

基于点阵模型的惯性融合导航技术

乔亮^{1*}, 羊富贵^{1*}, 余运龙¹, 任海科², 武永华², 董建怀²

¹福建江夏学院数理教研部, 福建 福州

²福建江夏学院电子信息科学学院, 福建 福州

收稿日期: 2026年5月4日; 录用日期: 2026年6月23日; 发布日期: 2026年7月6日

摘要

为解决单惯性导航系统中锚点引起的空间漂移问题, 通常采用多传感器系统, 通过不同传感器间的相互锚定机制有效抑制空间漂移。然而, 传统方法在提升导航精度和降低数据分析复杂度方面效果有限。本文提出了一种基于物理类比的、有前景的探索性方法, 该方法类比晶体物理的点阵结构, 将多个惯性传感器抽象为点阵中的格点, 利用格点间的相对约束关系构建对称模型, 通过多传感器间的相对位置约束实现漂移误差的自校正, 进而抑制导航过程中的空间漂移。本文分别设计多组模拟实验与一组真实场景实验对所提方法进行验证, 实验结果表明, 相较于传统单惯性导航方法与常规多传感器融合方法, 该方法可以在控制算法复杂度的前提下, 有效提升定位导航的精度, 为多惯性传感器协同导航提供了一种新的可行思路。该方法为惯性导航系统的多传感器融合提供了新的视角与方法论, 有望推动该领域进一步的技术进步。

关键词

数据融合, 定位导航, 点阵模型, 无人机

Inertial Fusion Navigation Technology Based on the Lattice Model

Liang Qiao^{1*}, Fugui Yang^{1*}, Yunlong Yu¹, Haike Ren², Yonghua Wu², Jianhuai Dong²

¹Department of Mathematics and Physics Teaching and Research, Fujian Jiangxia University, Fuzhou Fujian

²Department of Electronic Information Science, Fujian Jiangxia University, Fuzhou Fujian

Received: May 4, 2026; accepted: June 23, 2026; published: July 6, 2026

Abstract

To address spatial drift caused by anchor points in single-inertial navigation systems, multi-sensor systems are typically employed, effectively suppressing spatial drift through mutual anchoring

*通讯作者。

文章引用: 乔亮, 羊富贵, 余运龙, 任海科, 武永华, 董建怀. 基于点阵模型的惯性融合导航技术[J]. 传感器技术与应用, 2026, 14(4): 611-622. DOI: 10.12677/jsta.2026.144060

mechanisms among sensors. However, traditional approaches demonstrate limited effectiveness in enhancing navigation accuracy and reducing data analysis complexity. This paper proposes a promising exploratory method based on physical analogy, which mimics the lattice structure of crystal physics by abstracting multiple inertial sensors as grid points within a lattice. By leveraging the relative constraint relationships between grid points to construct a symmetric model, the method achieves self-correction of drift errors through positional constraints among sensors, thereby mitigating spatial drift during navigation. The proposed method is validated through multiple simulated experiments and one real-world scenario experiment. Results demonstrate that, compared to conventional single-inertial navigation methods and standard multi-sensor fusion approaches, this method significantly improves positioning and navigation accuracy while maintaining comparable control algorithm complexity, offering a novel and feasible strategy for collaborative multi-inertial sensor navigation. This approach provides fresh perspectives and methodologies for multi-sensor fusion in inertial navigation systems, poised to drive further technological advancements in the field.

Keywords

Data Fusion, Positioning and Navigation, Lattice Model, Unmanned Aerial Vehicle (UAV)

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

1.1. 惯性导航技术研究现状及多传感器协同的重要性

纵观人类发展历程，定位与导航技术始终与我们息息相关。从古人类利用日月星辰辨别方向，到指南针、陀螺仪的发明，再到现代惯性导航、卫星定位、视觉系统及激光雷达技术的涌现，技术演进的背后，是先辈们不懈探索与追求的壮阔图景。经过多年发展，定位与导航技术已形成惯性导航、卫星导航及新兴传感器导航三大核心类别[1][2]。与卫星导航相比，惯性导航能够在隧道、室内及深海等特殊环境中稳定完成导航任务，至今仍是不可或缺的关键工具。然而，惯性导航领域仍面临若干核心科学挑战：其一，惯性导航精度受时间影响显著，长期使用后精度会逐渐下降，这源于当前惯性传感器依赖重力加速度测量，通过积分计算位移的工作原理，而该过程本质上与时间强相关，易引发系统漂移；其二，惯性导航的空间锚定点位于传感器内部，空间漂移问题难以避免。时空漂移长期制约着测量精度的突破，即便采用高精度的陀螺仪惯性传感器，其精度通常也仅能达到米级水平。

对于飞行时长通常不足 10 分钟的微型无人机而言，时间漂移效应的影响相对较小，此时空间漂移成为制约精度的更关键因素。为缓解单传感器系统因空间漂移导致的精度问题，多传感器系统可通过相互参照形成基准，有效应对这一挑战。多传感器协同运作能够更全面地反映被测物体的真实状态，为后续决策与控制过程提供精准的信息支持；同时，这种协同机制还能显著提升系统的鲁棒性与容错能力。

在多传感器协同数据分析中，数据融合是核心环节，其方法主要分为两大类：基于信息的融合与基于模型的融合。基于信息的融合通过对传感器数据的加权组合生成最终结果，常见技术包括加权平均法[3]、特征融合[4]和决策级融合[5]。其中，加权平均法作为基础方法，依据数据可靠性与权重因子对多传感器信息进行加权处理，但未充分考虑传感器间的潜在相关性及误差；特征融合则突破简单加权，进一步提取并整合数据特征，有助于识别关键信息以提升准确性与效率；决策级融合通过综合多传感器结果

形成最终决策,可借助决策树、贝叶斯网络等技术实现,尤其适用于需整合数据的复杂决策场景。基于模型的融合则利用预设数学模型进行数据整合,需预先构建模型并输入传感器数据处理以获得融合结果,常见技术包括卡尔曼滤波[6]-[9]、粒子滤波[10]和均值滤波[11]。卡尔曼滤波是基于最优原理的线性时变系统估计方法,在线性系统数据融合中效果显著,通过递归处理传感器数据实现最优状态估计;粒子滤波是基于蒙特卡洛采样的非线性、非高斯系统估计方法,在复杂系统数据融合中表现突出,作为基础模型融合技术,其在信息融合层面与加权平均法存在诸多相似之处,通过平均运算降低噪声与误差影响;均值滤波操作原理简单,特定条件下可显著提升性能——当传感器数据受随机噪声干扰时,能有效平滑数据波动、提高准确性,但也存在局限性:处理快速变化数据或含非线性误差的数据时,可能无法达到预期融合效果。

在惯性导航领域,文献中已记载信息融合与模型融合两种方法,其中采用卡尔曼滤波的模型融合研究已被广泛探讨。例如,徐柳提出一种适用于 SINS 集成导航系统的双自适应无迹卡尔曼滤波算法,与传统 UKF 算法及 Sage-Husa 自适应 UKF (SH-AUKF)相比,该方法滤波精度相当且稳定性更优[12]。王迪引入异步顺序滤波技术,开发基于马氏距离的鲁棒卡尔曼滤波(KF)算法,不仅能有效剔除异常值、降低计算负担并提升导航精度,其核心在于基于速度误差模型改进的卡尔曼滤波算法[13] [14]。Yue Yu 开发了一套稳健的无缝定位框架,将 Wi-Fi FTM/GNSS 技术与内置传感器相结合,通过行人航位推算和磁检测技术减少惯性系统的累积误差,实现精确的航向与速度估算[15]。鉴于该领域已有大量文献,此处不再赘述。

1.2. 多传感器融合领域的当前挑战

在数据融合的两大主要类别中,基于信息的方法的准确性与传感器硬件质量密切相关。若传感器硬件精度不足或稳定性欠佳,这类方法的有效性将显著降低。此外,信息融合方法通常需经过数据清洗、校准等预处理步骤,这些步骤的准确性与效率直接影响后续融合结果。相比之下,基于模型的方法虽能在数据融合中实现更高精度,但其实施复杂度也更高。这类方法需要对系统进行精确的数学建模,且会消耗大量计算资源,因此对硬件性能要求较高。以卡尔曼滤波为例,它在线性系统融合中表现出色,但仍存在局限性:其一,它依赖于系统噪声与观测噪声服从高斯分布的关键假设,这限制了其在非高斯噪声环境中的适用性——实际系统中噪声分布往往偏离高斯模式,进而降低卡尔曼滤波器的性能;其二,卡尔曼滤波处理非线性系统的能力有限,尽管扩展卡尔曼滤波器(EKF)和无迹卡尔曼滤波器(UKF)试图克服这一局限,但在面对高度非线性系统时仍面临挑战;其三,卡尔曼滤波的递归特性依赖于精确的系统模型,任何模型的不准确性或不确定性都可能严重削弱其效果。另一方面,作为模型融合的替代方法,粒子滤波在处理非线性系统时相较于卡尔曼滤波具有一定优势。不过,其实现复杂度同样不容忽视:粒子滤波通过一组加权粒子近似系统状态分布,虽能解决更复杂的非线性问题和非高斯噪声环境,但通常需要大量计算资源——尤其是在高维空间中,需生成大量粒子才能准确描述系统状态分布,这会显著增加资源消耗。此外,粒子滤波还面临粒子退化问题:随着时间推移,粒子权重可能极度不均,多数权重趋近于零,仅少数保持较高数值,这种现象会降低估计精度并增加计算复杂度。因此,尽管粒子滤波在特定场景中展现出应用潜力,但其实现复杂度与资源消耗仍是限制其广泛应用的关键因素。

一款卓越的融合模型必须具备高精度、稳定性及可扩展性等关键特性。高精度能确保在处理大规模数据集时,准确反映现实世界的复杂性与不确定性;稳定性则能保证模型在不同条件下保持一致性能,避免因数据波动或异常值导致的显著偏差;可扩展性则关乎模型适应不断变化的应用场景、日益增长的数据量及算法更新的能力,需要通过灵活调整以保持与动态环境的契合。因此,多传感器协同数据分析的核心挑战在于:在降低计算复杂度和资源消耗的同时,实现精度与鲁棒性的平衡——这一亟待解决的紧迫问题亟需立即找到解决方案。

本文提出了一种基于点阵模型的多传感器协同数据分析方法,该方法被应用于研究惯性导航系统中的多传感器融合问题。该方法旨在克服现有技术的局限性,特别是在降低计算复杂度和提高精度方面。通过将数据空间划分为希尔伯特空间中的离散点,点阵模型能够通过这些点之间的相互作用和动态变化来捕捉数据的整体特征。该方法不仅降低了计算负担、提升了处理效率,同时在确保分析精度的同时保留了关键数据细节。此外,点阵模型具有出色的可扩展性,能够灵活适应不同规模和类型的数据集,从而为多传感器协同数据分析开创了新的研究路径。

2. 物理模型及所提出的算法

传感器采集的数据通常包含距离、角度、加速度等多种参数,这些参数共同构成数据集 $\{X_{ij}\}$ 。在该数据集中,行索引 i 与列索引 j 具有明确物理意义: i 代表距离、加速度等特定物理量, j 则对应物理量的维度。例如,在三维笛卡尔坐标系中,每个 i 值对应三个 j 值。传统多传感器数据融合方法中,不同传感器数据缺乏直接关联,导致动态系统数据处理复杂度较高,且数据呈现非线性特征。这种非线性会引发数据融合过程中的误差累积,进而影响分析结果的准确性与可靠性。为此,本文提出一种基于点阵模型的新型多传感器协同数据分析方法,该模型可关联不同空间位置的传感器数据,有效提升分析准确性。

点阵模型的理论基础源于固态物理学中的晶体理论。晶体是原子、分子或离子在三维空间周期性排列形成的固体材料,对于具有长程有序结构的晶体,点阵模型可将其表示为离散且相互连接的格点。借鉴这一核心思想,我们可将分布在不同空间位置的惯性传感器抽象为离散格点:格点的权值由对应传感器的输出数据和误差特性共同确定,格点之间的连接权重则由传感器间的空间相对位置关系计算得到,由此构建出适配多惯性传感器的协同点阵模型。晶体物理点阵的关键特征是周期性,但本文构建的点阵模型并不要求传感器严格遵循周期性分布,仅需各传感器的相对空间位置可标定即可——任意满足该条件的传感器分布均可完成模型构建,因此能够灵活适配不同应用场景。完成点阵模型构建后,系统的整体导航定位误差可表示为所有格点权值误差与格点间连接误差的加权和,通过点阵的对称性操作,即可分离并降低这些误差。与传统卡尔曼滤波和粒子滤波方法相比,该算法无需递归迭代计算,有效降低了计算复杂度;同时无需对噪声分布做预先假设,对非线性误差也具有更强的鲁棒性。实际计算中,还可根据系统对精度和效率的需求,调整格点连接范围,仅保留空间位置邻近传感器的相互作用项,进一步压缩计算量,适配不同性能的机载硬件平台。

适用于惯性导航的机械装置应用广泛,涵盖飞机、机器人、汽车、船舶等设备。本文以微型无人机为研究对象,旨在详细验证点阵模型对惯性导航系统的具体贡献。根据相关规范,我们可将无人机抽象为物理模型,如图1所示。

整个框架分为三个部分:(a)表示现实世界的状态;(b)描述由质量点表示各组件的骨架状态;(c)展示点阵模型的状态。在状态(c)中,我们建立了一个坐标系,将晶格点的位置标记为A1~A4和B1~B4,并在物体中心O周围对称地布置了两个传感器S1和S2。

此外,我们为点阵模型开发了一种高效的数据处理算法,用于数据融合与分析。该算法能够轻松将复杂数据分解为线性项和非线性项,从而获得准确可靠的分析结果。下文将阐述点阵模型算法的主要理论公式。

基于 $SU(N)$ 群在希尔伯特空间中的表示[16],通过选择合适的函数基可对数据集进行描述,具体如下所示。

$$\bar{P}\{X_{ij}\} = \sum_v k_v^{ij} X_v^{ij} \quad (1)$$




Figure 1. Schematic diagram for Lattice model. (a) The real state in the real world of UAV; (b) The skeleton state; (c) The Lattice model state

图 1. 点阵模型示意图。(a) 无人机真实世界中的实际状态；(b) 骨架状态；(c) 点阵模型状态

这是一个 $\bar{P}$ 线性算子，其中 ν 表示组合总数， k 表示比例参数。该函数 $\{X_\nu\}$ 被称为“基函数”。数据集 $\{X_{ij}\}$ 包含两部分：第一部分代表真实值(在理论物理学中称为本征态)；另一部分由系统误差、测量误差、各类噪声及其他因素引起，称为多重态。在正常情况下，这两部分相互混杂，难以分离。因此，数据处理的主要任务就是区分这两部分。根据上述定义，该数据集可表示为：

$$\{X_{ij}\} = \{X_{ij0}\} + \sum \{\Delta X_{ij}\} \quad (2)$$

其中 $\{X_{ij}\}$ 表示 i 个传感器产生的 j 个元素的数据集，即

$= \{X_{11}, X_{12}, \dots, X_{1m}, X_{21}, X_{22}, \dots, X_{2m}, \dots, X_{n1}, X_{n2}, \dots, X_{nm}\}$ ，其中 n 为传感器总数， m 为每个传感器收集的数据类型总数。 $\{X_{ij0}\}$ 是本征态， $\sum \{\Delta X_{ij}\}$ 是多重态。

我们采用通用的“高阶展开”方法对第二部分[17]进行展开。为简化运算，仅考虑一阶项；现假设：

$$\{X_{ij}\} = \{X_{ij0}\} + \{\Delta X_{ij}\} \quad (3)$$

为简化说明，我们选择两个传感器 S1 和 S2 来阐述后续公式的推导过程。我们将用“ $\{X_{ij}\}$ ， $\{Y_{ij}\}$ ”分别表示这些传感器采集的原始数据。

$$\{X_{ij}\} = \{X_{ij0}\} + \{\Delta X_{ij}\} \quad (4)$$

$$\{Y_{ij}\} = \{Y_{ij0}\} + \{\Delta Y_{ij}\} \quad (5)$$

上述公式仅将数据划分为本征态部分和多重态部分，但仍无法求得它们的解析值。然而，点阵模型

赋予这些数据空间对称性, 因此可运用线性空间(希尔伯特空间)群论对这些数据进行变换, 从而获得解析解。

在对称性类型中, 最常见的有两种对称性: 一种是中心对称性, 另一种是平移对称性。中心对称性(也称为中心反演)是最重要的对称操作之一, 通常具有高度对称性, 其特征在于物理定律在经历中心对称性变换后保持不变。利用中心对称性的特性, 我们对传感器 S1 和 S2 的数据进行了中心反演操作。由于本征态代表整个汽车的固有状态, 中心反演的结果表明这两个传感器的本征态是相同的。另一方面, 平移对称性揭示了不同空间位置之间的差异。因此, 当对 S1 和 S2 应用平移对称性时, 该对称性会影响它们的多重态。通过调整平移对称性的算法参数, 我们能够精确确定两个传感器多重态之间的差异。因此, 我们执行了中心对称性变换, 得到:

$$\vec{M}\{X_{ij0}\} = \{Y_{ij0}\} \quad (6)$$

$$\vec{L}\{\Delta X_{ij}\} = \{\Delta Y_{ij}\} \quad (7)$$

其中 $\vec{M}$ 是中心对称算子, $\vec{L}$ 是平移对称算子。

根据群代数理论, 并结合方程(1)~(7), 可求解零阶和一阶基函数。

$$\{X_{ij0}\} = \frac{\vec{L}\{X_{ij}\} - \{Y_{ij}\}}{\vec{L} - \vec{M}} \quad (8)$$

$$\{Y_{ij0}\} = \vec{M}\{X_{ij0}\} = \vec{M} \frac{\vec{L}\{X_{ij}\} - \{Y_{ij}\}}{\vec{L} - \vec{M}} \quad (9)$$

$$\{\Delta X_{ij}\} = \frac{\vec{M}\{X_{ij}\} - \{Y_{ij}\}}{\vec{M} - \vec{L}} \quad (10)$$

$$\{\Delta Y_{ij}\} = \vec{L}\{\Delta X_{ij}\} = \vec{L} \frac{\vec{M}\{X_{ij}\} - \{Y_{ij}\}}{\vec{M} - \vec{L}} \quad (11)$$

$$\{X_{ij}\} = \frac{\vec{L}\{X_{ij}\} - \{Y_{ij}\}}{\vec{L} - \vec{M}} + \frac{\vec{M}\{X_{ij}\} - \{Y_{ij}\}}{\vec{M} - \vec{L}} \quad (12)$$

$$\{Y_{ji}\} = \vec{M} \frac{\vec{L}\{X_{ij}\} - \{Y_{ij}\}}{\vec{L} - \vec{M}} + \vec{L} \frac{\vec{M}\{X_{ij}\} - \{Y_{ij}\}}{\vec{M} - \vec{L}} \quad (13)$$

我们采用平均值法对两个传感器的数据集进行整合, 最终得到如下所示的零阶项基函数:

$$\{D_0\} = \frac{\{X_{ij0}\} + \{Y_{ij0}\}}{2} \quad (14)$$

对于 N 个传感器而言:

$$\{D_0\} = \frac{\sum_N D_{ij0N}}{N} \quad (15)$$

$\{D_0\}$ 是 N 个传感器的最终本征状态结果, 它反映了机载雷达检测的真实值, 并完全消除了所有其他干扰波的影响。

3. 实验和讨论

如图 2 所示, 该无人机配备了 1~4 个惯性传感器, 这些传感器分布在无人机的不同空间位置(详见图

2(b))。任务要求无人机从起点(原点 $O [0, 0, 0]$)飞往空中目标点 $P [x, y, z]$ 。此外, 我们建立了地面坐标系 O -xyz 和机体坐标系 O' -x'y'z'。图中 P' 表示真实位置, 因此 PP' 的距离反映了定位精度。




Figure 2. Schematic diagram of UAV flight scene in the experiment. (a) Coordinate system and target position; (b) Schematic diagram of Lattice model

图 2. 实验中无人机飞行场景的示意图。(a) 坐标系及目标位置; (b) 点阵模型示意图

如引言所述, 卡尔曼滤波是多传感器融合中的关键算法。为验证基于点阵的多传感器数据融合方法的有效性, 我们以卡尔曼滤波作为基准。由于无人机系统可近似为线性系统, 实验中采用标准卡尔曼滤波器。相关参数设置如下: 时间域设置为离散时间模式, 卡尔曼滤波器状态向量定义如下: $A: [0.9, 0, 0; 0, 0.9, 0; 0, 0, 0.9]$; $C: [1, 0, 0; 0, 1, 0; 0, 0, 1]$ 。由于未引入额外输入向量, 控制输入矩阵 B 和 D 保持未指定状态。过程噪声协方差矩阵 Q 设为 $[0.5, 0.5, 0.5]$, 观测噪声协方差矩阵 R 设为 $[0.1, 0.1, 0.1]$ 。N 取值为 0。初始状态为 $[0, 0, 0]$ 。需要强调的是, 这些参数是经过多轮测试后确定的相对最优参数组合。

众所周知, Matlab 软件是算法验证的有效且可靠的工具。因此, 我们采用 Matlab 来模拟多传感器惯性导航系统。整个项目框架如图 3 所示。




Figure 3. The Matlab-based simulation framework for UAV inertial navigation

图 3. 基于 Matlab 的无人机惯性导航仿真框架

整个仿真平台由四个关键组件构成: 外部指令模块、飞行控制模块、六自由度(6DOF)估计器以及惯性测量单元(IMU)模块。值得注意的是, 飞行控制模块采用了无人机广泛用于姿态预测的 PID 算法。仿真流程如下:

首先,在外部指令模块中,操作员通过“cmd”端口向无人机发出飞行指令,随后无人机将自动执行飞行任务。其次,在飞行控制模块中,目标位置会被转换为无人机飞行角度及三个地理坐标力“ F'_{xyz} ”;随后利用PID算法计算出机体坐标系扭矩“ M_{xyz} ”;最后,地理坐标系力“ F'_{xyz} ”会被转换为机体坐标系力“ F_{xyz} ”,再传输至电机执行导航任务。第三,在6自由度估计模块中,通过Simulink固件中的6DOF模块,以“ F_{xyz} ”和“ M_{xyz} ”为输入,可求解包括位移、欧拉角、速度、角速度和加速度在内的飞行变量,所得姿态估计数据即为输出结果。第四,惯性测量单元(IMU)在本系统中起关键作用,承担多传感器融合的核心任务:多传感器系统的第一个子模块涵盖传感器布局、原始数据处理、信息融合算法及数据整合输出等功能;第二个子模块为实时姿态计算模块,可将加速度和角速度实时转换为位移、速度、欧拉角等姿态数据,这些实时数据随后作为输出反馈至飞行控制模块,形成闭环控制。

在仿真实验中,为了更准确地验证各类算法的性能,我们构建了一个理想的飞行环境。在此设置下,无人机计划从起点起飞并悬停在指定空中位置P,从而能够测量惯性导航系统(INS)的性能。采用这种简化方案是因为它能显著降低飞行过程中环境因素(如气压波动、风速变化和温度差异)带来的负面影响。此外,该方法也不会干扰我们对算法惯性导航系统性能的研究。由于惯性传感器通过整合加速度计的测量值来获取位置信息,这一过程主要取决于时间因素,而悬停状态和飞行状态对其影响甚微。

3.1. 模拟场景 I: 惯性传感器数量对导航性能的影响

首先,我们研究传感器数量如何影响惯性导航性能。在此场景中,目的地P位于坐标P [10, 10, 10]米处,飞行时长为10分钟。加速度计和陀螺仪的误差分别为 $a\text{-bias} = 0.2 \text{ m/s}^2$ 、 $w\text{-bias} = 0.4 \text{ rad/s}$ 。

实验结果如图4和表1所示。结果表明,通过多个惯性测量单元(IMU)传感器的协同工作,点阵模型算法实现了0.10~0.14米的定位精度,显著优于单独使用卡尔曼滤波算法获得的12.39~13.99米精度。此外,随着传感器数量的增加,定位精度未出现明显波动,这表明点阵模型算法具有出色的鲁棒性和稳定性。当使用两个和四个IMU传感器时,定位精度均达到0.10米的最佳水平,进一步证实了传感器数量和布局对点阵模型算法性能的关键影响。鉴于两个传感器即可实现高性能惯性导航,考虑到成本效益,




Figure 4. Influence of the number of inertial sensors on the Lattice model

图4. 不同4惯性传感器数量对点阵模型的影响

Table 1. Influence of the number of inertial sensors on the Lattice model algorithm**表 1.** 不同惯性传感器数量对点阵模型算法的影响

IMU 编号	位置精度(±米)	
	卡尔曼滤波	点阵模型
1	12.39	12.39
2	13.99	0.10
3	12.39	0.14
4	12.39	0.10

后续实验将主要聚焦于两个惯性传感器的协同工作。需要强调的是，在 600 秒的时间范围内，点阵模型的精度范围为 0.10~0.14 米，这种波动主要源于随机白噪声而非恒定漂移。由于随机白噪声的特性，误差不会像恒定漂移那样随时间累积。在仿真实验中，随机白噪声会根据采样时间周期性重置，以模拟真实环境。通过定期重置随机白噪声，我们可以更准确地评估该点阵模型算法在应对真实传感器噪声时的抗干扰能力和误差抑制效果。

3.2. 模拟场景 II：传感器质量对导航性能的影响

在此，我们将探讨传感器的质量如何影响导航性能。实验中使用了两个传感器，飞行目的地坐标为 P [10, 10, 10]米，飞行时间为 $t = 600$ 秒。在商用产品中，传感器的质量直接影响成本，因此成为工业应用中的关键因素。如前所述，商用 MPU9250 传感器测量范围的 1%被用作角速度测量误差(2000 rad/s)，而重力加速度 g 的 2%被用作加速度测量误差。因此，加速度测量偏差范围为 $a\text{-bias} = 0 \sim 0.2 \text{ m/s}^2$ ，而角速度测量偏差范围为 $w\text{-bias} = 0 \sim 0.4 \text{ rad/s}$ 。惯性传感器主要依靠加速度计和陀螺仪来测量加速度、角速度等物理量。因此，加速度和角速度测量值的偏差幅度可用于评估传感器的质量。在商用产品中，传感器的质量直接影响成本，这使其成为工业应用中的关键因素。实验结果如图 5 和表 2 所示。结果表明，


**Figure 5.** The relationship between the quality of sensors and navigation accuracy**图 5.** 传感器质量与导航精度之间的关系

Table 2. The relationship between the quality of sensors and navigation accuracy
表 2. 传感器质量与导航精度之间的关系

加速度测量偏差(a-bias), m/s ²	角速度测量偏差(w-bias), rad/s	位置精度(±米)	
		卡尔曼滤波	点阵模型
0	0	0	0
0.1	0	0.03	0.05
0.2	0	0.06	0.10
0	0.2	0.34	0
0	0.4	1.13	0
0.1	0.2	1.69	0.05
0.2	0.4	7.25	0.10

在处理加速度测量误差方面，点阵模型的表现逊于卡尔曼滤波器；但在处理角速度测量误差时，其性能显著优于卡尔曼滤波器。当加速度和角速度测量均存在误差时，卡尔曼滤波器的定位精度为 1.69~7.25 米，而点阵模型可达到 0.05~0.10 米，比卡尔曼滤波器高出近两个数量级。

实验数据表明，点阵模型的定位精度与鲁棒性均显著优于传统卡尔曼滤波器：前者定位精度稳定在 0.10 米，而后者精度范围为 1.60~5.89 米，振荡幅度最高达 4.29 米，且在动态目标突变场景下易出现发散。点阵模型之所以能取得这一优异实验结果，核心在于它不仅可有效揭示数据间的相关性，还能借助点群的对称变换实现高效数据分析。

由于无人机多传感器系统与点阵模型所类比的晶体在基础结构上存在根本性差异，这种方法在定位导航领域的应用较为罕见。关键差异在于晶体具有基于基本胞元的长程有序性，而多传感器系统并不具备这一特性。因此，将晶体物理学中的点群理论应用于多传感器融合问题时，必须采用近似方法——这一点体现在点阵模型的算法公式中，例如公式(1)和(3)分别采用了希尔伯特空间近似和一阶泰勒近似。在通过这些近似方法校准传感器数据后，再应用晶体物理学中常用的对称操作关联不同传感器数据(如公式(6)~(7)所示)。本文仅利用点群中的中心反演对称性和平移对称性验证了点阵模型的有效性；实际上对称性类型多种多样，这些都将成为未来研究的重点方向。

4. 结论

为解决单惯性导航系统中锚点导致的空间漂移问题，人们通常采用多传感器系统，通过不同传感器之间的相互锚定来有效抑制空间漂移。然而，无论是基于信息还是基于模型的传统多传感器融合技术，均未能显著提升惯性导航精度或降低数据分析复杂度。这表明传统方法在处理空间锚定数据时存在明显局限性。本文提出了一种基于物理类比的、有前景的探索性方法，该方法类比晶体物理的晶体点阵结构，将晶体点阵的对称性质应用于多传感器数据处理，成功实现了不同传感器误差的分离与抑制。理论推导与实验结果均表明，相较于传统卡尔曼滤波方法，本文所提出的点阵模型在惯性导航定位中具备更高的定位精度与更强的鲁棒性，且计算复杂度低，可适配不同性能的机载硬件平台。同时，本文仅采用了中心反演对称与平移对称两种基础对称操作便取得了显著效果，说明点阵模型框架仍有较大的挖掘空间，后续可探索引入更多对称操作进一步提升导航性能，为多传感器惯性导航领域提供新的可行技术路径。

仿真实验表明，传感器数量对该点阵模型的定位精度具有显著影响：单个传感器条件下，定位精度为 12.39 米；而采用两个或四个传感器时，精度均可提升至 0.10 米。传感器质量同样会影响定位精度：当传感器测量误差为零时，定位精度趋近于零；随着加速度计与陀螺仪测量误差的增大，定位精度会相

应降低。

总之，点阵模型在多传感器融合的空间锚定任务中优势显著，性能较广泛应用的卡尔曼滤波技术高出一个数量级。从实际应用角度看，该模型为惯性导航系统提供了高效稳定的多传感器融合解决方案。在复杂动态的实际环境中运行时，尽管其定位精度可能随飞行时间延长而下降，但下降幅度相对可控，整体仍能保持较高精度。与传统卡尔曼滤波技术相比，点阵模型在处理多传感器空间锚定数据时展现出更强的适应性与更高的精度，这对于提升无人机长时间飞行的稳定性和可靠性至关重要。此外，点阵模型的创新不仅在于将晶体物理学概念引入惯性导航领域，更在于通过点群对称操作实现了多传感器数据的有效关联与冗余信息消除。这一创新方法为惯性导航系统的多传感器融合提供了新的视角与方法论，有望推动该领域的进一步技术进步。随着无人机应用范围的扩大和性能要求的提高，点阵模型方法预计将在此领域发挥重要作用，为精确导航和稳定飞行提供可靠支持。与此同时，针对点阵模型中其他类型对称性的研究，以及更精确近似方法的探索，将成为未来研究的重点方向。

基金项目

本研究由福建省自然科学基金(项目编号: 2023H0022、2023J011100、2025J011101、2025J011106、2025J011095、2025J011097)及福建省技术创新重点攻关与产业化项目(项目编号: 2024XQ016)资助。

参考文献

- [1] Liu, Z., Xiao, G., Liu, H. and Wei, H. (2022) Multi-Sensor Measurement and Data Fusion. *IEEE Instrumentation & Measurement Magazine*, **25**, 28-36. <https://doi.org/10.1109/mim.2022.9693406>
- [2] Lyu, X., Hu, B., Wang, Z., Gao, D., Li, K. and Chang, L. (2022) A SINS/GNSS/VDM Integrated Navigation Fault-Tolerant Mechanism Based on Adaptive Information Sharing Factor. *IEEE Transactions on Instrumentation and Measurement*, **71**, 1-13. <https://doi.org/10.1109/tim.2022.3147335>
- [3] Rachwał, A., Karczmarek, P. and Rachwał, A. (2025) Smooth Ordered Weighted Averaging Operators. *Information Sciences*, **686**, Article ID: 121343. <https://doi.org/10.1016/j.ins.2024.121343>
- [4] Deng, X., Yang, H., Liu, Y., Wang, C. and Sun, H. (2025) Complex-Valued Neural Networks for Signal Classification in Sensor Networks Based on Multidomain Feature Fusion. *IEEE Sensors Journal*, **25**, 9034-9044. <https://doi.org/10.1109/jsen.2025.3525674>
- [5] Zhang, Y. and Chen, W. (2023) Decision-Level Information Fusion Powered Human Pose Estimation. *Applied Intelligence*, **53**, 2161-2172. <https://doi.org/10.1007/s10489-022-03623-z>
- [6] Zeng, G., Chen, S., Wu, H. and Yang, M. (2024) Continuous-Discrete Extended Kalman Filtering Based on the Neural Ordinary Differential Equations Method. *Engineering Applications of Artificial Intelligence*, **133**, Article ID: 108611. <https://doi.org/10.1016/j.engappai.2024.108611>
- [7] Ivánek, M., Ďuran, I., Entler, S., Torres, A., Pironti, A., Quercia, A., *et al.* (2025) Data Fusion of Magnetic Coils and Hall Sensors Using Kalman Filtering. *Fusion Engineering and Design*, **217**, Article ID: 115180. <https://doi.org/10.1016/j.fusengdes.2025.115180>
- [8] You, X., Xiao, K. and Wang, G. (2025) A Static Event-Triggered Background-Impulse Kalman Filter for Wireless Sensor Networks with Non-Gaussian Measurement Noise. *Information Fusion*, **118**, Article ID: 102955. <https://doi.org/10.1016/j.inffus.2025.102955>
- [9] Jung, R., Luft, L. and Weiss, S. (2025) Isolated Kalman Filtering: Theory and Decoupled Estimator Design. *Autonomous Robots*, **49**, Article No. 7. <https://doi.org/10.1007/s10514-025-10191-x>
- [10] Chen, X., Kang, J. and Yau, S.S.T. (2024) Time-Varying Feedback Particle Filter. *Automatica*, **167**, Article ID: 111740. <https://doi.org/10.1016/j.automatica.2024.111740>
- [11] Esedoğlu, S., Guo, J. and Li, D. (2024) On Median Filters for Motion by Mean Curvature. *Mathematics of Computation*, **93**, 2679-2710. <https://doi.org/10.1090/mcom/3940>
- [12] Lyu, X., Meng, Z., Li, C., Cai, Z., Huang, Y., Li, X., *et al.* (2024) A Dual Adaptive Unscented Kalman Filter Algorithm for Sins-Based Integrated Navigation System. *Journal of Systems Engineering and Electronics*, **35**, 732-740. <https://doi.org/10.23919/jsee.2024.000060>
- [13] Wang, D., Wang, B., Huang, H., Yao, Y. and Xu, X. (2023) Robust Filter Method for SINS/DVL/USBL Tight Integrated

-
- Navigation System. *IEEE Sensors Journal*, **23**, 10912-10923. <https://doi.org/10.1109/jsen.2023.3264755>
- [14] Wang, D., Wang, B., Huang, H. and Zhang, H. (2023) A Multisensor Fusion Method Based on Strict Velocity for Underwater Navigation System. *IEEE Sensors Journal*, **23**, 18587-18598. <https://doi.org/10.1109/jsen.2023.3287600>
- [15] Yu, Y., Chen, R., Chen, L., Li, W., Wu, Y. and Zhou, H. (2021) A Robust Seamless Localization Framework Based on Wi-Fi FTM/GNSS and Built-In Sensors. *IEEE Communications Letters*, **25**, 2226-2230. <https://doi.org/10.1109/lcomm.2021.3071412>
- [16] Ciavarella, A.N. and Bauer, C.W. (2024) Quantum Simulation of SU(3) Lattice Yang-Mills Theory at Leading Order in Large- N_c Expansion. *Physical Review Letters*, **133**, Article ID: 111901. <https://doi.org/10.1103/physrevlett.133.111901>
- [17] Mommeyer, C., Lombaert, G., Schevenels, M. and Sigmund, O. (2024) Taylor Series Approximations for Faster Robust Topology Optimization. *Structural and Multidisciplinary Optimization*, **67**, Article No. 181. <https://doi.org/10.1007/s00158-024-03890-z>