线性响应函数。直接法是通过图像的光度值直接估计场景结构和相机运动，相对于基于特征方法，直接法在缺乏纹理特征的环境或运动模糊下更具优势，比如论文[23]中 Direct Sparse Odometry 位姿估计准确并且累积误差小。结合特征点法与直接法有人提出半直接单目视觉里程计^[24] (SVO)，其保证精度较高时计算量较小的优点，适用于无人机。

1.2.3 惯性视觉组合导航发展现状

为了克服单一惯性导航和视觉里程计导航各自缺陷问题，视觉里程计与惯性融合成为了较好的解决方法。根据 VO 信息与 IMU 数据交互方法的不同主要分成松耦合(loosely-coupled)和紧耦合(tightly-coupled)。松耦合并未将图像信息加入到状态向量中，仅仅是依靠 IMU 自身的运动方程来预测状态，然后通过 VO 的输出作为量测值更新，虽然向量维度大大减小，而且整个系统模型的建立相对简单，因为不必考虑图像的预测过程，并且计算量大大降低，但是也正因为此，整个融合精度相对于紧耦合方式而言相对逊色，并且缺乏了对图像信息的利用，并且松耦合要考虑两个传感器信息的更新频率，尤其是对一致性的保证十分重要。但是对于平台计算量较低的应用场景将是一种很好的选择。而紧耦合则将图像信息加入到了状态向量中，会不断地预测更新，并且紧耦合状态向量维数会随着相机运动时间积累而极大增加，也正因为如此，紧耦合的方式对于图像信息的利用比较充分，但是使得计算负载变大，难以满足实时性要求，并且对无人机板载计算机性能提出很大挑战，而对于平台环境计算能力较强的场景则更加适合。其中紧耦合有根据后来对误差处理方式又分为基于滤波的和基于优化的紧耦合。

但比较经典的算法比如明尼苏达大学的 MSCKF^[25](Multi-State Constrain Kalman Filter)在传统的基于滤波的紧耦合 EKF-SLAM 框架中，此算法模型能够很好地表征从多个相机姿态观测静态特征所出现的几何约束，该模型不需要将三维特征位置包括到滤波向量中，并且最优到误差为线性误差，此方法计算的复杂度仅仅和特征数量呈线性关系，故能够在大规模的实时环境中进行位姿估计。苏黎世联邦理工的 ROVIO^[26] (Robust Visual Inertial Odometry)是直接利用图像像素强

度的误差,在检测之后通过将强度误差作为更新项,采用多斑块特征的跟踪与底层扩展卡尔曼紧密耦合的方式,此方法遵循纯机械中心的想法,其三维标签的位置是随着当前相机的位姿来估计的,另外他们将地表位置分解为方位向量和距离参数化,因此采用对应代数的差异最小化表示,从而获得更好的一致性进而可以改善性能。由于此算法采用的是以机器为中心的,并且是逆距离的标志参数化,故框架不需要初始化,是一种真正意义上的状态估计系统。

虽然基于滤波的融合方法被有效证明了,但是其精度相对于基于优化的而言较为逊色,非线性优化的方法由于底层问题的稀疏性解决了在复杂度上仍可以处理的情况。OKVIS^[27](Open Keyframe-based Visual-Inertial SLAM)是基于优化的紧耦合,算法中建立了一个严格的概率成本函数作为优化函数,该函数同时结合了地标和惯性系的重投影误差,通过边缘化将优化先知道关键帧的有界窗口内,进而确保了实时操作,关键帧可以是任意时间间隔的,同时和线性化的惯性系相连。对于这个新结构建立一个统一的误差函数来进行联合优化。相比于 MSCKF, OKVIS 是基于关键帧的代表,其优化目标包括一个重投影误差和一个 IMU 积分误差,其中已知已知观测数据是每两帧间的特征匹配及两帧间所有 IMU 采样数据的积分,优化针对的是关键帧。此算法的创新点是由于优化算法速度的限制,优化不能针对太多帧一起,故尽量把一些信息量少的帧滤掉,只留下一些关键帧之间的约束。ORB_SLAM2^[28]是另一个一个基于优化的紧耦合算法,文章提出了具有地图重用功能的单目视觉惯性定位算法,该算法的具体思路与港科大的 VINS^[29](Visual-Inertial Navigation System)有异曲同工之妙,整体过程包括:基于流型的 IMU 初始化及预积分和紧耦合优化。算法采用一种紧耦合的基于非线性优化的方法,通过融合 IMU 测量和特征观测获得更高的视觉里程计精度,其中回环检测模块结合紧耦合方式,能够以较低计算量的方式实现重定位。另外,该方法执行四个自由度姿态图优化用来增强全局的一致性。

基于滤波的松耦合方法简单了很多,避免把图像特征加入到滤波状态向量中,而是把图像当成一个黑箱,计算 VO 数据后再与 IMU 输出数据进行融合,Lynen^[30]在这方面有较多研究。Falquez^[31]采用基于优化的松耦合把计算产生的位姿变换添加到 IMU 优化框架中。

1.3 论文结构

本文的主要内容是分别提出一种鲁棒的多旋翼姿态解算方法和采用视觉里程计和惯性传感器融合的方式实现无人机室内定位^[32],首先介绍了适合无人机机

载计算量低的 VO 视觉算法，然后针对多旋翼无人机飞行过程中会出现重尾量测噪声的情况，提出了姿态解算方法，并且考虑融合算法在量测出现重尾噪声问题，提出了鲁棒的融合算法，结果表明了该方法的鲁棒性和有效性。论文文章结构分为：

第一章：描述研究背景与意义，并通过查阅大量文献，总结惯性导航、视觉里程计及视觉惯性融合导航定位的发展及研究现状并提出本文研究内容及文章结构。

第二章：列举了惯性导航及组合导航的基本知识，比如位姿描述方法和位姿解算方法，然后介绍了 VO 涉及到的相关知识，比如相机模型等。然后介绍了一种基于稀疏直接法视觉里程计方法，此方法将主要精力放置在导航定位上而忽略建图功能，故计算量小适合于承载能力小的无人机上。

第三章：提出一种鲁棒无人机姿态解算方法，将量测噪声协方差建模为逆 Wishart (Inverse Wishart, IW) 分布，然后针对于无人机姿态解算模型验证了算法在处理量测重尾噪声问题上的鲁棒性和有效性。

第四章：考虑到量测出现异常值的情况，提出一种将 VO 与 IMU 组合导航的融合框架方法，使用 IMU 数据进行实时位姿估计，然后采用 VO 输出数据作为量测值，故而采用松耦合方式进行滤波融合。然后设置两组实验，第一组实验用于测试算法融合精度，第二组实验和扩展卡尔曼滤波框架对比测试对量测重尾噪声处理能力。

第五章：总结本文主要内容并介绍了基于此论文后续的研究方向。

第二章 视觉惯性组合导航基础知识

本章主要讲述视觉惯性组合导航基础知识为接下来的算法推导及实验做准备。首先列举了惯性系统中常用的坐标系和姿态表示及解算方法，然后描述了基本的速度位移计算方法，接着讲述了视觉里程计中用到的相机投影模型的推导过程，最后介绍了一种基于稀疏直接法的视觉里程计，因为在第四章的视觉惯组合导航中用的就是此里程计方法。

2.1 惯性系统位姿描述方法

2.1.1 坐标系定义

在导航、制导和无人机的控制中，有几类应用比较广泛且重要的坐标系，对于算法的设计分析十分重要。要想描述载体的位姿等参数，均需要在一个特定的坐标系下给出，并且坐标系之间的转化关系成为了导航的关键基础知识。一种坐标系的建立必须使得描述空间中一个位置或者描述一个目标的速度是唯一的。为了是位置有意义，则必须指定一个起点或一个参考点作为原点，经过此原点的三条相互垂直的直线作为坐标轴构成一个完整的坐标系。根据所选的参考环境不同，主要分为以下几种：

惯性坐标系（ i 系）：在经典的物理学和狭义相对论中，惯性系是一个参照系，在这个参照系中，作用在它上面的净力为零的物体没有加速度，也就是说这样的物体时处于静止的或者做匀速运动。及惯性坐标系是以均匀的、各向同性的和时间无关的方式描述时间和空间的参照并符合右手正交规则。

地球坐标系（ e 系）：跟随地球旋转并且坐标系原点和地心重合，与惯性系的区别就是惯性系不随地球转动。 Z 轴是南北极之间的连线，正方显示朝着北方向。

地理坐标系（ g 系）：大多数飞行器都采用此种坐标系，随着载体不停的运动，故相对载体静止，根据其坐标轴的定义，通常称为“东北天”坐标系。

导航坐标系（ n 系）：为建模航空航天器飞行轨迹，需要飞行器相对于地球的位置和姿态，导航坐标系被定义为相对于地球的中心和表面，按照地北、东、地的方向定义 x_n, y_n, z_n 轴。

载体坐标系（ b 系）：原点位于载体重心，并跟随其运动，按照载体前右下的方向选取坐标系中的 x_b, y_b, z_b 。

2.1.2 姿态表示方法

在无人机飞行中如果以初始姿态为基准，可以用这组旋转角度和平移向量来表征移动过程中姿态和位置的变化。目前，常用的姿态表示方法有三种：基于方向余弦矩阵、基于欧拉角和基于四元数。

方向余弦矩阵表征一个参考系到另一个参考系的转化关系，一个坐标系的三组单位向量可以通过另一个坐标系三组单位向量线性表出，且表出系数即为方向 C_b^n 的对应各行元素的值。

$$C_b^n = \begin{bmatrix} c_{11} & c_{12} & c_{13} \\ c_{21} & c_{22} & c_{23} \\ c_{31} & c_{32} & c_{33} \end{bmatrix} \quad (2-1)$$

欧拉角是由 Euler 引入的三个姿态角，可以用来描述刚体相对于固定坐标系的定向，他们也可以表示物理学中可以动参考系的定向或者三维线性代数中一般基础的定向。任和定向都可以通过组合三个围绕坐标系轴线的旋转来实，欧拉角可以就是被这三个旋转来定义的，也可以由元素几何定义。三个基本旋转可以是本征的即关于绕原始静止的坐标系三个轴旋转，也可以是本征的，即绕着与自身移动保持一致的坐标系旋转。欧拉角有很多优点，但是一个致命的缺点就是 Gimbal Lock（万向节死锁）。从 n 系按绕 ZYX 轴分别旋转 $\psi\phi\theta$ 度得：

$$\begin{bmatrix} X^b \\ Y^b \\ Z^b \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\theta & -\sin\theta \\ 0 & \sin\theta & \cos\theta \end{bmatrix} \begin{bmatrix} \cos\phi & 0 & \sin\phi \\ 0 & 1 & 0 \\ -\sin\phi & 0 & \cos\phi \end{bmatrix} \begin{bmatrix} \cos\psi & -\sin\psi & 0 \\ \sin\psi & \cos\psi & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X^n \\ Y^n \\ Z^n \end{bmatrix} \quad (2-2)$$

则从 b 系经过 ZYX 旋转 $\psi\phi\theta$ 到 n 系的，其矩阵 $R_b^n = (R_n^b)^T$ ，则：

$$R_b^n = \begin{bmatrix} \cos\phi\cos\psi & \sin\theta\sin\phi\cos\psi - \cos\phi\sin\psi & \cos\theta\sin\phi\cos\psi + \sin\theta\sin\psi \\ \cos\phi\cos\psi & \sin\theta\sin\phi\sin\psi + \cos\phi\cos\psi & \cos\theta\sin\phi\sin\psi - \sin\theta\cos\psi \\ -\sin\phi & \sin\theta\cos\phi & \cos\theta\cos\phi \end{bmatrix} \quad (2-3)$$

三个欧拉角随时间传递为：

$$\begin{aligned} \dot{\psi} &= (w_x \sin\psi + w_z \cos\psi) \tan\phi + \omega_x \\ \dot{\phi} &= w_y \cos\psi - w_z \sin\psi \\ \dot{\theta} &= (w_x \sin\psi + w_z \cos\psi) \sec\phi \end{aligned} \quad (2-4)$$

以上公式表示了载体相对于导航坐标系的欧拉角随时间的变化。

在数学中，四元数是一个扩展复数的数系，Hamilton 首次对他进行了描述，将其应用于三维空间的力学中。将四元数定义为三维空间中两条有向线的商或者

等价的定义为两个向量的商。若一个四元数向量表示为 $a + bi_1 + ci_2 + di_3$ ，者其满足式 (2-5) 所示，

$$\begin{aligned} i_1^2 &= i_2^2 = i_3^2 = -1 \\ i_1 i_2 &= i_3, i_2 i_1 = -i_3 \\ i_2 i_3 &= i_1, i_3 i_2 = -i_1 \\ i_3 i_1 &= i_2, i_1 i_3 = -i_2 \end{aligned} \quad (2-5)$$

2.2 惯性系统位姿描述方法

2.2.1 姿态解算方法

捷联惯导中，陀螺仪测得的三个轴向角速度是相互耦合的，不可直接积分得到姿态角，故一般采用旋转矩阵或则四元数计算角度。设矢量 r^b 为 b 系里面的一个向量，为了将其转化到 n 系中，则需要左边乘以旋转矩阵 C_b^n ，即， $r^n = C_b^n r^b$ ，用 $W_{nb}^b = [\omega_x \ \omega_y \ \omega_z]$ 表示 b 系相对于 n 系的角速度，并且其是在 b 系下的表示，则方向余弦矩阵随时间的变化如下，

$$\dot{C}_b^n = W_{nb}^b C_b^n \quad (2-6)$$

$$\text{其中 } W_{nb}^b = \begin{bmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ -\omega_y & \omega_x & 0 \end{bmatrix}, \text{ 该式主要用来跟踪载体相对于导航坐标系的旋}$$

转。

若采用四元数的方法来表征旋转矩阵进而求解姿态时，假设 t 时刻坐标系 $Oxyz$ 相对于 $Ox_i y_i z_i$ 转动为 Q_1 ，则有 $R_i(t) = Q_1 R(t) Q_1^{-1}$ ，那么在 $t + \Delta t$ 时刻，由于坐标系 $Oxyz$ 角速率 $\bar{\omega}$ 的存在，使得两个坐标系相对位置发生了变化，此时坐标系 $Oxyz$ 相对于 $Ox_i y_i z_i$ 转动为 Q_2 ，则 $R_i(t + \Delta t) = Q_2 R(t + \Delta t) Q_2^{-1}$ ，那么 t 到 $t + \Delta t$ 时间段内，运动的 $Oxyz$ 的位置变化为 $Q_1^{-1} Q_2$ 表示。动系的角位移为 $\Delta\theta = |\bar{\omega}| \Delta t$ ，其方向的单位量为 $\xi = \frac{\bar{\omega}}{|\bar{\omega}|}$ ，则有 $\xi = \frac{\bar{\omega}}{|\bar{\omega}|}$ ，进而得，

$$\begin{aligned}
Q_1^{-1}Q_2 &= \cos \frac{|\bar{\omega}| \Delta t}{2} + \xi \sin \frac{|\bar{\omega}| \Delta t}{2} \\
\dot{Q}(t) &= \lim_{\Delta t \rightarrow 0} \frac{Q_2 - Q_1}{\Delta t} = \lim_{\Delta t \rightarrow 0} \frac{Q_1}{\Delta t} \left(\cos \frac{|\bar{\omega}| \Delta t}{2} + \xi \sin \frac{|\bar{\omega}| \Delta t}{2} \right) \\
\dot{Q} &= \frac{1}{2} Q \xi |\bar{\omega}| = \frac{1}{2} Q \bar{\omega} = \frac{1}{2} Q \omega
\end{aligned} \tag{2-7}$$

假设在四维空间的单位一点对应绕三个旋转轴的角度，其四元坐标构成了单位四元数用四元数 $e = [e_0 \ e_1 \ e_2 \ e_3]^T$ ，表征的旋转矩阵为：

$$R = \begin{bmatrix} e_0^2 + e_1^2 - e_2^2 - e_3^2 & 2(e_1e_2 + e_0e_3) & 2(e_1e_3 - e_0e_2) \\ 2(e_1e_2 - e_0e_3) & e_0^2 - e_1^2 + e_2^2 - e_3^2 & 2(e_2e_3 + e_0e_1) \\ 2(e_1e_3 + e_0e_2) & 2(e_2e_3 - e_0e_1) & e_0^2 - e_1^2 - e_2^2 + e_3^2 \end{bmatrix} \tag{2-8}$$

式中 R 代表和余弦矩阵 C_b^n 相同的含义，且有 $e_0^2 + e_1^2 + e_2^2 + e_3^2 = 1$ ，四元数随时间的变化为：

$$\dot{e} = \frac{1}{2} e \cdot p_{nb}^b \tag{2-9}$$

式中， $p_{nb}^b = [0 \ (\omega_{nb}^b)^T]^T$ 。则四元数随时间的传递为：

$$\begin{aligned}
\dot{e}_0 &= \frac{1}{2} (e_1\omega_x + e_2\omega_y + e_3\omega_z) \\
\dot{e}_1 &= \frac{1}{2} (e_0\omega_x - e_3\omega_y + e_2\omega_z) \\
\dot{e}_2 &= \frac{1}{2} (e_3\omega_x + e_0\omega_y - e_1\omega_z) \\
\dot{e}_3 &= \frac{1}{2} (e_2\omega_x - e_1\omega_y - e_0\omega_z)
\end{aligned} \tag{2-10}$$

2.2.2 速度位移解算方法

为了对惯导速率 V_g 和位移 S_g 进行解算，首先需要将加速度传感器输出的值转换到世界参考坐标系下，然后减去重力加速度分量则得到惯导相对于世界坐标系的运动加速度。设加速度计输出值向量为 $a = [a_x \ a_y \ a_z]^T$ ，重力加速度分量为 $g = [0 \ 0 \ g]^T$ ， R 表征旋转矩阵，则：

$$\begin{cases} a_g = R^{-1}a - g \\ \dot{V}_g = a_g \\ \dot{S}_g = V_g \end{cases} \quad (2-11)$$

将其离散后得到:

$$\begin{cases} V_{g_k} = V_{g_{k-1}} + a_{g_{k-1}} T \\ S_{g_k} = S_{g_{k-1}} + V_{g_{k-1}} T + \frac{a_{g_{k-1}} T^2}{2} \end{cases} \quad (2-12)$$

2.3 相机投影模型

2.3.1 坐标系

相机投影模型建立的时候由于需要知道相机传感器本身的位置和姿态，故定义世界坐标系来表征相机传感器的位姿。所谓世界坐标系就是静止不动的绝对坐标系，一个物体在世界坐标系下的位置可以用坐标 (X_w, Y_w, Z_w) 来表示。因为数码相机采集到的图像信息其实是各个像素点的信息，为了将像素点的位置信息与世界坐标系联系起来，则需要三次坐标转换最终得到像素点在世界坐标系下的位置。

其中像素系和图像系均为二维坐标系，两者的两条轴分别对应平行，而像素坐标系为图像的左上角，图像系的原点为图像中心。而世界系和相机系为三维坐标系，相机系的 X 轴和 Y 轴与图像系的两个坐标轴分别重合，相机的光轴为 Z 轴。故像素点 (u, v) 由像素坐标系首先要转到图像系下 (x, y) ，然后再由图像系转化到相机系中 (X_c, Y_c, Z_c) ，最后由相机坐标系转化到世界坐标系中 (X_w, Y_w, Z_w) 。故相机模型的本质就是矩阵之间的转换关系。

2.3.2 投影模型

设 dx 、 dy 像是感光芯片上像素实际大小，则素坐标与像平面系之间的关系为，

$$\begin{bmatrix} x \\ y \\ 1 \end{bmatrix} = \begin{bmatrix} dx & 0 & -u_0 dx \\ 0 & dy & -v_0 dy \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} \quad (2-13)$$

设旋转矩阵为 R ，平移矩阵为 T ，则相机系和世界系之间的转换关系可以表示为，

$$\begin{bmatrix} X_c \\ Y_c \\ Z_c \\ 1 \end{bmatrix} = \begin{bmatrix} R & T \\ 0^T & 1 \end{bmatrix} \begin{bmatrix} X \\ Y \\ Z \\ 1 \end{bmatrix} = L_w \begin{bmatrix} X \\ Y \\ Z \\ 1 \end{bmatrix} \quad (2-14)$$

上式中, $L_w = \begin{bmatrix} R & T \\ 0^T & 1 \end{bmatrix}$ 成为相机外参数矩阵。

设 f 为成像平面距离相机中心的距离, 则相机系与像平面系之间的转换关系为,

$$\begin{cases} \frac{x}{f} = \frac{X_c}{Z_c} \\ \frac{y}{f} = \frac{Y_c}{Z_c} \end{cases} \Rightarrow \begin{cases} Z_c \cdot x = f \cdot X_c \\ Z_c \cdot y = f \cdot Y_c \end{cases} \quad (2-15)$$

$$Z_c \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} = \begin{bmatrix} f & 0 & 0 & 0 \\ 0 & f & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} X_c \\ Y_c \\ Z_c \\ 1 \end{bmatrix} \quad (2-16)$$

图像系和像素系之间关系为,

$$\begin{cases} u = \alpha \cdot f \cdot \frac{X}{Z} + c_x \\ v = \beta \cdot f \cdot \frac{Y}{Z} + c_y \end{cases} \Rightarrow \begin{cases} u = f_x \cdot \frac{X}{Z} + c_x \\ v = f_y \cdot \frac{Y}{Z} + c_y \end{cases} \quad (2-17)$$

$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} \quad (2-18)$$

其中 $K = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix}$ 为相机的内参数矩阵。故由式 (2-13) (2-14) (2-16) (2-18)

可得,

$$Z_c \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} \frac{1}{dx} & 0 & u_x \\ 0 & \frac{1}{dy} & v_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} f & 0 & 0 & 0 \\ 0 & f & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} R & T \\ 0^T & 1 \end{bmatrix} \begin{bmatrix} X \\ Y \\ Z \\ 1 \end{bmatrix} \quad (2-19)$$

上式描述了图像中的二维像点和真实三维世界的三维点存在的变换关系。

2.4 基于稀疏直接法的视觉里程计^[24]

视觉里程计算法中首先建立与位姿有关的误差函数，通过对误差函数的优化进行相机位姿状态的估计和建图。当这个误差函数最小时则此时的位姿估计是最优的，在位姿优化时，常用的方法分为直接法和特征点法，特征点法首先从图像中选取有代表性的特征点，然后最小化重投影误差最终进行运动估计，常用的特征有 SIFT^[33]、SURF^[34]、ORB^[35]。但是关键点的提取与描述子的计算非常耗时，使用特征点时，忽略了除特征点以外的所有信息，并且相机有时运动到特征缺失的地方，则此时可能就找不到足够的匹配点来计算相机运动。直接法中优化的是测量误差来优化相机位姿与运动，只要在场景中存在明暗变化，直接法就可以工作。

本节介绍一种直接法和特征点法结合使用的轻量级视觉里程计，跟踪一些关键点，然后采用直接法，根据这些关键点周围信息，估计相机运动及位置。相比于特征点法，此方法不需要对每张图像提取特征和描述子实现，故计算量较低。此算法主要包括四个部分：基于稀疏点亮度的位姿预估、基于图像块的特征点匹配、基于特征位置的位姿再优化和基于深度估计的地图构建。

2.4.1 基于稀疏点亮度的位姿预估

首先对算法中涉及的符号量进行如下定义： $I_k: \Omega \subset \mathbb{R}^2$ 表示 k 时刻图像， Ω 表示图像区域， $\mathbf{u} = (u, v)^T \in \Omega$ 表示像素点， $\mathbf{p} = (x, y, z)^T$ 表示空间点坐标， ${}_k \mathbf{p}$ 表示 k 帧对应的相机坐标系下坐标，相机投影模型函数为 Γ ，相机逆投影模型函数为 Γ^{-1} ， d_u 表示点的深度，则有，

$$\begin{aligned} \mathbf{u} &= \Gamma({}_k \mathbf{p}) \\ p_k &= \Gamma^{-1}(\mathbf{u}, d_u) \end{aligned} \quad (2-20)$$

相机 k 时刻的位姿可以用刚体转换 $\mathbf{T}_{k,w} \in SE(3)$ 表示，则世界坐标系中的三维点与相机坐标系中点的关系可表示为 $\mathbf{p}_k = \mathbf{T}_{k,w} \cdot {}_w \mathbf{p}$ ，则连续帧之间的位姿转化可以表示为，

$$\mathbf{T}_{k,k-1} = \mathbf{T}_{k,w} \cdot \mathbf{T}_{k-1,w}^{-1} \quad (2-21)$$

最后引入李代数的指数形式表征位姿转化矩阵，即为，

$$T(\xi) = \exp(\xi) \quad (2-22)$$

设相邻帧之间位姿为 $T_{k,k-1}$ ，已知 $k-1$ 帧图像 I_{k-1} 中某个特征在图像平面的位置为 (u,v) 以及深度为 d_u ，能够将该特征投影到 $k-1$ 时刻相机坐标系下三维空间得到 ${}_{k-1}p$ ，然后通过 $T_{k,k-1}$ 将 $k-1$ 时刻下三维点转换到当前帧相机坐标系下点 ${}_k p$ ，最后通过通过坐标系转换矩阵转化到图像 I_k 像素坐标系下 (u',v') ，即完成重投影。通过不断优化位姿使得重投影残差最小，最后得到最优位姿 $T_{k,k-1}$ ，其最小残差损失函数可表示为，

$$T_{k,k-1} = \arg \min_{T_{k,k-1}} \frac{1}{2} \sum_{i \in \mathfrak{R}} \|\delta I(T_{k,k-1}, u_i)\|^2 \quad (2-23)$$

$$\delta I(T, u) = I_k(\underbrace{\Gamma(T \cdot \underbrace{\Gamma^{-1}(u, du))}_{\substack{1 \\ 2}})}_{\substack{3}}) - I_{k-1}(u) \quad (2-24)$$

其中“1”表示将 $k-1$ 像素位置通过相机模型逆矩阵转化到相机坐标系中，“2”表示将前一帧相机坐标系下转化到当前帧相机坐标系下，“3”表示将前一帧的像素当在当前相机坐标下的坐标点通过相机投影模型转化到当前帧的像素坐标系中。

可采用高斯牛顿法求解式 (2-22)，位姿的迭代增量 ξ 可通过下述方程计算：

$$J^T J \xi = -J^T \delta I(0) \quad (2-25)$$

2.4.2 基于图像块的特征点匹配

通过式 (2-23) 可以得到位姿的粗略估计，但是存在较大的累计误差，故需要进一步和地图之间进行特征点对比，构造残差目标函数进行特征快预测位置的优化。因为特征快的亮度在任何帧中的亮度基本不变，因于此，通过建立特征快在当前帧的亮度与参考帧中该特征块的亮度残差，从而对特征块的位置进行优化，残差优化函数如式 (2-26) 所示。

$$u'_i = \arg \min_{u'_i} \frac{1}{2} \|I_k(u'_i) - A_i \cdot I_r(u_i)\|^2 \quad (2-26)$$

式中 I_r 表示根据三维点追溯到这个三维点在关键帧中的像素，而不是相邻帧中像素， A_i 表示仿射变换。

使用式(2-25)求解上式，其中雅可比矩阵为：

$$J = \begin{bmatrix} \frac{\partial r}{\partial u'} & \frac{\partial r}{\partial v'} \end{bmatrix} = \begin{bmatrix} \frac{\partial I(u', v')}{\partial u'} & \frac{\partial I(u', v')}{\partial v'} \end{bmatrix} \quad (2-27)$$

通过当前帧特征块与参考帧中特征块亮度残差优化方程，可以取得更加准确的特征块位置，进而将会将更优的特征块位置运用到相机位姿的优化中。

2.4.3 基于特征位置的位姿再优化

上述前两步的优化均是基于特征块亮度残差，优化相机位姿和特征块在像素坐标系下的位置，但是基于的假设是光度不变理论，但实际中并不可能始终会光度不变，因此前两步优化后得到的特征块在像素坐标系下的位置会存在差异，故根据优化后的特征块位置与之前预测的位置构造残差函数，并通过优化相机位姿使得位置残差最小。

$$T_{k,w} = \arg \min_{T_{k,w}} \frac{1}{2} \sum_{i \in \mathcal{R}} \|u_i - \Gamma(T_{k,w} p_i)\|^2 \quad (2-28)$$

上式雅可比矩阵变为 u ， v 对六个李代数变量的求导为，

$$J = \begin{bmatrix} \frac{1}{p_z} & 0 & \frac{-p_x}{p_z^2} & \frac{-p_x p_y}{p_z^2} & 1 + \frac{p_x^2}{p_z^2} & \frac{-p_y}{p_z} \\ 0 & \frac{1}{p_z} & \frac{-p_y}{p_z^2} & -1 - \frac{p_y^2}{p_z^2} & \frac{p_x p_y}{p_z^2} & \frac{p_x}{p_z} \end{bmatrix} \quad (2-29)$$

2.4.4 地图构建

1. 三角测量法

根据对极的几何定义，设 X_1 ， X_2 为两个特征点的归一化坐标，则满足：

$$s_1 X_1 = s_2 R X_2 + t \quad (2-30)$$

$$s_1 X_1 - s_2 R X_2 = t \quad (2-31)$$

对 (2-32) 左右分别左乘以 X_1^T ，得：

$$s_1 X_1^T X_1 - s_2 X_1^T R X_2 = X_1^T t \quad (2-33)$$

再对 (2-33) 左右分别左乘以 $(R X_2)^T$ ，得：

$$s_1 (R X_2)^T X_1 - s_2 (R X_2)^T R X_2 = (R X_2)^T t \quad (2-34)$$

由式 (2-33) (2-34) 联立，然后利用 Cramer's 法则可得：

$$\begin{bmatrix} X_1^T X_1 & -X_1^T R X_2 \\ (R X_2)^T X_1 & -(R X_2)^T R X_2 \end{bmatrix} \begin{bmatrix} s_1 \\ s_2 \end{bmatrix} = \begin{bmatrix} X_1^T t \\ (R X_2)^T t \end{bmatrix} \quad (2-35)$$

根据式 (2-35) 则可求出两个特征点深度 s_1 和 s_2 ，其中 R 和 t 分别为旋转矩阵和平

移矩阵。

2. 深度估计

建图过程就是根据给定一帧图像和它对应的姿态 $\{I_k, T_{k,w}\}$ ，在对应的三维点坐标未知情况下来估计二维特征的深度。一个特征点的深度估计根据一个概率分布建模。每一个观测帧 $\{I_k, T_{k,w}\}$ 被用于更新在贝叶斯框架下的分布概率，当分布此概率误差低于设定的阈值时，则将此深度估计用于三维点，然后这个三维点将会被加入到地图中去，从而用做位姿估计。

深度滤波器时基于关键帧 r 的，滤波器初始化的时候具有很大的不确定性，平均值被设定为参考帧场景的深度平均值。对于每一观测帧 $\{I_k, T_{k,w}\}$ ，根据 $T_{k,w}$ 找出参考帧 r 上深度未确定点 $\{p, u\}$ 的极线，然后在极线上搜索与该点最接近的点 u' ，然后通过三角测量法计算该点的深度 x 及其不确定性 π 。然后利用贝叶斯概率模型更新 p 点的深度，当其深度估计收敛时，则将其加入到地图中。 p 点的深度估计值 x 分布可以用高斯分布和均匀分布联合表示，即，

$$p(x|Z, \pi) = \pi N(x|Z, \tau^2) + (1-\pi)U(x|Z_{\min}, Z_{\max}) \quad (2-35)$$

采用最大后验概率求解 Z 和 π ，

$$\begin{aligned} \arg \max_{Z, \pi} p(Z, \pi | x_1, x_2, \dots, x_N) \\ p(Z, \pi | x_1, x_2, \dots, x_N) \propto p(Z, \pi) \prod_n p(x_n | Z, \pi) \end{aligned} \quad (2-36)$$

将上式近似为 Gaussian $\times$ Beta 分布，

$$p(Z, \pi | a_n, b_n, \mu_n, \sigma_n) \triangleq \text{Beta}(\pi | a_n, b_n) \cdot N(\mu_n, \sigma_n) \quad (2-37)$$

根据 Vogiatzis^[36]等人推导出了上式的迭代格式，

$$p(Z, \pi | a_n, b_n, \mu_n, \sigma_n) \approx p(x_n | Z, \pi) p(Z, \pi | a_n, b_n, \mu_n, \sigma_n) \quad (2-38)$$

则当有新的量测关键帧时， p 点的深度估计近似后验概率将根据上式不断更新，当 σ_n 小于一定阈值时，则认为 p 点深度估计完成，然后计算其三维位置并加入到地图中去。

2.5 本章小结

本章讲述了视觉和惯性组合导航的基础知识。首先介绍了惯导系统中几种常见的位姿描述方法并比较其优缺点，然后介绍了位姿计算的原理，最后介绍了相机投影模型，最终得到了像素点坐标与世界中坐标点的转换关系，为接下来的算

法提出准备了相关基础知识。然后介绍了一种半直接法视觉里程计，此算法把主要精力放在了位姿解算上而非建图上，因此计算量较低，适合用于板载计算能力有限的无人机。

第三章 针对重尾噪声的鲁棒姿态解算方法

为解决多旋翼无人机姿态解算由于量测重尾噪声存在导致传统算法性能下降问题,本章针对无人机姿态解算模型,将量测噪声协方差矩阵建模成逆威沙特(Inverse-Wishart IW)分布,提出一种针对重尾噪声的鲁棒多旋翼姿态解算方法(Robust Attitude Measurement algorithm, RAMA)。基于惯性元件和磁力计相关数据,针对噪声存在重尾噪声的场景进行仿真验证。结果表明,当重尾噪声存在时,本章提出的鲁棒姿态解算方法(RAMA)具有良好的鲁棒性,并且精度优于传统扩展卡尔曼滤波(Extended Kalman Filtering algorithm)EKF 姿态解算方法。

3.1 问题提出

姿态解算的作用是解算三个姿态角度,对于无人机自主飞行而言是至关重要的部分,因为姿态是无人机的根本状态,因此姿态解算研究具有极大意义。卡尔曼滤波算法^{[37][38]}在姿态解算中应用广泛,利用的高斯状态空间将量测噪声建模为高斯分布,在噪声参数已知且保持不变的情况下效果比较理想。

但是在实际应用中,将量测噪声近似为高斯分布具有一定的局限性,比如在无人机飞行过程中,系统本身会存在震动并且容易受到外界不定因素的影响干扰,导致量测噪声在滤波过程中是未知的,从而使得量测值中存在误差极大的野值,此时基于 EKF 的解算方法精度将会大幅度降低。“野值”是一种常见的非高斯现象^{[39][40][41]},具有重尾特性,因为在实际应用中的频繁出现使得研究变得十分有意义。“野值”被定义为分布于整体数据之外的观察值,与其他采样数据相差甚远。比如,外界突然的不确定干扰、传感器突然失效异常等等均会导致野值的产生。为了能够模拟“野值”的非高斯分布噪声,本文采用逆威沙特(Inverse-Wishart IW)分布^{[42][43]}来近似观测噪声协方差矩阵概率分布,此时量测噪声则近似服从 t 分布^{[44][45][46]},因为 t 分布的重尾特点可以更好地模拟野值噪声特性。通过仿真实验,与传统的扩展卡尔曼滤波方法对比,验证了本文提出的新型姿态解算方法 RAMA 在处理重尾噪声问题上的有效性。

3.2 针对重尾噪声的鲁棒姿态解算方法

3.2.1 测量噪声建模

在传统 EKF 算法中，系统模型和观测模型都是近似为高斯分布。为了建立一个鲁棒的状态空间模型，本文将测量噪声近似具有不确定协方差的高斯分布，如式(4-2)所示。其中 $\{R_t\}$ 表示对称正定矩阵集上的随机过程，其中 R_t 个体不要求是相互独立的，唯一的要求是其边缘分布存在并且具有有限矩。值得注意的是表征量测方程随机性水平的噪声协方差矩阵本身是个随机变量，这种不确定性保证了模型鲁棒的噪声特性。为了实现鲁棒的模型，首先需要定义对于每一个 t 时 R_t 的先验分布，逆威沙特(Inverse-Wishart IW)分布是均值已知的高斯协方差参数的一个先验分布。因为共轭保证了后验与先验具有相同的函数形式本文选择 IW 分布近似测量噪声协方差矩阵概率分布。

类似于威沙特分布，IW 也是 $d \times d$ 维对称正定矩阵凸锥上 $\mathbb{C}_+^{d \times d}$ 的分布，其表达式如式(4-4)所示，由式可知该分布由逆尺度矩阵 $\Lambda \succ 0$ 和自由度参数 $\nu > 0$ 所决定。当 $\nu > d+1$ 时，该分布的值等于 $(\nu-d-1)^{-1} \Lambda$ ，自由度描述了其分布的聚集程度。

$$x_t | x_{t-1} \sim N(f(x_t), Q) \quad (3-1)$$

$$z_t | x_t \sim N(h(x_t), R) \quad (3-2)$$

$$z_t | x_t, R_t \sim N(h(x_t), R_t) \quad (3-3)$$

$$R_t \sim w^{-1}(\Lambda, \nu) \quad (3-4)$$

为了推导方便，本文将 IW 分布的表达式做稍加改变为下式，

$$R_t \sim w^{-1}(\nu_t \Lambda_t, \nu_t) \quad (3-5)$$

则 R_t 的对数概率密度函数为：

$$\ln p(R_t) = -\frac{\nu_t + d + 1}{2} \ln |\Lambda_t| - \frac{\nu}{2} \text{Tr}(\Lambda_t R_t^{-1}) + \dots \quad (3-6)$$

其中： $|\cdot|$ 表示行列式， $\text{Tr}(\cdot)$ 表示矩阵的迹， $\dots$ 表示与 Λ_t 无关的项。上式具有如下性质：

$$E[R_t^{-1}] = \Lambda_t^{-1} \quad (3-7)$$

$$E[\ln|R_t^{-1}|] = \ln|\Lambda_t^{-1}| + \ln\phi(\nu)^2 \quad (3-8)$$

其中 $E[\cdot]$ 表示期望，然后定义，

$$\ln \varphi(v) = \frac{1}{2} \sum_{i=1}^d \psi\left(\frac{v+1-i}{2}\right) - \frac{d}{2} \ln \frac{v}{2} \quad (3-9)$$

其中 ψ 为伽马对数函数的第一阶导数，也被称数字函数。因此 R_t 的调和平均值（逆平均值的逆）就变为了简单的 Λ_t ，并且其行列式对数的期望和本身行列式的期望只相差了一个常数 $\ln \varphi(v)^2$ 。这个常数可以被看作是一个修正项，用来解释 R_t 的变化。当 $v > d+1$ 时， $\ln \varphi(v)^2 < 0$ ，当 $v \rightarrow \infty$ ， $\ln \varphi(v)^2 = 0$ 。

根据式（3-3）和式（3-6）可以产生关于 x_t 条件下的数据点 z_t 和其噪声协方差矩阵 R_t 上的联合分布，边缘化 R_t 并应用矩阵行列式引理可以得到，

$$p(z_t | x_t) \propto \left(1 + \frac{(z_t - H^T x_t)^T \Lambda_t^{-1} (z_t - H^T x_t)}{v_t} \right)^{-\frac{v_t+1}{2}} \quad (3-10)$$

“ $\propto$ ”表示“成正比”，上式说明了给定其状态量，观测量服从 t 分布。

$z_t | x_t$ 的分布是 t 分布的，而 t 是亚指数分布，即它以小于指数的速率衰减到零，这就意味着他的尾巴比高斯分布要厚的多。当 $v_t \rightarrow \infty$ 时，它的尾部变得平坦，进而减少小到高斯分布。对于有极限值的 v_t ，概率质量越来越均匀的分布在观测空间中并且远离模式，给“野值”分布了不可忽略的概率。因此，“野值”不需要被明确的做预处理或作特殊情况处理。相反因为模型现在能够解释他们，所以在贝叶斯滤波框架中自然会处理它们。 t 分布的一个吸引人的特征是它的内在函数，该函数量化了分布对数据中微小变化的敏感性，且与负对数密度函数有关。

当量测值明显偏移时，毫无疑问，它在信息方面的贡献是微不足道的。给定量测上的预测分布，如果实际数据点落在包含概率质量的 95% 区域之外，则将其丢弃。如果预测分布是椭圆形的比如高斯分布，那么该区域是椭球体，测试量测量是否位于它内最简单的方法是计算归一化的新息残差，然后将其与阈值对比，然后再计算。在鲁棒模型中， z_t 的边缘不再是高斯实际上是非椭圆的，但是这并不影响采对异常值的处理。通过 $p(z_t | x_t)$ 和公式（3-3）无法直接得到 z_t 的边缘，因为它没有闭环解，故使用 Jensen 不等式可得，

$$\ln(p(z_t | x_t)) \geq E[\ln p(z_t | x_t, R_t)] \quad (3-11)$$

对于不等式的右边项可根据公式（3-3）、公式（3-8）和公式（3-9）可以得到：

$$E[\ln(p(z_t | x_t))] = -\frac{d}{2} \ln(2\pi) - \frac{1}{2} \ln|\Lambda_t| + \ln \varphi(v_t) - \frac{e_t^2}{2} \quad (3-12)$$

其中 $\ln \varphi$ 函数在公式（3-9）中定义， e_t^2 是新息残差正则化后的平方，然后依据

Gabriel 等^{[47][48]}计算方法可推导出,

$$\begin{aligned} S_t &= (z_t - H^T \mu_t)(z_t - H^T \mu_t)^T + H^T \Sigma_t H \\ \Lambda_t &= \frac{hR + S_t}{h+1} \end{aligned} \quad (3-13)$$

上式中 Λ_t 是一个对称正定矩阵, $h > d-1$ 表示自由度, 表征先验噪声和统计的相对重要性, d 为量测向量维数。当量测 z_t 接近期望值 $H^T \mu_t$ 时, 噪声协方差矩阵就会接近 R , 但是当 z_t 与 $H^T \mu_t$ 相差较大时, 噪声协方差矩阵就会远大于 R , 此时观测值就会被当作量测野值处理。

3.2.2 多旋翼姿态解算模型建立

首先设多旋翼姿态测量系统模型为:

$$\begin{cases} x_{k+1} = f(x_k) + W_k \\ z_{k+1} = h(x_{k+1}) + V_{k+1} \end{cases} \quad (3-14)$$

其中, $x = [B\omega_l B \quad B\dot{\omega}_l B \quad Br_g \quad Br_m]^T$, 状态变量分别为三轴角速度、三轴角加

速度、加速度在机体坐标系三轴分量和磁力计在机体坐标系三轴分量。观测量分别由三轴陀螺仪, 加速度计, 磁力计测得。

$$x_{k+1} = \begin{bmatrix} \omega_k^b + \dot{\omega}_k^b \Delta t + W_{\omega,k} \\ \dot{\omega}_k^b + W_{\dot{\omega},k} \\ C_k^{k+1} \gamma_{a,k}^b + W_{\gamma_{a,k}} \\ C_k^{k+1} \gamma_{m,k}^b + W_{\gamma_{m,k}} \end{bmatrix} \quad (3-15)$$

$$z_k = \begin{bmatrix} \bar{\omega}_k^b + V_{\omega,k} \\ \bar{\gamma}_{a,k}^b + V_{a,k} \\ \bar{\gamma}_{m,k}^b + V_{m,k} \end{bmatrix} \quad (3-16)$$

其中 C_k^{k+1} 就是 k 时刻到 $k+1$ 时刻的旋转矩阵。对非线性方程式 (3-14) 中状态方程通过求雅可比矩阵进行线性化处理,

$$\begin{aligned}
\Phi_{k+1,k} &= \frac{\partial f(x_k)}{\partial x_k^T} \Big|_{x_k=\hat{x}_k} \\
&= \begin{bmatrix} \frac{\partial f_1(x_k)}{\partial \omega_k} & \frac{\partial f_1(x_k)}{\partial \dot{\omega}_k} & \frac{\partial f_1(x_k)}{\partial \gamma_{a,k}} & \frac{\partial f_1(x_k)}{\partial \gamma_{m,k}} \\ \frac{\partial f_2(x_k)}{\partial \omega_k} & \frac{\partial f_2(x_k)}{\partial \dot{\omega}_k} & \frac{\partial f_2(x_k)}{\partial \gamma_{a,k}} & \frac{\partial f_2(x_k)}{\partial \gamma_{m,k}} \\ \frac{\partial f_3(x_k)}{\partial \omega_k} & \frac{\partial f_3(x_k)}{\partial \dot{\omega}_k} & \frac{\partial f_3(x_k)}{\partial \gamma_{a,k}} & \frac{\partial f_3(x_k)}{\partial \gamma_{m,k}} \\ \frac{\partial f_4(x_k)}{\partial \omega_k} & \frac{\partial f_4(x_k)}{\partial \dot{\omega}_k} & \frac{\partial f_4(x_k)}{\partial \gamma_{a,k}} & \frac{\partial f_4(x_k)}{\partial \gamma_{m,k}} \end{bmatrix} \\
&= \begin{bmatrix} I & I\Delta t & 0 & 0 \\ 0 & I & 0 & 0 \\ \tilde{r}_{a,k}\Delta t & 0 & C_k^{k+1} & 0 \\ \tilde{r}_{m,k}\Delta t & 0 & 0 & C_k^{k+1} \end{bmatrix} \tag{3-17}
\end{aligned}$$

其中, $\tilde{r}_{a,k} = \begin{bmatrix} 0 & -a_z & a_y \\ a_z & 0 & -a_x \\ -a_y & a_x & 0 \end{bmatrix}$, $\tilde{r}_{m,k} = \begin{bmatrix} 0 & -m_z & m_y \\ m_z & 0 & -m_x \\ -m_y & m_x & 0 \end{bmatrix}$, 式 (3-14) 中量测方程为

线性方程, 其量测矩阵为:

$$H = \begin{bmatrix} I & 0 & 0 & 0 \\ 0 & 0 & I & 0 \\ 0 & 0 & 0 & I \end{bmatrix} \tag{3-18}$$

3.2.3 针对重尾噪声的鲁棒姿态解算算法

本章提出针对重尾噪声的鲁棒姿态解算方法过程主要包括预测和更新两个过程。预测过程中完成状态变量 x_k 和协方差 P_k 的预测, 更新过程完成量测噪声协方差矩阵 Λ_k 及状态变量 x_k 和协方差 P_k 的更新。算法输入量为初始状态 x_0 , 自由度 h , 输出量为 k 时刻状态向量 x_k , 状态协方差矩阵 P_k 。具体算法过程如下:

表 3-1 针对重尾噪声的鲁棒姿态解算方法流程表
Table 3-1 Robust attitude measurement algorithms for heavy-tailed noise

输入：初始状态 x_0 ，自由度 h

输出： k 时刻状态向量 x_k ，状态协方差矩阵 P_k

开始：

预测：

$$\begin{aligned} x_k^- &= \Phi_{k,k-1} x_{k-1} \\ P_k^- &= \Phi_{k,k-1} P_{k-1} \Phi_{k,k-1}^T + Q \end{aligned}$$

更新：

循环

$$\begin{aligned} S_k &= (z_k - H^T x_k^-)(z_k - H^T x_k^-)^T + H^T P_k^- H \\ \Lambda_k &= \frac{hR + S_k}{h+1} \\ K_k &= (H^T P_k^- H + \Lambda_k)^{-1} H^T P_k^{-T} \\ x_k &= x_k^- + K_k^T (z_k - H^T x_k^-) \\ P_k &= K_k \Lambda_k K_k^T + (I - HK_k)^T P_k (I - HK_k) \end{aligned}$$

结束

结束

3.3 实验与分析

为验证鲁棒姿态解算方法的有效性，本章设置噪声重尾噪声存在与否的两组对比实验，将鲁棒姿态解算方法(RAMA)测量结果和常规的扩展卡尔曼滤波(EKF)测量的结果进行对比。图 3-1 是采集的无人机真实姿态角随时间的变化曲线。




图 3-1 无人机真实姿态角度
Fig. 3-1 Real attitudes of UAV

3.3.1 不存在重尾的高斯噪声环境

本组实验设定测量噪声方差 $v_n \sim N(0, R_n)$ ，状态变量初始值取，其中 $R_n = \text{diag}([0.0008, 0.0008, 0.0008, 1000, 1000, 1000, 100, 100, 100])$ 姿态解算系统状态向量为 12 维，初值为， $x_0 = [0, 0, 0, 0, 0, 0, 0, -0.9998, 0, 0, 1]^T$ 状态协方差矩阵初值为，

$$P_0 = \begin{bmatrix} 0.004I & 0.056I & 0 & 0 \\ 0.056I & 0.2971I & M1 & M2 \\ 0 & -M1 & 2.9956I & 0 \\ 0 & -M2 & 0 & 0.7046I \end{bmatrix} \quad \text{其中, } M1 = \text{diag}([0, 0, 0.0001]),$$

$M2 = \text{diag}([0, 0.0001, -0.0001])$ ，过程噪声协方差取 $Q_n = \text{diag}([0.0001, 0.0001, 0.0001, 0.08, 0.08, 0.08, 0.009, 0.009, 0.009, 0.005, 0.005, 0.005])$ 自由度常数取 $h = 25$ 。图 3-2、图 3-3、图 3-4 中前三个图分别表示了高斯噪声下两种算法解算的三个姿态角误差对比，其中实线表示本文提出的鲁棒姿态解算方法(RAMA)，虚线表示传统 EKF 解算方法。




图 3-2 高斯噪声下俯仰角误差对比

Fig. 3-2 Comparison of pitch angle error under gauss noise




图 3-3 高斯噪声下横滚角误差对比图

Fig. 3-3 Comparison of roll angle error under gauss noise




图 3-4 高斯噪声下航向角误差对比

Fig. 3-4 Comparison of yaw angle error under gauss noise

3.3.2 量测噪声存在重尾环境

为了模拟带有重尾噪声的噪声，本实验将噪声设置为 $v = (1 - \beta)N(0, R_n) + \beta f$ ，式中：噪声野值的分布为 $f = N(0, 10R_n)$ ， $\beta = 0.2$ 表示野值出现的概率。图 3-3、图 3-4、图 3-5 分别表示了存在野值的非高斯噪声环境下两种算法解算得到的三个姿态角误差对比。




图 3-5 重尾噪声下俯仰角误差对比

Fig. 3-5 Comparison of pitch angle error under heavy-tailed noise




图 3-6 重尾噪声下横滚角误差对比

Fig. 3-6 Comparison of roll angle error under heavy-tailed noise




图 3-7 重尾噪声下航向角误差对比

Fig. 3-7 Comparison of yaw angle error under heavy-tailed noise

3.3.3 结果与分析

由图 3-2、图 3-3、图 3-4 可以看出, 当不存在野值的高斯噪声时, RAMA 算法能达到与 EKF 算法精度相似的滤波效果。由于量测异常值的出现, 如图 3-5、图 3-6、图 3-7 所示, EKF 方法测量效果下降的很厉害, 但是 RAMA 算法并没有受到异常值的影响, 仍然具备很高的测量精度。这是因为野值的存在使得量测噪

声出现重尾特性，但 EKF 算法仍然将噪声建模为高斯分布并将噪声方差设置为固定值，导致算法对于野值造成的噪声方差的波动没有适应能力，从而使得滤波精度降低；而 RAMA 算法通过将会测量噪声协方差矩阵建模为 IW 分布，使得量测噪声近似为 t 分布，能够更好的模拟重尾噪声，从而消除野值的影响，能够实现高精度解算。

3.4 本章小结

本章为解决量测重尾噪声存在导致多旋翼无人机姿态解算精度下降问题，提出一种将量测噪声协方差矩阵近似为 IW 分布(Inverse-Wishart)的鲁棒姿态解算方法。基于实测数据仿真结果表明：该方法在处理量测重尾噪声问题时具有优于传统 EKF 的解算精度，能够较精准的测量无人机的三个姿态角，因而具有一定的理论和实际应用价值。本章只讨论了量测噪声野值存在时的解算方法，过程噪声仍是被近似为高斯分布，但是现实中，过程噪声也有可能因为系统不稳定出现噪声野值情况，使得建模为非高斯分布变得也不合理。因而在今后的研究中将会针对过程噪声的野值情况提出另外一种新型的鲁棒解算方法。

第四章 针对重尾噪声的鲁棒视觉惯性组合导航算法

本章针对于量测噪声出现重尾的情况提出一种基于逆 Wishart(IW)分布的鲁棒组合导航方法。此方法主要包含两个过程, 首先根据 IMU 的数据进行预测, 然后实验视觉里程计输出的数据作为更新, 并且将 VO 数据噪声协方差矩阵建模为 IW 分布, 最后通过仿真验证算法的有效性。本章主要包括问题提出、组合导航非线性误差模型的建立、针对重尾噪声的组合导航算法介绍和仿真实验。

4.1 问题提出

Vaganay^[47]等人指出水下探测器由于多径传播引起的测量值出现“野值”情况, 导致测量结果不准确。Lekkas 等^[48]提出由于测量值尖峰的存在使得机器人的导航变得极为不准确, 为了处理这些尖峰“野值”, 他们采用基于卡尔曼滤波计算量测残差, 并设置阈值, 若残差高于设定的阈值, 则当前量测值被舍弃。Olson^[49]等人通过对量测值添加几何约束来解决水下机器人导航定位时出现量测“野值”的问题。He^[50]等人提出了针对北斗导航由于强干扰、高动态使得接收机出现异常从而导致测量值出现离群值的问题, 提出了一种基于卡尔曼滤波的离群值抑制算法, 该算法可以抑制连续的异常值。Salim^[51]等人在论文中指出由于城市建筑物对卫星导航信号的影响, 使得接收机的数据得到破坏, 进而导致了“野值”的产生, 文中提出了一种划分离群值的算法, 实验证明, 他们提出的算法不仅能够有效的剔除离群值并且可以很好的应对非高斯噪声的情况。本章充分考虑由于视觉里程计不稳定导致测量数据出现“野值”的情况, 针对这种重尾特性的噪声, 提出一种鲁棒的视觉惯性组合导航算法, 并通过实验验证其对重尾噪声处理的有效性。

4.2 组合导航模型建立

4.2.1 系统状态方程^[52]

状态包括 IMU 在世界坐标系 ω 下的位置 p_{ω}^i 、速度 v_{ω}^i 和姿态 q_{ω}^i , 陀螺仪零偏 b_{ω} 和加速度偏差 b_a 以及视觉里程计求得的位移与实际比例关系的尺度因子 λ , IMU 框架到相机坐标系旋转参数 q_i^c 以及相机中心在 IMU 框架的坐标 p_i^c , 表征视觉框架 v 与世界坐标系 ω 转换参数漂移的参数, 即从 v 系到 ω 系的旋转 q_v^{ω} 和平移 p_v^{ω} 。故总的状态量为 31 维:

$$X = \begin{bmatrix} p_{\omega}^{i^T} & v_{\omega}^{i^T} & q_{\omega}^{i^T} & b_{\omega}^T & b_a^T & \lambda & p_i^{c^T} & q_i^{c^T} & p_v^{\omega^T} & q_v^{\omega^T} \end{bmatrix}^T \quad (4-1)$$

其对应的状态微分方程为：

$$\begin{cases} \dot{p}_{\omega}^i = v_{\omega}^i \\ \dot{v}_{\omega}^i = C_{q_{\omega}^i}^T (a_m - b_a - n_a) - g \\ \dot{q}_{\omega}^i = \frac{1}{2} \Omega(\omega_m - b_{\omega} - n_{\omega}) \\ \dot{b}_{\omega} = n_{b_{\omega}} \quad \dot{b}_a = n_{b_a} \quad \dot{\lambda} = 0 \\ \dot{p}_i^c = 0 \quad \dot{q}_i^c = 0 \quad \dot{p}_v^{\omega} = 0 \quad \dot{q}_v^{\omega} = 0 \end{cases} \quad (4-2)$$

其中 $C_{q_{\omega}^i}^T$ 表示四元数对应的转化矩阵， Ω 表示四元数更新矩阵， g 表示世界坐标系下重力向量。考虑到状态估计过程噪声符合高斯分布，故对式 (4-2) 求期望可得：

$$\begin{cases} \hat{p}_{\omega}^i = \hat{v}_{\omega}^i \\ \hat{v}_{\omega}^i = C_{\hat{q}_{\omega}^i}^T (a_m - \hat{b}_a) - g \\ \dot{\hat{q}}_{\omega}^i = \frac{1}{2} \Omega(\omega_m - \hat{b}_{\omega}) \hat{q}_{\omega}^i \\ \hat{b}_{\omega} = n_{b_{\omega}} \quad \hat{b}_a = n_{b_a} \quad \hat{\lambda} = 0 \\ \hat{p}_i^c = 0 \quad \hat{q}_i^c = 0 \quad \hat{p}_v^{\omega} = 0 \quad \hat{q}_v^{\omega} = 0 \end{cases} \quad (4-3)$$

上述系统状态是使用四元数来描述姿态，为提高系统的数值稳定性并且用最少的状态来描述姿态，采用四元数误差的形式来表示姿态误差和对应的方差。因此，可以得到 28 元素的误差状态向量：

$$\tilde{x} = \begin{bmatrix} \Delta p_{\omega}^{i^T} & \Delta v_{\omega}^{i^T} & \delta \theta_{\omega}^{i^T} & \Delta b_{\omega}^T & \Delta b_a^T & \Delta \lambda & \Delta p_i^{c^T} & \delta \theta_i^{c^T} & \Delta p_v^{\omega^T} & \delta \theta_v^{\omega^T} \end{bmatrix}^T \quad (4-4)$$

其中四元数的误差变量满足：

$$\begin{cases} \delta q_{\omega}^i = q_{\omega}^i \otimes \hat{q}_{\omega}^{i^{-1}} \approx \begin{bmatrix} \frac{1}{2} \delta \theta_{\omega}^{i^T} & 1 \end{bmatrix}^T \\ \delta q_{\omega}^c = q_{\omega}^c \otimes \hat{q}_{\omega}^{c^{-1}} \approx \begin{bmatrix} \frac{1}{2} \delta \theta_i^{c^T} & 1 \end{bmatrix}^T \\ \delta q_{\omega}^v = q_v^{\omega} \otimes \hat{q}_v^{\omega^{-1}} \approx \begin{bmatrix} \frac{1}{2} \delta \theta_v^{\omega^T} & 1 \end{bmatrix}^T \end{cases} \quad (4-5)$$

则连续时间下误差状态微分方程为：

$$\begin{cases} \Delta \dot{p}_\omega^i = \Delta v_\omega^i \\ \Delta \dot{v}_\omega^i = C_{\dot{q}_\omega^i}^T \left[(a_m - \hat{b}_a)_\times \right] \delta \theta - C_{\dot{q}_\omega^i}^T \Delta b_a - C_{\dot{q}_\omega^i}^T n_a \\ \delta \dot{\theta}_\omega^i = - \left[(\omega_m - \hat{b}_\omega)_\times \right] \delta \theta - \Delta b_\omega - n_m \\ \Delta \dot{b}_\omega = n_{b_\omega} \quad \Delta \dot{b}_a = n_{b_a} \quad \Delta \dot{\lambda} = 0 \\ \Delta \dot{p}_i^c = 0 \quad \delta \dot{q}_i^c = 0 \quad \Delta \dot{p}_v^\omega = 0 \quad \delta \dot{q}_v^\omega = 0 \end{cases} \quad (4-6)$$

故可得连续时间下线性误差状态方程为：

$$\dot{\tilde{x}} = F_c \tilde{x} + G_c n \quad (4-7)$$

其中 $n = \begin{bmatrix} n_a^T & n_{b_a}^T & n_\omega^T & n_{b_\omega}^T \end{bmatrix}$ 为噪声向量。

将上述状态方程离散化得：

$$F_d = \exp(F_c \Delta t) = I_d + F_c \Delta t + \frac{1}{2!} F_c^2 \Delta t^2 \quad (4-8)$$

计算后可得，

$$F_d = \begin{bmatrix} I_{d_3} & \Delta t & A & B & -C_{\dot{q}_\omega^i}^T \frac{\Delta t^2}{2} & 0_{3 \times 13} \\ 0_3 & I_{d_3} & C & D & -C_{\dot{q}_\omega^i}^T \Delta t & 0_{3 \times 13} \\ 0_3 & 0_3 & E & F & 0_3 & 0_{3 \times 13} \\ 0_3 & 0_3 & 0_3 & I_{d_3} & 0_3 & 0_{3 \times 13} \\ 0_{3 \times 13} & 0_{3 \times 13} & 0_{3 \times 13} & 0_{3 \times 13} & 0_{3 \times 13} & I_{d_3} \end{bmatrix} \quad (4-9)$$

其中

$$\begin{cases} A = -C_{\dot{q}_\omega^i}^T \left[(a_m - \hat{b}_a)_\times \right] \left(\frac{\Delta t^2}{2} - \frac{\Delta t^3}{3!} \left[(\omega_m - \hat{b}_\omega)_\times \right] + \frac{\Delta t^4}{4!} \left[(\omega_m - \hat{b}_\omega)_\times \right]^2 \right) \\ B = -C_{\dot{q}_\omega^i}^T \left[(a_m - \hat{b}_a)_\times \right] \left(\frac{\Delta t^3}{3!} + \frac{\Delta t^4}{4!} \left[(\omega_m - \hat{b}_\omega)_\times \right] - \frac{\Delta t^5}{5!} \left[(\omega_m - \hat{b}_\omega)_\times \right]^2 \right) \\ C = -C_{\dot{q}_\omega^i}^T \left[(a_m - \hat{b}_a)_\times \right] \left(\Delta t - \frac{\Delta t^2}{2} \left[(\omega_m - \hat{b}_\omega)_\times \right] + \frac{\Delta t^3}{3!} \left[(\omega_m - \hat{b}_\omega)_\times \right]^2 \right) \\ D = -A \\ E = I_d - \Delta t \left[(\omega_m - \hat{b}_\omega)_\times \right] + \frac{\Delta t^2}{2} \left[(\omega_m - \hat{b}_\omega)_\times \right]^2 \\ F = -\Delta t + \frac{\Delta t^2}{2} \left[(\omega_m - \hat{b}_\omega)_\times \right] - \frac{\Delta t^3}{3!} \left[(\omega_m - \hat{b}_\omega)_\times \right]^2 \end{cases} \quad (4-10)$$

同时得

$$G_c = \begin{bmatrix} 0_3 & 0_3 & 0_3 & 0_3 \\ -C_{\hat{q}_\omega}^T & 0_3 & 0_3 & 0_3 \\ 0_3 & 0_3 & -I_{d_3} & 0_3 \\ 0_3 & 0_3 & 0_3 & I_{d_3} \\ 0_3 & I_{d_3} & 0_3 & 0_3 \\ 0_{13 \times 3} & 0_{13 \times 3} & 0_{13 \times 3} & 0_{13 \times 3} \end{bmatrix} \quad (4-11)$$

故可得误差状态协方差矩阵:

$$P_{k|k-1} = F_d P_{k-1|k-1} F_d^T + \int_{\Delta t} F_d(\tau) G_c Q_c Q_c^T F_d(\tau)^T d\tau \quad (4-12)$$

其中 $Q_c = \text{diag}(\sigma_{n_a}^2, \sigma_{n_{b_a}}^2, \sigma_{n_\omega}^2, \sigma_{n_{b_\omega}}^2)$ 为连续时间系统下的过程噪声协方差矩阵。

4.2.2 系统观测方程^[52]

利用本文 2.4 节稀疏直接法视觉里程计解算得到的相机在视觉坐标系下的位置 p_v^c 和旋转 q_v^c 作为系统观测量, 故可得观测模型为:

$$\begin{cases} z_p = p_v^c = C_{q_v^\omega}^T (p_\omega^i + C_{q_\omega^i}^T p_i^c) \lambda + n_p \\ z_q = q_v^c = q_i^c \otimes q_\omega^i \otimes q_v^\omega \end{cases} \quad (4-13)$$

上式中, 首先将相机在惯性系下的位置 p_i^c 通过惯性系到世界系旋转矩阵 $C_{q_\omega^i}$ 和平移 p_ω^i 转化到世界系中, 然再通过世界系到视觉系的旋转矩阵转化到视觉系中的位置, 最后乘以尺度因子 λ 并叠加噪声。故可得相应的误差方程为:

$$\begin{cases} \tilde{z}_p = z_p - \hat{z}_p \\ \quad = C_{q_v^\omega}^T (p_\omega^i + C_{q_\omega^i}^T p_i^c) \lambda + n_p - C_{\hat{q}_v^\omega}^T (\hat{p}_\omega^i + C_{\hat{q}_\omega^i}^T \hat{p}_i^c) \hat{\lambda} \\ \tilde{z}_q = z_q - \hat{z}_q \\ \quad = q_i^c \otimes q_\omega^i \otimes q_v^\omega \otimes (q_i^c \otimes \hat{q}_\omega^i \otimes \hat{q}_v^\omega)^{-1} \end{cases} \quad (4-14)$$

上式 (4-14) 线性化相应的线性量测方程为:

$$\begin{cases} \tilde{z}_p = H_p \tilde{x} \\ \tilde{z}_q = H_q^{\omega i} \delta q_\omega^i = H_q^{ic} \delta q_i^c = H_q^{v\omega} \delta q_v^\omega \end{cases} \quad (4-15)$$

式中

$$H_p = \begin{bmatrix} C_{\hat{q}_v}^T \hat{\lambda} \\ -C_{\hat{q}_v}^T C_{\hat{q}_\omega}^T [\hat{p}_{i \times}^c] \hat{\lambda} \\ 0_3 \\ 0_3 \\ C_{\hat{q}_v}^T C_{\hat{q}_\omega}^T \hat{p}_i^c + C_{\hat{q}_v}^T \hat{p} \\ C_{\hat{q}_v}^T C_{\hat{q}_\omega}^T \hat{\lambda} \\ 0_3 \\ -C_{\hat{q}_v}^T [(p_\omega^i + C_{\hat{q}_\omega}^T p_i^c) \lambda_\times] \end{bmatrix}^T \quad (4-16)$$

最终得观测方程为:

$$\begin{bmatrix} \tilde{z}_p \\ \tilde{z}_q \end{bmatrix} = H \tilde{x} \\ = \begin{bmatrix} 0_{3 \times 6} & \tilde{H}_q^{\omega i} & H_p & \tilde{H}_q^{ic} & \tilde{H}_q^{v\omega} \end{bmatrix} \tilde{x} \quad (4-17)$$

4.2.3 量测噪声建模

假设视觉里程计输出的位置 p 和姿态的噪声 q 的噪声向量为 $n_m = [n_p \quad n_q]^T$, 若 n_p, n_q 相互独立且为高斯白噪声时, 即, $n_p \sim N\{0 \quad \sigma_{n_p}^2\}$ $n_q \sim N\{0 \quad \sigma_{n_q}^2\}$, 可得此时的量测噪声协方差为:

$$R_c = \text{diag}(\sigma_{n_p}^2, \sigma_{n_q}^2) \quad (4-18)$$

为处理视觉里程计计算的数据出现野值问题, 将量测噪声协方差建模为逆威沙特分布(Inverse-Wishart IW)能够更好的模拟重尾噪声。

$$R_{c_t} \sim w^{-1}(v_t \Lambda_{c_t}, v_t) \quad (4-19)$$

参考第三章推导方法可得:

$$S_{c_t} = \tilde{z}_t \cdot \tilde{z}_t^T + H^T P_t H \\ \Lambda_{c_t} = \frac{h R_c + S_{c_t}}{h+1} \quad (4-20)$$

上式中 Λ_{c_t} 是一个对称正定矩阵, $h > d-1$ 表示自由度, 表征先验噪声和统计的相对重要性, d 为量测向量维数。

4.3 针对重尾噪声的视觉惯性组合导航算法

组合导航算法过程主要包括预测过程和更新过程，预测过程实现状态基于 IMU 数据根据上述误差状态模型进行预测，更新过程是利用视觉里程计输出的位姿信息矫正预测后的状态，具体过程如下：

1. 预测过程

将 $k-1$ 时刻状态 $x_{k-1|k-1}$ 通过系统状态矩阵得到 k 时刻的预测状态 $x_{k|k-1}$ ，此时用到的是 IMU 更新的线加速度和角加速度数据，

$$x_{k|k-1} = F_d x_{k-1|k-1} \quad (4-21)$$

然后进行误差状态协方差预测，

$$P_{k|k-1} = F_d P_{k-1|k-1} F_d^T + \int_{\Delta t} F_d(\tau) G_c Q_c Q_c^T F_d(\tau)^T d\tau \quad (4-22)$$

2. 更新过程

利用视觉里程计更新的数据得到新息残差 $\tilde{z}_k$ ，进而得到 k 时刻更新后的重尾情况下量测噪声协方差矩阵 Λ_{c_k} ，

$$\begin{aligned} S_{c_k} &= \tilde{z}_k \cdot \tilde{z}_k^T + H^T P_{k|k-1} H \\ \Lambda_{c_k} &= \frac{h R_c + S_{c_k}}{h+1} \end{aligned} \quad (4-23)$$

利用更新后的 k 时刻量测噪声协方差矩阵 Λ_{c_k} 和和预测的状态协方差矩阵 $P_{k|k-1}$ 及量测矩阵 H 可得增益，

$$K_k = (H^T P_{k|k-1} H + \Lambda_{c_k})^{-1} H^T P_{k|k-1}^T \quad (4-24)$$

最后根据更新后的增益 K_k^T 和预测的系统状态 $x_{k|k-1}$ 计算更新矫正后的系统状态，

$$x_{k|k} = x_{k|k-1} + K_k^T \tilde{z} \quad (4-25)$$

更新误差状态协方差矩阵

$$P_{k|k} = K_k \Lambda_{c_k} K_k^T + (I - H K_k)^T P_{k|k-1} (I - H K_k) \quad (4-26)$$

表 4-1 针对重尾噪声的鲁棒视觉惯性组合导航算法流程
Table 4-1 Robust vision inertial fusion navigation algorithms

输入：初始状态 x_0 ，自由度 h ，视觉里程计输出的位姿

输出： k 时刻状态向量 x_k ，状态协方差矩阵 P_k

开始：

预测：

$$x_{k|k-1} = F_d x_{k-1|k-1}$$

$$P_{k|k-1} = F_d P_{k-1|k-1} F_d^T + \int_{\Delta t} F_d(\tau) G_c Q_c Q_c^T F_d(\tau)^T d\tau$$

更新:

循环

$$S_{c_k} = \tilde{z}_k \cdot \tilde{z}_k^T + H^T P_{k|k-1} H$$

$$\Lambda_{c_k} = \frac{h R_c + S_{c_k}}{h + 1}$$

$$K_k = (H^T P_{k|k-1} H + \Lambda_{c_k})^{-1} H^T P_{k|k-1}^T$$

$$x_{k|k} = x_{k|k-1} + K_k^T \tilde{z}$$

$$P_{k|k} = K_k \Lambda_{c_k} K_k^T + (I - H K_k)^T P_{k|k-1} (I - H K_k)$$

结束

结束

算法预测时是利用 IMU 输出的线加速度和角加速度，更新利用的数据是视觉里程计输出的位姿信息，故可得算法流程图如下，




图 4-1 融合算法流程图

Fig. 4-1 Diagram of fusion algorithm

4.4 实验与分析

本文基于 ubuntu 环境下的 ROS 操作系统 (Robot Operation System)，采用苏黎世大学开源数据集^[53]进行两组实验。第一组实验测试高斯噪声下融合算法，并对比融合后结果与单视觉里程计和测试集参考值；第二组实验为测试非高斯噪声下融合算法对处理量测重尾噪声的效果，并与基于 EKF 的融合算法做对比。

首先设置实验中各参数初始值，加速度噪声为 0.1，加速度噪声偏差为 0.01，

角速度噪声为 0.002, 角速度噪声偏差为 0.0002, IMU 框架到相机系转化参数 q_i^c 以及相机中心在 IMU 框架的坐标 p_i^c 和从 v 系到 ω 系的旋转 q_v^ω 以及平移 p_v^ω 的噪声均设置为 0, 量测噪声 $n_{p_c^\omega}$ 和 $n_{q_c^\omega}$ 分别设置为 0.05 和 0.025, 尺度因子 λ 设置为 1, 自由度常数取 $h=30$ 。

图 4-2 和图 4-3 量测噪声为高斯噪声下本章所提出的鲁棒融合算法(FUSION)与单视觉里程计 (VO) 及数据集参考值 (GT) 之间位置和姿态的对比, 从图中可以看出和 IMU 融合后的结果比单视觉里程计具有好的效果, 原因是单独的视觉里程计输出具有空间的漂移, 而单独惯性导航数据会存在时间的漂移, 但是两者存在互补性, 故而两者融合的效果会优于单一的视觉里程计。图 4-4 为融合算法计算的相对于世界坐标系的运动速度, 图 4-5 显示了加速度偏差和角加速度偏差随时间的漂移情况。

第二组实验为了模拟带有野值的重尾噪声, 采用与 3.3.2 节类似方法, 实验中将噪声设置为 $v = (1 - \beta)N(0, R_c) + \beta f$, 式中: 噪声野值的分布为 $f = N(0, 20R_c)$, $\beta=0.3$ 表示野值出现的概率, R_c 为与第一组实验中相同的量测噪声协方差矩阵。图 4-7 和图 4-8 为量测噪声为重尾噪声下本章所提出的鲁棒融合算法 (FUSION) 与扩展卡尔曼滤波 (EKF) 及数据集参考值 (GT) 之间位置和姿态的对比, 实验结果显示当量测出现噪声野值时, FUSION 算法融合精度高于 EKF 融合, 故具备更好的鲁棒性。

本文提出的融合算法对重尾噪声处理性能之所以好于基于 EKF 框架的融合算法原因是本文算法在量测噪声建模时考虑到了量测野值噪声出现的情况, 并且将量测噪声协方差矩阵建模为逆 Wishart 分布, 这样才能模拟噪声重尾特性, 故而协方差矩阵是随机的。但是基于 EKF 框架的组合导航算法在整个过程中始终把量测噪声协方差矩阵当作是定值, 故在处理野值时无法达到相对高的精度, 使得其性能下降。




图 4-2 融合算法与 VO 及数据集参考值位置对比

Fig. 4-2 Position Comparison of Fusion Algorithms with VO and Reference Value




图 4-3 融合算法与 VO 及数据集参考值姿态对比

Fig. 4-3 Attitude Comparison of Fusion Algorithms with VO and Reference Value




图 4-4 融合算法计算的相对于世界坐标系速度

Fig. 4-4 Velocity Computed by Fusion Algorithms in Relative to World Coordinate System




图 4-5 融合算法计算的角速度及加速度偏差

Fig. 4-5 Angular Velocity and Acceleration Deviation Calculated by Fusion Algorithms




图 4-6 IMU 线加速度变化
Fig. 4-6 Linear Acceleration variation of IMU




图 4-7 IMU 角加速度变化
Fig. 4-7 Angular Acceleration variation of IMU




图 4-8 重尾噪声下 FUSION 与扩展卡尔曼滤波 EKF 位置对比
Fig. 4-8 Comparison of FUSION and EKF positions under outlier noise




图 4-9 重尾噪声下 FUSION 与扩展卡尔曼滤波 EKF 姿态对比
Fig. 4-9 Comparison of FUSION and EKF attitudes under outlier noise

4.5 本章小结

本章提出了一种 VO 和 IMU 融合算法，其中 IMU 输出的角加速度和加速度用于状态的预测，VO 输出的位姿和姿态数据作为状态更新使用，通过分别设置

量测噪声为高斯分布和出现重尾噪声的两组实验对比，结果显示了本章提出的算法很高的修正了单视觉里程计的估计累计误差，对于长时间的运动提高了更加高的位置和姿态的估计，设置的第二组实验结果显示了与基于 EKF 框架融合方法相比此算法对处理量测重尾噪声时具有更高精度。

第五章 总结与展望

5.1 主要工作与创新点

本文主要工作是对无人机姿态解算和视觉惯性融合导航定位进行研究，并提出针对重尾噪声的鲁棒多旋翼姿态解算方法和针对重尾噪声的鲁棒视觉惯性组合导航算法，主要工作内容和创新点如下：

1. 介绍了研究背景和意义，无人机在室内飞行时由于受到墙的阻挡，基于 GPS 的室外导航方法则无法使用，而基于室内标签的定位需要外界设备辅助，故不具备通用性，且外部设备价格十分昂贵，如 UWB (Ultra Wideband)，而仅基于惯性传感器的导航方法对传感器精度要求较高，并且具有随时间漂移的致命缺点，而基于视觉里程计方法会存在空间尺度的偏移，故本文对视觉里程计和惯导融合方法研究是较优的方向。然后文章分别介绍了惯性导航和视觉里程计的发展和现状并且介绍了视觉惯性组合导航的几种融合方法，分别是基于松耦合和紧耦合滤波的融合方法及基于优化的融合方法，考虑本文研究对象是无人机室内导航，由于无人机带载计算能力的局限性，故选择计算量较低的基于松耦合滤波的融合方法，即不把图像信息加入到滤波状态向量中，故计算量大大减少。
2. 介绍了本文所用到的视觉惯性导航中需要的预备知识，如坐标系的选取、惯性位姿解算方法及相机模型等。然后介绍了一种计算量相对较低的基于稀疏直接法的视觉里程计算法。
3. 本文第一个创新点是提出了一种针对重尾噪声的鲁棒姿态解算方法。基于 EKF 的多旋翼姿态测算方法应用比较广泛，由于传感器可能会突然失效，比如外界因素的影响使得传感器的输出出现异常等，使得传感器输出出现野值，在这种重尾特性噪声情况下，基于 EKF 的姿态解算方法则会出现很大误差。通过实测数据并与传统 EKF 姿态解算方对比，试验结果表明，本文提出的针对重尾噪声的鲁棒姿态解算方法对于上述异常环境的处理比传统 EKF 精度要高。
4. 本文第二个创新点是提出一种针对重尾噪声的基于松耦合的 VO 和 IMU 融合框架。因为单个视觉传感器或者惯性传感器导航都会出现空间或时间的漂移问题，并且由于外界恶劣环境或者传感器突然失效会使得传感器数据出现具有重尾噪声的“野值”情况。基于此本文提出上述组合导航算法，并基于开源数据集设置了两组对比试验分别说明了融合算法的有效性和处理重尾噪声的鲁棒

性。

5.2 后续研究工作

本文先后提出了针对重尾噪声的鲁棒多旋翼无人机姿态解算方法和针对重尾噪声的鲁棒视觉惯性融合方法，并通过实验验证了算法的鲁棒性，但是仍有很多需要改进的方面，比如，

1. 在处理野值时，是将量测噪声协方差矩阵建模为逆威沙特分布，若将其建模为其他分布是否会有更好的解算效果值得探究。本文仅仅考虑到了量测噪声出现野值的状况，而对于系统过程噪声有可能出现野值得情况值得深思。
2. 在视觉惯性融合算法中并未具体讨论里程计与惯性传感器输出频率的一致性，而传感器数据更新是否同步将很大程度上影响融合精度。并且本文采用的是松耦合融合方式，故图像信息并未加入到状态向量中，导致很多有用的图像特征点信息丢失，以后会向紧耦合方向研究。
3. 随着机器学习的火热发展，基于深度学习的视觉里程计方法成为新颖的研究方向，这将是一个有趣的领域。
4. 本文实验采用的是实测数据和开源数据集，下一步准备移植到硬件中进行实际飞行试验。

参 考 文 献

- [1] 张炎华, 王立端, 战兴群, et al. 惯性导航技术的新进展及发展趋势[J]. 中国造船, 2008(S1).
- [2] 郭秀中. 惯导系统陀螺仪理论[M]. 国防工业出版社, 1996.
- [3] Ristic L, Shah M. Trends in MEMS technology[C]. Wescon. IEEE, 1996:64-72.
- [4] Melnichenko M M, Osadchy S I. Trends of MEMS technology in UAV development[C]. Actual Problems of Unmanned Aerial Vehicles Developments. IEEE, 2015:66-68.
- [5] 杨晓东, 邓太光. 平台式惯导系统两点校的常值误差分析[J]. 交通运输工程学报, 2011(3):100-104.
- [6] 黄卫权. 舰船用平台式惯导系统测控技术研究[D]. 哈尔滨工程大学, 2006.
- [7] 孙丽, 秦永元. 捷联惯导系统姿态算法比较[J]. 中国惯性技术学报, 2006, 14(3):6-10.
- [8] 孙枫, 孙伟, 郭真. 基于 IMU 旋转的捷联惯导系统自补偿方法[J]. 仪器仪表学报, 2009, 30(12):2511-2517.
- [9] Moravec H P . Obstacle avoidance and navigation in the real world by a seeing robot rover[M]. Stanford University, 1980.
- [10] Matthies L, Shafer S A. Error modeling in stereo navigation[M]. Autonomous Robot Vehicles. Springer New York, 1990:239-248.
- [11] Olson C F , Matthies L H , Schoppers M , et al. Robust Stereo Ego-motion for Long Distance Navigation[C]. IEEE Conference on Computer Vision & Pattern Recognition. IEEE, 2000.
- [12] Lacroix S , Mallet A , Chatila R , et al. Rover Self Localization in Planetary-Like Environments[J]. Artificial Intelligence, 2013, 440:433.
- [13] Milella A , Siegwart R . Stereo-Based Ego-Motion Estimation Using Pixel Tracking and Iterative Closest Point[C]. IEEE International Conference on Computer Vision Systems. IEEE Computer Society, 2006.
- [14] Howard A . Real-Time Stereo Visual Odometry for Autonomous Ground Vehicles[C]. IEEE/RSJ International Conference on Intelligent Robots & Systems. IEEE, 2008.
- [15] Cheng Y , Maimone M , Matthies L . Visual odometry on the Mars Exploration

- Rovers[C]. IEEE International Conference on Systems. IEEE, 2006.
- [16]Maimone M , Cheng Y , Matthies L . Two years of Visual Odometry on the Mars Exploration Rovers[J]. Journal of Field Robotics, 2007, 24(3):169-186.
- [17]Besl P J , Mckay N D . A Method for Registration of 3-D Shapes[M]. IEEE Computer Society, 1992.
- [18]Michael Blösch, Weiss S , Scaramuzza D , et al. Vision based MAV navigation in unknown and unstructured environments[C]. IEEE International Conference on Robotics & Automation. IEEE, 2010.
- [19]Monocular Vision for Long-term Micro Aerial Vehicle State Estimation: A Compendium[J]. Journal of Field Robotics, 2013, 30(5):803-831.
- [20]Comport A , Malis E , Rives P . Real-time Quadrifocal Visual Odometry[J]. International Journal of Robotics Research, 2012, 29(29):245-266.
- [21]Tykkala T , Audras C , Comport A I . Direct Iterative Closest Point for Real-time Visual Odometry[C]. IEEE International Conference on Computer Vision Workshops. IEEE, 2016.
- [22]Kerl C , Sturm J , Cremers D . Robust Odometry Estimation for RGB-D Cameras[C]. IEEE International Conference on Robotics & Automation. IEEE, 2013.
- [23]Engel J, Koltun V, Cremers D. Direct Sparse Odometry.[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, PP(99):1-1.
- [24]Forster C , Pizzoli M , Scaramuzza D . SVO: Fast Semi-Direct Monocular Visual Odometry[C]. IEEE International Conference on Robotics & Automation. IEEE, 2014.
- [25]Mourikis A, Roumeliotis S. A Multi-State Constraint Kalman Filter for Vision-aided Inertial Navigation[C]. IEEE International Conference on Robotics & Automation. IEEE, 2007.
- [26]Bloesch M , Omari S , Hutter M , et al. [IEEE 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) - Hamburg, Germany (2015.9.28-2015.10.2)] 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) - Robust visual inertial odometry using a direct EKF-based approach[J]. 2015:298-304.
- [27]Leutenegger S , Lynen S , Bosse M , et al. Keyframe-based visual - inertial odometry using nonlinear optimization[J]. International Journal of Robotics Research, 2014, 34(3):314-334.
- [28]Mur-Artal R , Tardos J D . Visual-Inertial Monocular SLAM with Map Reuse[J]. IEEE Robotics & Automation Letters, 2016, 2(2):796-803.

- [29]Qin T , Li P , Shen S . VINS-Mono: A Robust and Versatile Monocular Visual-Inertial State Estimator[J]. IEEE Transactions on Robotics, 2017, PP(99):1-17.
- [30]Lynen S , Achteik M W , Weiss S , et al. A robust and modular multi-sensor fusion approach applied to MAV navigation[C]. IEEE/RSJ International Conference on Intelligent Robots & Systems. IEEE, 2013.
- [31]Falquez J M , Kasper M , Sibley G . Inertial aided dense & semi-dense methods for robust direct visual odometry[C]. IEEE/RSJ International Conference on Intelligent Robots & Systems. IEEE, 2016.
- [32]赵琳, 王小旭, 丁继成,等. 组合导航系统非线性滤波算法综述[J]. 中国惯性技术学报, 2009, 17(1):46-52.
- [33]Lowe D G . Distinctive Image Features from Scale-Invariant Keypoints[J]. 2004.
- [34]Bay H, Tuytelaars T, Gool L V. SURF: Speeded Up Robust Features[C] European Conference on Computer Vision. 2006.
- [35]Rublee E, Rabaud V, Konolige K, et al. ORB: An efficient alternative to SIFT or SURF[C] International Conference on Computer Vision. 2012.
- [36]Vogiatzis G, Hernández C. Editor's Choice Article: Video-based, real-time multi-view stereo[J]. Image & Vision Computing, 2011, 29(7):434-441.
- [37]Hajiyev C, Soken H E. Robust Adaptive Kalman Filter for estimation of UAV dynamics in the presence of sensor/actuator faults[J]. Dialogues in Cardiovascular Medicine Dcm, 2013, 28(1):376 – 383.
- [38]Zhang X, Cao Y. Kalman Filtering of Attitude Measurement with Magnetometer and Gyroscope[J]. Journal of Detection & Control, 2011, 33(4):48 – 43.
- [39]Pearson R K. Outliers in process modeling and identification[J]. Control Systems Technology IEEE Transactions on, 2002, 10(1):55 – 63.
- [40]Grubbs F. Procedures for Detecting Outlying Observations in Samples[J]. Technometrics, 1969, 11(1):1 – 21.
- [41]Ting J A, D'Souza A, Schaal S. Automatic Outlier Detection: A Bayesian Approach[C]. IEEE International Conference on Robotics and Automation. IEEE, 2007:2489 – 2494.
- [42]Dawid A P. Some Matrix-Variate Distribution Theory: Notational Considerations and a Bayesian Application[J]. Biometrika, 1981, 68(1):265 – 274.
- [43]He, Zhongshi, Leung, et al. A variational Bayesian approach to robust sensor fusion based on Student-t distribution[J]. Information Sciences, 2013, 221(1):201 – 214.
- [44]Kotz, Samuel, Nadarajah, Saralees. Multivariate T-Distributions and Their

- Applications[J]. Cambridge Books, 2004, 101(101):xii,272.
- [45]Agamennoni G, Nieto J I, Nebot E M. Approximate Inference in State-Space Models With Heavy-Tailed Noise[J]. IEEE Transactions on Signal Processing, 2012, 60(10):5024 – 5037.
- [46]Agamennoni G, Nieto J I, Nebot E M. An outlier-robust Kalman filter[C]. IEEE International Conference on Robotics and Automation. IEEE, 2011:1551 – 1558.
- [47]Vaganay J , Leonard J J , Bellingham J G . Outlier rejection for autonomous acoustic navigation[C] IEEE International Conference on Robotics & Automation. IEEE, 1996.
- [48]Lekkas A M , Candeloro M , SchjLberg I . Outlier Rejection in Underwater Acoustic Position Measurements Based on Prediction Errors[J]. IFAC-PapersOnLine, 2015, 48(2):82-87.
- [49]Olson E , Leonard J J , Teller S . Robust range-only beacon localization[C] Autonomous Underwater Vehicles, IEEE/OES. IEEE, 2004.
- [50]He W , Lian B , Yang Q . An outlier suppression algorithm for Beidou satellite navigation timing using robust Kalman filter[J]. Journal of Northwestern Polytechnical University, 2014, 32(3):378-381.
- [51]Salim Z , Le Hégarat-Masclé Sylvie, Emmanuel S . Outlier Detection in GNSS Pseudo-Range/Doppler Measurements for Robust Localization[J]. Sensors, 2016, 16(4):580-.
- [52]Lynen S , Achtelik M W , Weiss S , et al. A robust and modular multi-sensor fusion approach applied to MAV navigation[C] IEEE/RSJ International Conference on Intelligent Robots & Systems. IEEE, 2013.
- [53]<http://projects.asl.ethz.ch/datasets/doku.php?id=k mavvisualinertialdatasets>

致 谢

随着毕业论文的完成，我的硕士生涯就此告一段落，回首硕士两年多时间里，我不仅学到了更深入的专业知识，通过参与课题组科研项目，动手能力得到了锻炼，深切体会到了如何将书本上所学到的算法应用到实际项目中，更重要的是我学到了如何去学习、如何去实践，深刻明白了“实践是检验真理的唯一标准”这句话的深刻含义。不光要一味的啃书本、看论文，更有意义的是要亲自动手做实验来验证方法的有效性，即使期间会遇到意想不到的问题，但是最终得到实验结果后将会感到无比的激动。

首先，我衷心感谢我的导师敬忠良教授，您为人谦和、教学严谨，不仅在学习方面给了我很多指导，并且对我的生活和即将要进入工作方面您都给了我宝贵的建议。您经常说的一句话我记忆犹新“要把所学的算法应用到实际的工程项目中去”，感谢您对我学习和生活的关怀！

其次，我想感谢董鹏老师，感谢您对我在学习方面的指导，每次我遇到问题时，您总是能给我指点迷津。感谢您每次给我细心讲解问题，您严谨的科研态度永远值得我学习。

然后我想感谢实验室的潘汉老师、李旻哲师兄、乔凌峰师兄、张抒扬等，谢谢你们对我在学习上的帮助，在参与实验室课题中，我深刻感受到了你们的努力专研、踏实务实的精神，和你们一块参与项目是我宝贵的经验。

我的室友张天佳、朱壬泰、熊靖丰，谢谢你们对我生活和学习上的帮助，还记得我们四个一块参与的“钱学森”杯竞赛吗？我们一块在实验室调程序、讨论的场景一直印刻在我的脑海里，谢谢你们。

最后，我想感谢我的家人，我的父母，谢谢你们给我的支持，每次遇到烦心事时，您们总会很好的开导我、鼓励我。没有您们的支持和默默付出，我也不可能完成学业，谢谢你们！爸妈辛苦了！

最后再次忠心感谢帮助过我的家人、老师、同学和朋友！

攻读硕士学位期间已发表或录用的论文

- [1] 李忠威，敬忠良，董鹏. 一种鲁棒的多旋翼姿态解算方法. 计算机仿真杂志（终审中）.

上海交通大学

学位论文原创性声明

本人郑重声明：所呈交的学位论文《基于视觉惯性里程计的无人机室内定位研究》，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已经注明引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品成果。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律结果由本人承担。

学位论文作者签名：李忠威

日期：2019年1月14日