

低成本无人器组合导航滤波算法机制研究

阳 显 杨远超

(西安工程大学电子信息学院 西安 710048)

摘 要: 针对低成本无人器在复杂运动环境下的导航精度问题,提出了一种基于多模态运动特性分解的组合导航滤波算法选择机制。该方法结合卡尔曼滤波与容积卡尔曼滤波,依据无人器运动环境的动态特性选择最优滤波策略;在低动态环境下,采用卡尔曼滤波提升计算效率;在中等动态环境下,使用容积卡尔曼滤波以增强非线性状态估计能力;实验基于纯捷联惯性导航系统工具箱,仿真无人机与无人车运动轨迹,验证了所提方法的有效性。结果表明,相较于传统滤波方法,该算法在无人机场景下位置估计误差降低 25%,在无人车场景下计算效率提升 50%。

关键词: 低成本无人器;滤波器选择;卡尔曼滤波;容积卡尔曼滤波;粒子滤波

中图分类号: TN902.1 **文献标识码:** A **国家标准学科分类代码:** 510.50

Research on the mechanism of filtering algorithms for integrated navigation of low cost unmanned vehicles

Yang Xian Yang Yuanchao

(School of Electronic Information, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: To address the navigation accuracy challenges of low-cost unmanned vehicles in complex motion environments, this paper proposes an integrated navigation filtering algorithm based on multi-modal motion characteristic decomposition. The method combines Kalman Filter and Cubature Kalman Filter dynamically selecting the optimal filtering strategy according to the motion characteristics of the vehicle. In low-dynamic environments, the Kalman Filter is used to improve computational efficiency, while in medium-dynamic environments, the Cubature Kalman Filter is applied to enhance nonlinear state estimation capabilities. The proposed method is validated through simulations using the Precise Strapdown Inertial Navigation System toolbox, analyzing UAV and UGV trajectories. Experimental results show that compared to traditional filtering methods, the proposed algorithm reduces position estimation errors by 25% in UAV scenarios and improves computational efficiency by 50% in UGV scenarios.

Keywords: low-cost unmanned vehicles; filter selection; Kalman filter; cubature Kalman filter; particle filter

0 引 言

近年来,随着现代战争形态向信息化、智能化方向快速演进,低成本无人飞行器在军事侦察、目标打击、战场监视等任务中得到广泛应用。在俄乌冲突等典型实战场景中,大量部署并高频损耗的小型无人飞行器展现出快速响应、成本低廉与任务可牺牲性强等优势,已成为新型无人作战体系的重要组成部分。然而,受限于平台体积、成本与能耗约束,此类无人系统多采用微型传感器与低算力芯片,导致其导航系统在面对复杂战场环境(如全球导航卫星系统信号中断、遮挡、高动态机动等)时难以维持足够的稳定性与精度,严重制约了其作战效能的进一步提升。

如在高精度导航系统中,通常依赖光纤陀螺仪、激光陀

螺仪等高性能惯性器件,结合全球导航卫星系统(global navigation satellite system, GNSS)进行信息融合。但受限于其高昂成本与系统复杂度,上述方案难以适用于对成本、批量性与部署效率要求极高的低成本无人平台。当前主流解决方案转向基于微机电系统惯性测量单元(micro-electro-mechanical system inertial measurement unit, MEMS IMU)与 GNSS 的组合导航系统。然而, MEMS 惯性测量单元存在零偏不稳定、温漂显著、随机游走严重等问题,且 GNSS 信号在复杂环境中也常面临遮挡、中断与低更新率等限制。在不同行驶阶段(如匀速直线、缓转弯、剧烈机动)中,系统动态特性和非线性程度差异较大,传统固定滤波器难以兼顾计算效率与状态估计精度,进一步限制了其应用可靠性。

为了提升组合导航系统在不同动态环境下的适应性与精度,学者们提出了多种改进滤波算法。其中,自适应扩展卡尔曼滤波(adaptive extended Kalman filter, AEKF)、强跟踪卡尔曼滤波(strong tracking Kalman filter, STKF)等方法通过调节噪声协方差或增益参数,有效提升了滤波器对动态突变与建模误差的适应能力^[1-2]。自适应无迹卡尔曼滤波(adaptive unscented Kalman filter, AUKF)算法也被广泛研究,通过动态调节过程噪声与测量噪声协方差,有效提升了系统非线性与不确定性环境下的估计精度与稳定性^[3-4]。此外,部分研究构建了多滤波器切换机制,依据系统状态协方差、观测残差或加速度等动态特征^[5]。然而,这类方法大多依赖系统内部状态的实时反馈,缺乏统一、明确的状态划分建模机制,尤其在如何根据“系统非线性程度”选择合适滤波器方面尚缺成熟理论框架。

与此同时,人工智能技术也被引入到导航估计任务中。例如,部分研究利用长短期记忆网络(long short-term memory network, LSTM)对惯性测量误差进行建模,或使用神经网络估计状态协方差矩阵,实现滤波性能的自适应优化^[6]。但该类方法对训练数据依赖强,泛化能力差,且对算力资源要求高,难以直接部署于轻量级、低成本导航系统。

为此,本文提出一种组合导航滤波算法选择机制。该机制通过轨迹曲率间接衡量当前运动状态所对应的系统非线性程度,该方法并非融合多个滤波器结果,也不依赖深度学习模型进行选择,而是基于明确划分规则实现最优单一滤波器的选择。实验基于纯捷联惯性导航系统(pure strapdown inertial navigation system, PSINS)仿真平台进行^[7],结果表明该机制在动态变化条件下能够有效提升估计精度与鲁棒性,为低成本无人平台的高精度导航提供了可行路径。

1 传统卡尔曼滤波与非线性卡尔曼滤波

1.1 线性卡尔曼滤波

卡尔曼滤波(Kalman filter, KF)是一种递归算法,基于贝叶斯估计原理,常用于 GNSS 与 INS 数据的融合处理。其通过对系统状态的预测与观测进行不断修正,能够实现系统状态的最优估计^[8]。主要包括状态更新和量测更新两个阶段:首先根据系统输出对状态进行预测;然后通过比较预测值与实际测量值,利用新的测量数据进行状态更新。

卡尔曼滤波的状态和测量模型、更新步骤可表示为:

$$\begin{cases} \mathbf{x}_k = \boldsymbol{\phi}_{k-1} \mathbf{x}_{k-1} + \boldsymbol{\omega}_{k-1} \\ \mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \\ \hat{\mathbf{x}}_k^- = \boldsymbol{\phi}_{k-1} \hat{\mathbf{x}}_{k-1} \\ \hat{\mathbf{P}}_k^- = \boldsymbol{\phi}_{k-1} \hat{\mathbf{P}}_{k-1} \boldsymbol{\phi}_{k-1}^T + \mathbf{Q}_{k-1} \\ \mathbf{K}_k = \hat{\mathbf{P}}_k^- \mathbf{H}_k^T (\mathbf{H}_k \hat{\mathbf{P}}_k^- \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \\ \hat{\mathbf{x}}_k = \mathbf{x}_k + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_k^-) \\ \hat{\mathbf{P}}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \hat{\mathbf{P}}_k^- \end{cases} \quad (1)$$

其中, \mathbf{x}_k 为状态向量, $\boldsymbol{\phi}_{k-1}$ 为状态转移矩阵; \mathbf{z}_k 为测量向量, \mathbf{H}_k 为测量矩阵。 \mathbf{Q}_k 和 \mathbf{R}_k 分别为过程噪声协方差矩阵和测量噪声协方差矩阵。 $\hat{\mathbf{x}}_k^-$ 为先验状态估计值, $\hat{\mathbf{x}}_{k-1}$ 为上一时刻的后验状态估计值, $\hat{\mathbf{P}}_k^-$ 为先验状态协方差矩阵, $\hat{\mathbf{P}}_{k-1}$ 为上一时刻的后验状态协方差矩阵。卡尔曼增益 \mathbf{K}_k 影响状态更新过程,使新测量值与模型预测值在融合时具有合理的权重分配,从而优化最终状态估计。

$$\begin{cases} E\{\boldsymbol{\omega}_k\} = E\{\mathbf{v}_k\} = 0 \\ E\{\boldsymbol{\omega}_k \mathbf{v}_k^T\} = 0 \\ E\{\mathbf{w}_k \mathbf{w}_k^T\} = \begin{cases} \mathbf{Q}_k, & i = k \\ 0, & i \neq k \end{cases} \\ E\{\mathbf{v}_k \mathbf{v}_k^T\} = \begin{cases} \mathbf{R}_k, & i = k \\ 0, & i \neq k \end{cases} \end{cases} \quad (2)$$

噪声项 $\boldsymbol{\omega}_{k-1}$ 和 \mathbf{v}_k 为零均值不相关的白噪声序列。卡尔曼增益的大小受测量噪声协方差 \mathbf{R}_k 和系统状态协方差 \mathbf{Q}_k 的影响。如果卡尔曼增益过小,可能会导致估计结果偏离真实值;增益过大,则可能引发滤波器的发散^[9-10]。卡尔曼滤波算法原理图如图 1 所示。

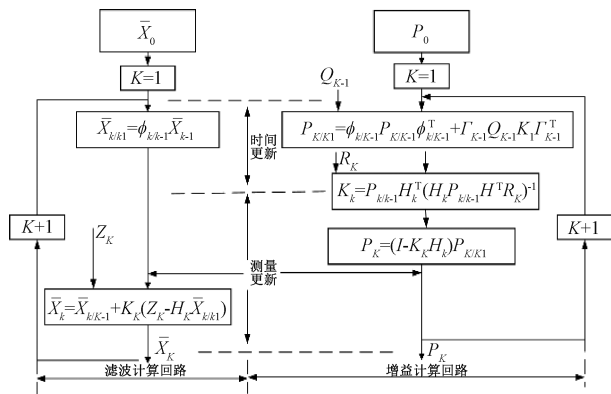


图 1 卡尔曼滤波算法原理过程

Fig. 1 Principle of Kalman filter algorithm

1.2 非线性容积卡尔曼滤波

在组合导航系统中,由于状态方程和观测方程都是非线性的,最初的 KF 算法在处理这类非线性系统时,估计结果往往不够精确^[11]。因此有学者提出容积卡尔曼滤波,容积卡尔曼滤波(cubature Kalman filter, CKF)的原理是基于球面积分,通过这种方法对状态空间进行有效的积分,从而更精确地逼近非线性系统的预测和更新步骤^[12-14]。其核心思想是对系统的状态进行一组采样点(即立方体点或球面点)的采样,以 $2n$ 个等权重求积点之和近似求解加权高斯积分,所以在处理高维数非线性滤波估计问题时具有更高的精度和稳定性^[15]。

CKF 的步骤主要包括预测步骤和更新步骤。

预测步骤:首先计算当前状态估计的均值 $\hat{\mathbf{x}}_{k|k-1}$ 和协方差矩阵 $\mathbf{P}_{k|k-1}$ 。然后,通过采样点(即立方体点或球面

点)对状态空间进行离散化。这些采样点是基于状态均值 $\hat{\mathbf{x}}_{k|k-1}$ 和协方差矩阵 $\mathbf{P}_{k|k-1}$ 生成的,它们覆盖了状态空间的各种可能性。

生成的采样点为:

$$\boldsymbol{\sigma}_i = \hat{\mathbf{x}}_{k|k-1} \pm \alpha \sqrt{\mathbf{P}_{k|k-1}}, i = 1, 2, \dots, 2n \quad (3)$$

其中, α 是一个常数, n 是状态向量的维度, $\sqrt{\mathbf{P}_{k|k-1}}$ 是协方差矩阵的平方根。

对于每个采样点,利用系统的非线性状态方程进行时间更新,得到每个采样点的预测状态。最后,通过对所有采样点的加权平均来得到状态预测的均值和协方差。每个采样点 $\boldsymbol{\sigma}_i$ 被代入系统的非线性状态方程进行时间更新,得到预测的状态 $\hat{\mathbf{x}}_{k|k-1}^{(i)}$, 并计算预测的协方差。

$$\left\{ \begin{aligned} \hat{\mathbf{x}}_{k|k-1} &= \frac{1}{2n} \sum_{i=1}^{2n} \hat{\mathbf{x}}_{k|k-1}^{(i)} \\ \mathbf{P}_{k|k-1} &= \frac{1}{2n} \sum_{i=1}^{2n} (\hat{\mathbf{x}}_{k|k-1}^{(i)} - \hat{\mathbf{x}}_{k|k-1})(\hat{\mathbf{x}}_{k|k-1}^{(i)} - \hat{\mathbf{x}}_{k|k-1})^T \\ \hat{\mathbf{z}}_{k|k-1} &= \frac{1}{2n} \sum_{i=1}^{2n} \mathbf{H}(\hat{\mathbf{x}}_{k|k-1}^{(i)}) \\ \mathbf{P}_{zz} &= \frac{1}{2n} \sum_{i=1}^{2n} (\mathbf{H}(\hat{\mathbf{x}}_{k|k-1}^{(i)}) - \hat{\mathbf{z}}_{k|k-1})(\mathbf{H}(\hat{\mathbf{x}}_{k|k-1}^{(i)}) - \hat{\mathbf{z}}_{k|k-1})^T \\ \mathbf{P}_{xz} &= \frac{1}{2n} \sum_{i=1}^{2n} (\hat{\mathbf{x}}_{k|k-1}^{(i)} - \hat{\mathbf{x}}_{k|k-1})(\mathbf{H}(\hat{\mathbf{x}}_{k|k-1}^{(i)}) - \hat{\mathbf{z}}_{k|k-1})^T \\ \mathbf{K} &= \mathbf{P}_{xz} \mathbf{P}_{zz}^{-1} \\ \hat{\mathbf{x}}_{k|k} &= \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}(\mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1}) \\ \mathbf{P}_{k|k} &= \mathbf{P}_{k|k-1} - \mathbf{K} \mathbf{P}_{zz} \mathbf{K}^T \end{aligned} \right. \quad (4)$$

在预测步骤中,系统首先计算下一时刻的状态向量 $\hat{\mathbf{x}}_{k|k-1}$ 和协方差矩阵 $\mathbf{P}_{k|k-1}$; 在更新步骤中,通过每个采样点的预测状态计算相应的观测值,并将其与实际观测值进行比较。观测值的均值和协方差矩阵分别为 $\hat{\mathbf{z}}_{k|k-1}$ 和 \mathbf{P}_{zz} ; 此外,预测的状态与观测之间的协方差矩阵为 \mathbf{P}_{xz} , 根据这些量计算卡尔曼增益 \mathbf{K} , 并最终得到更新后的状态估计 $\hat{\mathbf{x}}_{k|k}$ 和协方差矩阵 $\mathbf{P}_{k|k}$ [16]。

通过预测和更新两个步骤,CKF 能够在非线性系统下实现状态估计。这一过程的重复迭代,使得 CKF 逐步逼近系统的真实状态。CKF 算法原理图如图 2 所示。

1.3 非线性、非高斯粒子滤波

粒子滤波 (particle filter, PF) 是一种基于蒙特卡洛方法的非线性、非高斯系统的递归状态估计算法,其核心原理是通过随机采样 (粒子) 来近似描述后验概率分布 [17-18]。

PF 的核心原理可以分为以下 5 个步骤:

初始化:在初始时刻,PF 通过对系统状态空间进行随机采样生成一组粒子,每个粒子代表状态空间中的一个可能状态。每个粒子 $\mathbf{x}_t^{(i)}$ 和其对应的权重 $w_t^{(i)}$ 反映了系统当前状态的可能性。通常,粒子的初始权重是相等的。

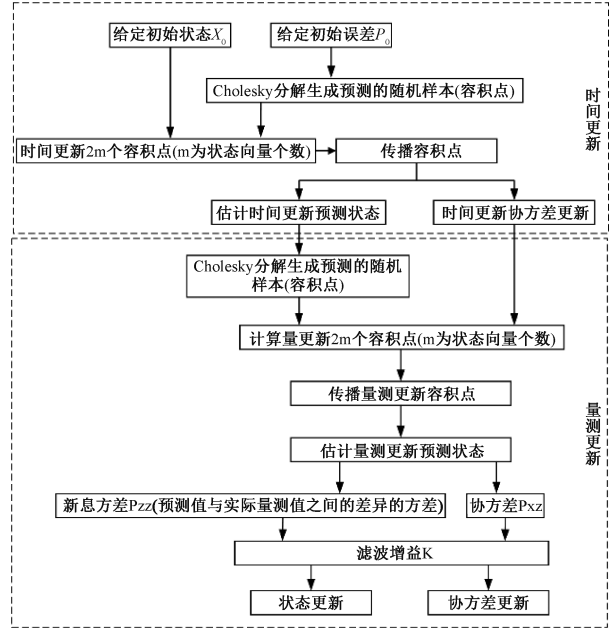


图 2 容积卡尔曼滤波算法原理过程

Fig. 2 Principle of unscented Kalman filter algorithm

预测 (重要性采样): 在每一时刻, PF 根据系统的动态模型对粒子进行传播。也就是说, 根据上一时刻的状态估计和系统的运动模型, 通过高斯噪声生成下一时刻的粒子。粒子的位置由状态转移方程描述:

$$\mathbf{x}_t^{(i)} = f(\mathbf{x}_{t-1}^{(i)}, \mathbf{u}_t) + \mathbf{v}_k \quad (5)$$

其中, $f(\mathbf{x}_{t-1}^{(i)}, \mathbf{u}_t)$ 是系统状态转移函数, \mathbf{u}_t 是控制输入, \mathbf{v}_k 是高斯噪声, 表示系统的随机变化。

更新 (加权): 在每一时刻, 利用测量值和预测粒子, PF 通过计算每个粒子的权重来反映其与当前测量值的匹配程度。通过测量模型 $p(\mathbf{z}_t | \mathbf{x}_t)$, 更新粒子的权重:

$$w_t^{(i)} = p(\mathbf{z}_t | \mathbf{x}_t^{(i)}) \quad (6)$$

其中, $w_t^{(i)}$ 是粒子 $\mathbf{x}_t^{(i)}$ 在时刻 t 的权重, \mathbf{z}_t 是当前时刻的观测数据, $p(\mathbf{z}_t | \mathbf{x}_t^{(i)})$ 是观测模型, 描述了粒子状态与观测数据之间的关系。

重采样: 在实际应用中, 随着粒子的传播, 可能会出现部分粒子的权重非常小, 而部分粒子的权重较大, 导致粒子集中在某些区域, 其他区域则无粒子。这种现象叫做“粒子退化”。为了解决这个问题, PF 使用重采样技术。在重采样步骤中, 粒子根据其权重进行抽样, 低权重的粒子被丢弃, 高权重的粒子被复制。这样可以保持粒子的多样性, 减少粒子退化的影响, 用数值逼近的方法得到系统最优估计 [19]。

估计与输出: 经过多次预测、更新和重采样后, 粒子滤波通过加权平均得到系统状态估计:

$$\hat{\mathbf{x}}_t = \sum_{i=1}^N w_t^{(i)} \mathbf{x}_t^{(i)} \quad (7)$$

其中, $\hat{\mathbf{x}}_t$ 是当前时刻的状态估计, $\mathbf{x}_t^{(i)}$ 是第 i 个粒子的

位置, $w_i^{(i)}$ 是第 i 个粒子的权重。粒子滤波算法原理图如图 3 所示。

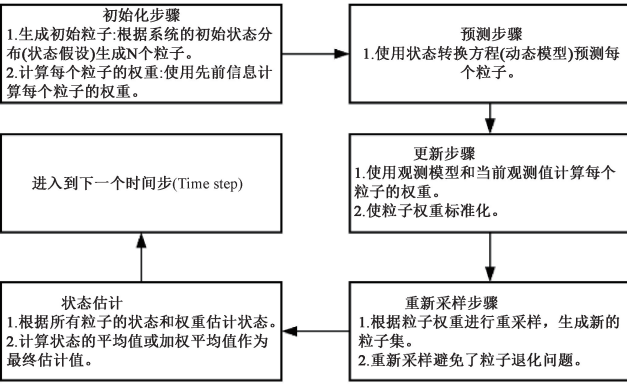


图 3 粒子滤波算法原理过程
Fig. 3 Principle of particle filter algorithm

2 动态滤波器选择算法

2.1 滤波器选择机制及轨迹曲率判断

本文提出的滤波器选择机制基于无人器的运动状态进行自适应选择,以平衡导航精度与计算效率。核心思想是通过轨迹曲率评估无人器的运动特性,并根据不同动态环境选用合适的滤波器。低动态环境(直线或缓慢转向运动):轨迹曲率较低($K \leq K_1$),选用卡尔曼滤波(KF),以减少计算开销。中等动态环境(一般转弯、爬升等非线性运动):轨迹曲率介于 K_1 和 K_2 之间($K_1 \leq K < K_2$),选用容积卡尔曼滤波(CKF),提高非线性状态估计能力。高动态环境(剧烈机动、急转、避障等):轨迹曲率较高($K \geq K_2$),理论上适用粒子滤波(PF),但由于其计算复杂度较高,未来的研究将扩展至 PF 在高动态场景下的验证与优化。

曲率反映了无人器运动轨迹的非线性变化程度,能够有效识别直线、转弯、爬升等典型场景。为了验证轨迹曲率作为动态划分指标的合理性,本文进一步分析了其与速度、加速度、角速度等其他常见运动参数的关系,并说明其作为滤波器选择依据的优势:

首先,速度与加速度主要描述运动快慢与变化率,虽然可反映动态强度,但难以直接区分直线加速与曲线转向等非线性行为。而角速度往往受到载体姿态变化影响较大,存在噪声敏感性与方向耦合问题,不易稳定量化轨迹变化趋势。相比之下,轨迹曲率可从无人器位置序列中直接计算,具有方向无关性和几何稳定性,适合作为滤波器选择的主要依据。

其次,实验表明,在大多数典型场景下(如转弯、绕障、斜爬升等),轨迹曲率变化显著,对动态状态分类具有良好区分度。因此本文优先采用轨迹曲率作为动态环境量化指标,以构建简洁稳定的滤波器切换机制。

当然,在未来研究中,考虑将加速度模、角速度变化率等参数纳入多维状态评估指标体系中,进一步提高滤波器

选择的准确性与鲁棒性。
本文将计算飞行器运动的轨迹曲率,作为选择滤波器的依据。轨迹曲率反映了飞行器运动的动态变化程度,其中,轨迹曲率 K 由无人器的位置变化率计算得出:

$$K = \frac{|x'y'' - y'x''|}{(x'^2 + y'^2)^{3/2}} \tag{8}$$

其中, (x', y') 和 (x'', y'') 分别是轨迹的一阶和二阶导数。设定阈值和用于滤波器选择,不同环境下的参数设定值分别为 $K_1 = 0.01$ 和 $K_2 = 0.1$ 。实际应用中,这些阈值可通过实验调整,以适应不同无人器的动力学特性。滤波器选择机制如图 4 所示。

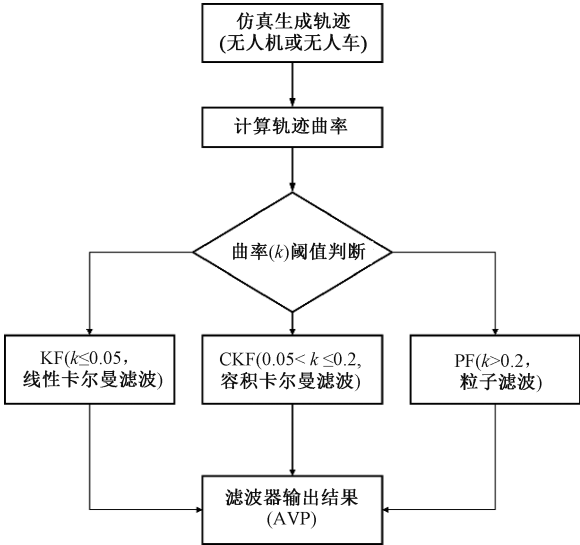


图 4 动态滤波器选择机制
Fig. 4 Dynamic filter selection mechanism

此滤波器选择机制根据轨迹曲率值 k 设定 3 个阈值:当 $K \leq 0.05$ 时,选择卡尔曼滤波器(KF);当 $0.05 < K \leq 0.2$ 时,选择容积卡尔曼滤波器(CKF);当 $K > 0.02$ 时,理论上选择粒子滤波器(PF),但本研究暂未启用 PF 分支,保留扩展接口。

2.2 不同滤波器的计算复杂度对比

由于不同滤波器的计算开销不同,本文对 KF、CKF 和 PF 在状态更新过程的计算复杂度进行了对比,如表 1 所示。

表 1 不同滤波器的计算复杂度对比
Table 1 Comparison of computational complexity of different filters

滤波方法	适用场景	时间复杂度 (Big-O notation)	主要计算开销
KF	低动态	$O(n^2)$	矩阵乘法、逆运算
CKF	中等动态	$O(n^3)$	立方体采样点计算
PF	高动态	$O(Mn^2)$ (M 为粒子数)	重采样

KF 计算复杂度最低,仅需进行矩阵运算,适用于低动态环境;CKF 需要计算 $2n$ 个采样点,并进行非线性变换,计算开销较 KF 高,但能更好处理非线性问题;PF 计算复杂度最高,与粒子数 M 成正比,不适用于计算资源受限的应用。

3 实验仿真设计和结果

3.1 实验设计

本研究运用 MATLAB 2023a 开展仿真实验,组合导航仿真依托 PSINS 工具箱^[4],该工具箱具备 SINS/GNSS 组合导航建模功能。不过,原始的 PSINS 工具箱缺乏轨迹曲率评估以及滤波器自适应选择机制,且其自带的 PF 算法存在缺陷。鉴于此,本文在该工具箱基础上,新增了轨迹曲率计算模块和滤波器选择策略,对 PF 算法存在的问题进行了调试与优化,并提出了使其能够正常运行进行仿真实验。

为验证所提出的滤波器选择机制在不同运动环境下的有效性。仿真过程中,设定了典型的无人机和无人车运动轨迹,并基于实际传感器特性构建 IMU/GNSS 误差模型。

1)IMU 误差模型

惯性测量单元(IMU)误差来源包括零偏漂移、随机游走噪声等,本文根据常见低成本 MEMS 传感器的典型参数进行建模,具体参数如表 2 所示。

表 2 IMU 误差模型参数

参数	数值	单位
加速度计零偏误差	0.05	m/s^2
陀螺仪零偏误差	110	deg/h
加速度计随机游走噪声	0.003	$\text{m/s}^2/\sqrt{\text{Hz}}$
陀螺仪随机游走噪声	5	$\text{deg}/\sqrt{\text{h}}$

IMU 采样率设定为 100 Hz,仿真过程中,对加速度和角速度数据加入上述误差,以模拟低成本惯性传感器的真实误差特性。

2)GNSS 误差模型

GNSS 误差主要受信号遮挡、电离层延迟、多路径效应等影响。本文设定 GNSS 采样频率为 1Hz,并在测量数据中引入随机噪声,以模拟实际 GNSS 观测误差,具体参数如表 3 所示。

表 3 GNSS 误差模型参数

参数	数值/m
水平位置误差	1.0
垂直位置误差	2.0
速度误差	0.1

3)无人机/无人车运动轨迹

仿真实验分别构建了无人机和无人车的典型运动轨迹,并通过 IMU+GNSS 数据进行融合。无人机轨迹包括匀速飞行、加速飞行、爬升、转向等运动模式,轨迹生成参数如表 4 所示。

表 4 无人机轨迹仿真实验数据

Table 4 Simulation data of UAV trajectory				
飞行阶段	类型	持续时间/s	加速度/ $(\text{m}\cdot\text{s}^{-2})$	滚转 时间/s
1	匀速	80	0	0
2	加速	20	1	0
3	匀速	80	0	0
4	左转	45	2	4
5	匀速	80	0	0
6	右转	50	9	4
7	匀速	80	0	0
8	爬升	10	2	0
9	匀速	80	0	0
10	下降	10	2	0
11	匀速	80	0	0
12	减速	5	2	0
13	匀速	80	0	0

无人车轨迹包括直行、加速、转弯、爬坡等七种场景。轨迹生成参数如表 5 所示。

表 5 无人车轨迹仿真实验数据

Table 5 Simulation data of UGV trajectory				
行驶阶段	类型	持续时间/ s	加速度/ $(\text{m}\cdot\text{s}^{-2})$	角速度/ $(\text{rad}\cdot\text{s}^{-1})$
1	匀速	200	0	0
2	加速	20	1.5	0
3	右转	10	0	0
4	减速	10	3	0
5	爬坡	15	1.5	0
6	右转	10	0	0
7	下坡	10	0	0

为了验证所提出的动态滤波器选择机制的有效性,本文设计了以下实验:采用无人机、无人车仿真数据作为实验数据,分别在典型运动环境:低动态环境和中等动态环境。其中低动态环境:无人器以低速平稳飞行,模拟城市巡航或农田巡检场景。

实验通过对上面的实验数据参数设置之后,在 MATLAB 仿真生成一段无人机运动轨迹,用于测试导航算法的性能,无人机轨迹仿真如图 5 所示。




图 5 无人机轨迹仿真图

Fig. 5 UAV trajectory simulation

其次,生成无人车(轨迹)的仿真数据,用于测试车辆导航算法的性能。轨迹的初始速度为 10 m/s,采样间隔为 0.1 s,共包括 8 个行驶阶段。这些设置使得仿真实验更加贴近实际场景,能够有效验证导航算法在噪声环境下的鲁棒性和精度。在 MATLAB 仿真生成运动轨迹,无人车轨迹仿真如图 6 所示。




图 6 无人车轨迹仿真图

Fig. 6 UGV trajectory simulation

3.2 实验结果

1) 实验场景-无人车

在此场景下,模拟当无人车的轨迹动态线性程度比较高时,通过实验发现,滤波方法选择了普通卡尔曼滤波器(KF)。普通卡尔曼滤波算法能够处理线性化程度高的系统。实验是基于卡尔曼滤波算法(KF)的 15 维状态(姿态、速度、位置、加速度计误差、陀螺误差)状态 SINS/GPS 组合导航系统仿真,通过加载轨迹数据并添加 IMU 误差。在仿真过程中,利用 IMU 数据更新 INS 状态,并通过 GPS 位置观测修正 KF 估计。最终输出导航结果并绘制误差曲线,验证了 KF 在强线性系统中的估计精度和鲁棒性。同时,

实验对比分析了在没有滤波选择机制时,容积卡尔曼滤波和粒子滤波对无人机位置误差估计。在实验中,为了更好地验证算法机制的优越性,绘制了无人车滤波前位置误差图,如图 7 所示,以此图为对照进行滤波前后对比分析。为量化滤波效果的稳定性,本文引入收敛速度指标,定义为系统位置误差首次小于 0.5 m(用实心小正方形标注坐标点)并持续 200 s 的时间点,作为判断滤波器状态稳定的依据。无人车卡尔曼滤波位置误差如图 8 所示,其中点线曲线、点划线曲线、虚线曲线分别代表经度、纬度、高度的变化。实验结果表明,在选择了卡尔曼滤波算法时经度、纬度收敛速度相对于容积卡尔曼滤波算法提升了约 62%,同时维度误差,仍能保持在较小的误差范围之内,而容积卡尔曼滤波收敛速度慢,粒子滤波位置误差估计始终大于 0.5 m,所以此时更适用 KF 进行算法估计。图 9 和图 10 分别是无人车卡尔曼滤波位置误差和无人机粒子滤波位置误差,相对于卡尔曼滤波算法误差高度收敛较慢,误差较大。此外,从图 8~10 中可观察到,在约 200~250 s 的时间段,无人车纬度误差出现较明显的波动。这一现象主要源于车辆在此时段进入动态转弯及爬坡阶段,惯性导航误差迅速积累,而 GNSS 更新频率较低(1 Hz)导致估计无法及时修正,造成纬度方向的误差突增。




图 7 无人车滤波前位置误差

Fig. 7 UGV position error before filtering




图 8 无人车卡尔曼滤波位置误差

Fig. 8 UGV position error with Kalman filter




图 9 无人车粒子滤波位置误差

Fig. 9 UGV position error with particle filter




图 10 无人车容积卡尔曼滤波位置误差

Fig. 10 UGV position error with unscented Kalman filter

2) 实验场景-无人机

根据计算得到的轨迹曲率,系统将动态选择适合的滤波器。在本次实验中,当无人机轨迹变化较大且飞行状态较为不是特别平稳时,选择 CKF。中等曲率基于 CKF 的 15 维状态(姿态、速度、位置、加速度计误差、陀螺误差)SINS/GPS 组合导航系统仿真。通过加载轨迹数据并添加 IMU 误差,初始化 INS 和 CKF。在仿真过程中,利用 IMU 数据更新 INS 状态,并通过 GPS 位置观测修正 KF 估计,最终输出导航结果并绘制误差曲线,验证了系统在动态环境下的估计精度和鲁棒性。在实验中,为了更好验证算法机制的优越性,绘制了无人机滤波前位置误差图,如图 11 所示,以此图作为对照进行滤波前后对比分析。为量化滤波效果的稳定性,在此也引入收敛速度指标,定义为系统位置误差首次小于 0.5 m(用实心小正方形标注坐标点)并持续 200 s 的时间点,作为判断滤波器状态稳定的依据。无人机容积卡尔曼滤波位置误差如图 12 所示,其中点线曲线、点划线曲线、虚线曲线分别代表经度、纬度、高度的变化。同时,本文对比分析了在没有滤波选择机制时,KF 和 PF 对无人机位置误差估计。实验结果表明,在选择了 CKF 时高度误差缩小了约 40%,同时经度和维度误差,仍能保持在较小的误差范围之内,所以此时更适用 CKF 进行算法估计。图 13 和图 14 分别是无人机卡尔曼滤波位置误差和无人机粒子滤波位置误差,相对于 CKF 误差高度收敛较慢,误差较大。类似地,图 12~14 中,无人机在约 100 s 时段开始进入剧烈爬升与转向阶段,飞行轨迹发生突变,导致系统非线性增强,此时使用 KF 等线性滤波器时难以有效建模系统状态,进而使纬度估计偏差增大。尽管 CKF 在该时段表现优于 KF 和 PF,但仍受到系统动态复杂度与噪声扰动的共同影响。该现象表明,在快速动态变化阶段,滤波器应具备更强的非线性建模与观测适应能力,这也为后续研究探索高动态条件下 PF 或混合滤波方法的改进提供了参考依据。

3.3 结果分析

在 MATLAB 2023a 平台上,对本文所用的滤波器迭代过程进行运行时间测试。结果显示,KF 每次滤波处理平均耗时为 0.022 1 ms,CKF 平均耗时为 0.428 2 ms,两者均远低于嵌入式系统常见的 10 ms 控制周期,PF 每次滤波运行平均耗时为 12.49 ms(粒子数为 10 000),在不做并行加




图 11 无人机滤波前位置误差

Fig. 11 UAV position error before filtering




图 12 无人机容积卡尔曼滤波位置误差

Fig. 12 UAV position error with unscented Kalman filter




图 13 无人机卡尔曼滤波位置误差

Fig. 13 UAV position error with Kalman filter




图 14 无人机粒子滤波位置误差

Fig. 14 UAV position error with particle filter

速的情况下已接近常见嵌入式处理周期上限,说明在复杂动态环境下部署 PF 策略需配合降采样、并行化或粒子数压缩等优化手段,以满足实时处理需求。此上说明本文所提出的滤波器选择机制具备良好的实时性,适合部署在如 STM32H7、ARM Cortex-A 系列等资源受限的嵌入式平台中。实验结果表明,低动态环境下,本方法能有效降低误差。在静态环境下,卡尔曼滤波器(KF)表现出较高的计算效率和定位精度,定位误差在 0.1 m 以内;容积卡尔曼滤波器(CKF)的精度与 KF 相当,但由于其非线性处理特性,计算复杂度略高。在低动态环境下(如匀速直线运动),KF 的表现优于 CKF,定位误差较 CKF 降低了约 20%。在中等动态环境下(如无人机机动飞行),CKF 的定位精度保持稳定,误差较 KF 进一步降低至 30%。在静态和低动态线

性环境下(如无人车巡航),KF 能够以高计算效率实现定位精度;在低动态和中等动态非线性环境下(如无人机转弯、爬升),CKF 通过球面容积准则有效处理系统非线性,定位误差较 KF 显著降低;基于运动状态(如轨迹曲率)的自适应滤波器选择策略,能够平衡精度与计算效率,在静态、低动态和中等动态环境下均实现最优性能。未来研究可进一步探索高动态复杂环境(如高速避障、剧烈机动)下的滤波器优化方案,例如结合 PF 等非线性估计方法。

4 结 论

本文提出了一种基于轨迹曲率的滤波器自适应调整策略,可在不同运动环境下动态选择合适的滤波器(如 KF 与 CKF),实现导航精度与计算效率的协同优化。实验结果表明,该动态选择机制在静态、低动态及中等动态环境中均表现出良好性能;在静态和低动态线性场景中,KF 以较低计算开销实现较高定位精度;而在中等动态、非线性场景中,CKF 通过更精确的非线性状态估计将定位误差较 KF 降低约 20%~30%。该机制有效提升了低成本无人系统在复杂环境中的导航准确性与实时性。

进一步的研究工作可从以下两个方面展开:其一,融合视觉传感器、激光雷达等多源感知信息,构建冗余观测体系,以提升观测质量并降低对低性能 IMU 误差的敏感性;其二,针对高动态复杂场景(如高速避障与剧烈机动),探索粒子滤波(PF)等非线性估计算法的轻量化设计,在保障估计精度的同时优化实时性。这些改进将进一步推动动态滤波器选择机制在更广泛实际应用场景中的部署与落地。

参考文献

- [1] 张庭芳,凌勇,谢世坤,等. 自适应扩展卡尔曼滤波在车辆状态估计中的优化研究[J]. 井冈山大学学报(自然科学版),2025,46(2):89-96.
ZHANG T F, LING Y, XIE SH K, et al. Optimization research of adaptive extended kalman filter in vehicle state estimation [J]. Journal of Jinggangshan University (Natural Science Edition), 2025, 46(2): 89-96.
- [2] 陈雨,王健博,张凌东,等. 基于强跟踪滤波的捷联惯导/里程计组合导航[J]. 现代防御技术,2018,46(4):27-32,98.
CHEN Y, WANG J B, ZHANG L D, et al. Integrated navigation of strapdown inertial navigation system/odometer based on strong tracking filter[J]. Modern Defense Technology, 2018, 46(4): 27-32,98.
- [3] 荆蕾,林雪原,潘新龙,等. 基于改进 Sage-Husa 的 GNSS/SINS 组合导航系统自适应 UKF 算法[J]. 中国空间科学技术,2024,44(5):127-135.
JING L, LIN X Y, PAN X L, et al. Adaptive UKF algorithm for GNSS/SINS integrated navigation

system based on improved Sage-Husa [J]. Chinese Journal of Space Science and Technology, 2024, 44(5): 127-135.

- [4] 刘军,吴贤勇,田甜. 基于 AUKF 的 SINS/GPS 紧组合导航系统研究[J]. 电子测量与仪器学报,2020,37(11):97-102.
LIU J, WU X Y, TIAN T. Research on SINS/GPS tight integration navigation system based on AUKF[J]. Journal of Electronic Measurement and Instrumentation, 2020, 37(11): 97-102.
- [5] AKHLAGHI S, ZHOU N, HUANG Z. Adaptive adjustment of noise covariance in Kalman filter for dynamic state estimation [C]. 2017 IEEE Power & Energy Society General Meeting, 2017: 1-5.
- [6] 刘傲. 基于长短期记忆网络的 INS/GNSS 协同导航方法研究[D]. 沈阳:辽宁工程技术大学,2024.
LIU AO. Research on INS/GNSS integrated navigation method based on long short-term memory network [D]. Shenyang: Liaoning Technical University, 2024.
- [7] 严恭敏,王书军. PSINS: 惯性导航系统仿真测试的 MATLAB 工具箱 [J]. 航空学报,2018,39(5):1234-1245.
YAN G M, WANG SH J. PSINS: A MATLAB toolbox for inertial navigation system simulation and testing [J]. Chinese Journal of Aeronautics, 2018, 39(5): 1234-1245.
- [8] 田广亮,张丽杰,李志宇. SVR 辅助改进鲁棒卡尔曼滤波的 UWB/INS 组合定位方法[J]. 电子测量技术,2022,45(3):79-84.
TIAN G L, ZHANG L J, LI ZH Y. UWB/INS integrated positioning method based on SVR-assisted improved robust Kalman filter [J]. Electronic Measurement Technology, 2022, 45(3): 79-84.
- [9] 王金柱,李骏驰,董亮. 复杂环境下基于 BP-EKF 的 UWB-IMU 定位方法[J]. 自动化技术与应用,2021,40(4):19-23.
WANG J ZH, LI J CH, DONG L. UWB-IMU positioning method based on BP-EKF in complex environments [J]. Automation Technology and Applications, 2021, 40(4): 19-23.
- [10] 李晓明,赵长胜,谭兴龙. 改进的容积卡尔曼滤波的组合导航定位算法[J]. 测绘科学,2020,45(9):25-30,36.
LI X M, ZHAO CH SH, TAN X L. Improved cubature Kalman filter-based integrated navigation and positioning algorithm [J]. Geomatics Science and Technology, 2020, 45(9): 25-30,36.
- [11] 张学军,谭元皓,李雪缘,等. 星基 ADS-B 系统及关键

- 技术发展综述[J]. 北京航空航天大学学报, 2022, 48(9):1589-1604.
- ZHANG X J, TAN Y H, LI X Y, et al. Overview of satellite-based ADS-B system and key technology development[J]. Journal of Beihang University, 2022, 48(9): 1589-1604.
- [12] 张贺,秦伟伟,周城,等. 运用信息融合式高阶 UKF 的微小卫星姿态确定算法[J]. 空间科学学报, 2020, 40(6):1091-1101.
- ZHANG H, QIN W W, ZHOU CH, et al. Attitude determination algorithm for microsatellite based on high-order UKF using information fusion[J]. Chinese Journal of Space Science, 2020, 40(6): 1091-1101.
- [13] 张晓林,汪俊,严天宏,等. 基于改进 CKF 算法的 AUV 组合导航系统研究[J]. 舰船科学技术, 2025, 47(5): 37-42.
- ZHANG X L, WANG J, YAN T H, et al. Research on AUV integrated navigation system based on improved CKF algorithm [J]. Ship Science and Technology, 2025, 47(5): 37-42.
- [14] ZHANG Y G, XU G, LIU X. An improved SINS alignment method based on adaptive cubature kalman filter[J]. Sensors, 2019, 19(24): 5509.
- [15] 丁家琳,肖建,赵涛. 自适应 CKF 强跟踪滤波器及其应用[J]. 电机与控制学报, 2015, 19(11):110-120.
- DING J L, XIAO J, ZHAO T. Adaptive CKF strong tracking filter and its application [J]. Journal of Electric Machines and Control, 2015, 19 (11): 110-120.
- [16] 任萍,卢允娥. 一种基于 ADS-B 的空域态势监视系统设计方法研究[J]. 中国设备工程, 2021(22):105-107.
- REN P, LU Y E. Research on the design method of airspace situation awareness system based on ADS-B[J]. China Equipment Engineering, 2021(22): 105-107.
- [17] 李磊,高嵩,陈超波. 粒子滤波综述[J]. 国外电子测量技术, 2020, 39(6):6-12.
- LI L, GAO S, CHEN CH B. Overview of particle filtering [J]. Foreign Electronic Measurement Technology, 2020, 39(6): 6-12.
- [18] 江健,李伟峰,姚健,等. 改进的粒子滤波算法在船用组合导航中的应用[J]. 上海海事大学学报, 2018, 39(2): 17-21,65.
- JIANG J, LI W F, YAO J, et al. Application of improved particle filter algorithm in marine integrated navigation [J]. Journal of Shanghai Maritime University, 2018, 39(2): 17-21,65.
- [19] 田真. 多目标检测前跟踪的粒子滤波算法研究[D]. 成都:电子科技大学, 2019.
- TIAN ZH. Research on particle filter algorithm for tracking-before-detection of multiple targets [D]. Chengdu: University of Electronic Science and Technology of China, 2019.

作者简介

阳显(通信作者),硕士研究生,主要研究方向为组合导航与控制。

E-mail: 1140632348@qq.com

杨远超,副教授,主要研究方向为导航制导与控制,复杂航空和能源系统优化与控制。