

针对风力扰动下无人机状态估计综述

石钧化

(东北大学机械工程与自动化学院 沈阳 110819)

摘要:无人机的自主飞行性能在物流、巡检等实际应用中深受风力扰动的制约。传统基于滤波的方法依赖于精确的动力学模型与噪声假设,在面对复杂时变的风力扰动时,因存在未建模动态而导致估计性能显著退化。近年来,数据驱动与混合方法展现出巨大潜力。本文旨在综述风力扰动下无人机状态估计的研究进展,分析传统卡尔曼滤波系列方法在应对风扰中的局限性,同时探讨数据驱动方法在风扰建模与补偿方面的优势,并聚焦于物理信息神经网络及模型补偿学习等混合范式,为实现高精度、强泛化的抗风扰状态估计提供了有效路径。最后,本文总结了当前技术面临的挑战,并对未来研究方向进行展望,特别探讨了大型语言模型在增强状态估计系统智能性与可解释性方面的潜在价值。

关键词:无人机;状态估计;风力扰动;深度学习;物理信息神经网络;传感器融合

中图分类号: TP273+.2; V279+.3; TN929.5 **文献标识码:** A **国家标准学科分类代码:** 510.8010;120.3030

Review of drone state estimation under wind disturbances

Shi Junhua

(School of Mechanical Engineering and Automation, Northeastern University, Shenyang 110819, China)

Abstract: The autonomous flight performance of unmanned aerial vehicles is significantly constrained by wind disturbances in practical applications such as logistics and inspection. Traditional filter-based methods rely on precise dynamic models and noise assumptions. When confronted with complex, time-varying wind disturbances, these approaches suffer from significant degradation in estimation performance due to unmodeled dynamics. In recent years, data-driven and hybrid methods have demonstrated tremendous potential. This paper aims to review research progress in UAV state estimation under wind disturbances, analyze the limitations of traditional Kalman filter-based methods in addressing wind disturbances, and explore the advantages of data-driven approaches in modeling and compensating for wind disturbances. It focuses on hybrid paradigms such as physically informed neural networks and model compensation learning, providing effective pathways for achieving high-precision, robust and generalized wind-resistant state estimation. Finally, this paper summarizes current technical challenges and outlines future research directions, particularly exploring the potential value of large language models in enhancing the intelligence and interpretability of state estimation systems.

Keywords: UAV; state estimation; wind disturbance; deep learning; physically informed neural network; sensor fusion

0 引言

无人机技术正以前所未有的速度演进,深刻改变着众多领域。嵌入式飞控算力的跃升为复杂实时算法奠定基础^[1];多光谱成像、激光雷达等先进载荷日益普及^[2],大幅提升了复杂环境下的定位精度与适应性;精准农业中实现高效病虫害监测与变量作业^[3];物流运输破解“最后1公里”难题^[4];军事领域则在侦察监视、精确打击、电子对抗及集群作战方面扮演颠覆性角色^[5]。然而,迈向大规模高可

靠应用仍面临严峻挑战:电池续航瓶颈制约长航时任务;复杂动态未知环境(如密集城区、强干扰)对自主系统的鲁棒性、安全性提出更高要求等。未来,无人机将向智能化、集群化、网联化深度演进^[6]。在此进程中,高精度、强鲁棒的状态估计技术作为保障无人机可靠运行的基石^[7],其重要性日益凸显。

高精度状态估计是无人机实现自主飞行的核心前提,其通过实时解算位置、速度、姿态等关键状态量,为飞行控制、环境感知与任务决策提供重要的信息基础^[8]。在物流

配送、灾害救援、集群协同及精准农业等典型应用中,状态估计的精度与鲁棒性直接决定了系统整体性能与任务可靠性。此外,在风力发电机叶片巡检等工业领域,无人机也承担着重要的检测任务,其获取的图像质量直接影响缺陷识别效果,这进一步凸显了稳定、可靠的状态估计是完成高级别任务的基础^[9]。无人机的闭环控制系统可简要描述为:状态估计模块根据传感器观测信息解算当前状态;控制器基于期望状态与估计状态的偏差,计算并输出控制指令;执行机构驱动无人机完成飞行。在实际环境中,风力扰动不仅会直接破坏无人机的动力学平衡,导致其状态发生剧烈变化,更会污染惯性测量单元(inertial measurement unit, IMU)、空速计等传感器的观测数据^[10]。与无人机在其他巡检任务(如风机叶片检测)中遇到的问题类似,宋晔等^[11]在其综述中指出,天气条件、光照变化以及被检目标自身(如风机型号、叶片材料)的显著差异,是导致视觉检测模型泛化能力不足、难以跨场景应用的核心瓶颈。这意味着,状态估计器若无法有效抵抗风扰,将为控制器提供错误的状态信息,进而导致控制性能下降甚至失稳,形成恶性循环。因此,发展能够在风力扰动下保持精确、稳健的状态估计方法,具有重要的理论价值与工程意义。

面对风力扰动所带来的强非线性、时变性与不确定性挑战,传统的基于模型的状态估计方法(如卡尔曼滤波及其扩展变体)存在固有局限^[12]。其性能高度依赖于精确的无人机动力学模型与准确的噪声统计假设,而风扰恰恰引入了难以精确建模的未建模动力学与非高斯噪声,导致此类方法在复杂风场中估计精度急剧退化。

近年来,以深度学习为代表的驱动方法为破解这一瓶颈提供了新范式。此类方法不依赖于显式的风扰模型,而是直接从数据中学习风扰的动态特征与统计规律,展现出强大的非线性拟合与环境自适应能力,为克服传统方法局限提供了新的思路^[13]。其中,能够融合物理先验与数据驱动的混合方法,尤其是物理信息神经网络(physics-informed neural networks, PINNs),已成为最具潜力的研究方向之一^[14]。本文旨在系统综述面向风力扰动挑战的无人机状态估计方法研究进展。

本文系统梳理了从传统滤波到数据驱动乃至混合方法的演进脉络,辨析了各类方法在应对风扰时的优势与局限;重点分析了数据驱动方法(如高斯过程、循环神经网络)在风扰建模与补偿中的机理,并深入探讨了物理信息神经网络等混合范式如何通过融合物理模型与深度学习来提升估计器的泛化能力与物理一致性;基于对当前技术挑战的分析,展望了未来重要研究方向,特别探讨了大型语言模型(large language model, LLM)在提升状态估计系统智能性方面的潜在价值。

1 模型驱动方法

1.1 无人机动力学方程

无人机状态估计的理论基础是六自由度刚体动力学模

型,核心由非线性微分方程描述:

$$\dot{\mathbf{x}}(t) = \mathbf{f}(\mathbf{x}(t), \mathbf{u}(t)) \quad (1)$$

其中,状态向量 $\mathbf{x} = [\mathbf{p}, \mathbf{q}, \mathbf{v}, \boldsymbol{\omega}_B]^\top$ 包含位置 $\mathbf{p}$ 、姿态四元数 $\mathbf{q}$ 、线速度 $\mathbf{v}$ 和机体角速度 $\boldsymbol{\omega}_B$; 控制输入 $\mathbf{u} = [F_1, F_2, F_3, F_4]^\top$ 为旋翼升力。该方程融合了牛顿-欧拉平动/转动动力学及姿态/位置运动学关系,如图 1 所示。旋翼作用体现为机体坐标系下的总推力 $\mathbf{F}_B$ 与力矩 $\boldsymbol{\tau}_B$:

$$\mathbf{F}_B = \begin{bmatrix} 0 \\ 0 \\ \sum F_i \end{bmatrix} \quad (2)$$

$$\boldsymbol{\tau}_B = \begin{bmatrix} L/\sqrt{2}(-F_1 - F_2 + F_3 + F_4) \\ L/\sqrt{2}(-F_1 + F_2 + F_3 - F_4) \\ k_{\text{drag}}(-F_1 + F_2 - F_3 + F_4) \end{bmatrix} \quad (3)$$




图 1 四旋翼无人机配置示意图

Fig. 1 Diagram of the quadrotor configuration

1.2 卡尔曼滤波及其扩展算法

为从带噪声的传感器观测中估计状态,以卡尔曼滤波(Kalman filter, KF)为核心的一系列递归估计算法构成了模型驱动方法的基础。传统状态估计方法以卡尔曼滤波为代表,建立在显式物理模型与概率框架基础上,具有结构清晰、计算效率高、物理可解释性强等特点,在线性高斯系统中接近最优估计^[15]。KF 在无人机 GPS/INS 组合导航等线性场景中得到了成功应用,例如王均晖等^[16]系统对比了直接法与间接法滤波的性能,验证了间接法在提升精度和稳定性方面的优势,为 KF 在工程中的应用提供了重要参考。但其要求系统动态模型和观测模型均为线性,且过程噪声与观测噪声均为高斯白噪声,这与无人机复杂的非线性动力学严重不符,故在实战中应用有限。

为克服非线性问题,扩展卡尔曼滤波(extended Kalman filter, EKF)通过一阶泰勒展开在估计点处对非线性系统进行局部线性化,从而将 KF 框架推广至轻度非线性系统^[14]。EKF 在无人机姿态估计等领域取得了广泛成果,例如蒋宗池等^[17]设计了模糊自适应 EKF 算法,通过模糊逻辑动态调整噪声协方差,显著提升了四旋翼无人机在大机动飞行条件下的姿态估计鲁棒性。尽管如此,EKF 对强非线性系统的近似误差较大,且雅可比矩阵的计算复杂,容易引入数值不稳定^[18]。

为进一步提高非线性估计性能,无迹卡尔曼滤波

(unscented Kalman filter, UKF)利用无迹变换(unscented transform)选取一组确定性采样点(Sigma 点)来精确捕获状态的均值和协方差传播,避免了雅可比矩阵的计算,适用于中度非线性系统^[19]。UKF 在视觉惯性里程计(visual-inertial odometry, VIO)等应用中显示出比 EKF 更高的估计精度和稳定性。粒子滤波(particle filter, PF)则采用蒙特卡洛采样思路,使用一组带权粒子来近似状态的后验概率分布,理论上可以处理任意形式的非线性和非高斯噪声^[20],在同时定位与地图构建(simultaneous localization and mapping, SLAM)等强非线性问题中潜力巨大,但其计算负担随粒子数量增加而急剧增长,难以满足无人机的高实时性要求^[21]。

进一步,容积卡尔曼滤波(cubature Kalman filter, CKF)基于球形径向容积准则,采用 1 组数值积分点来逼近状态的后验均值和协方差,在处理非线性系统时具有更高的数值精度和稳定性。而 PF 采用蒙特卡洛采样思路,能够处理任意非线性和非高斯噪声系统,理论上非常适合建模复杂的风力扰动,但其计算复杂度随粒子数增加而急剧增长,难以满足无人机高实时性的要求^[22]。在面对风扰时,自适应卡尔曼滤波(adaptive Kalman filter, AKF)作为一种重要策略,通过在线实时监测滤波器的创新序列(残差),动态调整过程噪声协方差矩阵 Q 和观测噪声协方差矩阵 R 。然而,这些方法的共性是试图将风扰的影响吸纳到过程噪声协方差中,本质上是将风扰视为不相关的白噪声,而实际风扰是具有时空相关性的有色噪声,此种模型失配必然导致估计精度下降。综上所述,尽管经典滤波方法体系成熟,但其在面对风扰时存在根本性局限:它们都是“被动”的,依赖于预设的模型,只能通过调整噪声参数来“掩盖”模型误差,而无法主动地识别、学习或补偿风力扰动本身的结构化动态特性。

1.3 方法性能对比与局限性分析

尽管基于模型驱动的经典滤波方法在状态估计领域发展成熟且具有计算高效、物理意义明确等优点,但其在面对风力扰动这一典型不确定因素时,存在一系列固有的局限性。为系统对比不同状态估计方法的特性,表 1 梳理了代表性方法的性能指标与适用场景。

表 1 模型驱动方法对比

Table 1 Comparison of model-driven approaches

方法	估计精度	计算效率	抗风扰能力	参考文献
KF	低	高	差	[23-24]
EKF	中	中	中	[25-26]
UKF	高	中	良	[27-29]
PF	高	低	优	[30-31]
CKF	高	中	良	[32-34]
AKF	中~高	中	良~优	[35-36]

可以看出,不同方法在应对风扰挑战时表现出显著差

异:KF 仅限于理想线性系统,几乎无法应对风扰;EKF 通过线性化处理可适应轻度非线性场景,但在强风扰下线性化误差显著;UKF 和 CKF 采用更精确的非线性处理机制,对中度风扰具有更好的鲁棒性,但计算成本相应增加;PF 虽然理论上能够处理任意非线性和非高斯问题,但巨大的计算负担使其难以满足实时性要求;自适应滤波方法(如 AKF)通过在线调整噪声参数,展现出更好的环境适应性,是传统框架下提升抗风扰能力的有效方案。然而,所有这些方法的共性局限在于其“被动”的处理方式——它们依赖于精确的模型假设,只能通过调整噪声参数来间接应对风扰,而无法主动学习和补偿风力扰动的结构化动态特性。这种根本性的模型失配问题促使研究者转向更加强化和灵活的数据驱动与混合估计方法。

2 数据驱动方法与机器学习

2.1 从机器学习到深度学习

数据驱动方法的核心思想在于利用数据的统计规律构建从观测到状态的映射关系,为解决风力扰动问题提供了新的解决方案。这类方法的核心优势在于无需预先建立精确的风扰数学模型,而是通过数据驱动的方式主动学习和补偿风扰影响。在机器学习方法中,高斯过程回归(Gaussian process regression, GPR)作为贝叶斯非参数方法的代表,特别适用于建模具有高度不确定性的风扰动力学;它不仅能够提供状态的点估计,还能给出预测结果的不确定性度量(置信区间),这对评估风扰影响的严重程度至关重要。例如,GPR 可直接从无人机状态和控制输入中学习并实时估计作用于机体的风力和力矩,进而将该估计值前馈至控制器进行补偿,显著增强系统抗干扰能力^[37]。与此同时,最小二乘等参数估计方法也为风扰建模提供了实用途径,这些方法可以通过在线辨识技术实时估计风扰的参数化模型,为控制系统提供适应性的补偿策略^[38]。深度神经网络凭借其强大的非线性拟合和自动特征提取能力,已成为处理风扰问题的重要工具。这类方法不依赖于精确的物理方程,能够从大规模数据中自动学习系统动态特征和噪声统计规律,尤其擅长处理高维、非线性和多模态融合问题,在复杂环境下展现出优异的泛化能力和鲁棒性^[39]。曾亚琳^[40]指出,深度神经网络能够有效提取复杂环境中的特征信息,提升无人机环境感知能力,为状态估计提供坚实数据基础;朱文山等^[41]发现深度学习方法在航天器姿态估计中优于传统滤波;江灵杰^[42]强调,深度学习在处理高维非线性数据时表现优异,克服传统滤波方法的局限,显著提高估计精度和鲁棒性;Zhao 等^[43]证明深度学习在电池状态估计中的优势;雷毅飞等^[44]利用深度强化学习优化多无人机机动策略,展示了其在动态环境下实时状态估计与决策支持中的潜力。宋宏冰等^[45]研究表明,深度学习结合状态估计方法可实现复杂系统的准确预测和健康管理,为无人机故障诊断提供理论借鉴。深度学习凭借强大特征提取和

非线性建模能力,推动无人机状态估计技术迈向更高精度与实时性。其中,多层感知机(multi-layer perceptron, MLP)可构建从历史传感器数据(如 IMU、空速计)到当前状态或风扰力的端到端映射模型,实现高效推理;而循环神经网络(尤其是长短期记忆网络(long-short term memory, LSTM)、门控循环单元(gated recurrent unit, GRU)等)因其卓越的时序动态建模能力显得尤为关键——风扰作为典型的连续时序过程,其长期依赖关系和动态演化模式可通过这些门控机制有效捕捉,从而实现对风扰趋势的预测而不仅是瞬时响应,为控制系统提供宝贵的超前补偿信息。

在具体应用层面,深度学习已被成功应用于无人机状态估计的多个环节。在故障检测方面,管宽蛟等^[46]通过轻量化改进 YOLOv4 与 DeepLabV3+模型,实现了对航拍红外图像中光伏板热斑的快速识别与分割,展示了深度学习在无人机巡检任务中的高效感知能力。在深度学习的视觉算法方面,郝晋渊等^[47]针对“低慢小”无人机入侵目标,改进了 YOLO 检测算法,有效提升了复杂背景下的检测精度与模型效率;秦栋等^[48]则构建了基于 PLCnext 平台的无人机交通监控系统,通过算法优化实现了对地面车辆的实时高精度检测。这些研究为无人机在动态环境下获取可靠观测数据提供了重要技术支撑。

2.2 数据驱动方法的优势与挑战

数据驱动方法为风扰下的状态估计带来了范式转变,其核心价值在于能够从数据中主动学习并补偿风扰动力学的未建模部分,而非被动地将其视为噪声处理。首先,该类方法展现出强大的非线性拟合能力,深度神经网络能够通过多层非线性变换精确刻画风扰与系统状态间复杂的映射关系,无需进行任何线性化近似,从而避免了传统方法因线性化误差导致的性能下降问题^[49]。此外,数据驱动方法具有显著的环境自适应潜力,通过在线学习或迁移学习机制,模型能够依据实时传感数据动态调整自身参数,适应不同地理环境、气象条件下风场特性的变化,这一特性对于在复杂多变环境中长期运行的无人机系统尤为重要^[50]。

然而,这些优势的实现也面临着诸多挑战。以深度学习为例,尽管深度学习在状态估计中展现出显著潜力,实际应用仍面临诸多挑战。首先,深度模型对训练数据的数据量与质量极为敏感,缺乏多样性、代表性或标注质量较低的数据集会严重制约模型的泛化能力,这一点在柳杰^[51]的研究中已被明确强调。郑泛舟^[52]进一步指出,深度强化学习模型在复杂动态环境中的泛化能力有限,易受环境噪声和传感器误差干扰,导致估计结果波动较大、稳定性不足。其次,“黑箱”特性仍是深度学习在安全攸关系统中应用的主要障碍。模型决策过程缺乏透明性与可解释性,不仅为系统可靠性评估带来困难,也限制了其在无人机等高可靠性要求场景中的部署,赵慧婷^[53]因此呼吁引入可解释人工智能(explainable artificial intelligence, XAI)方法以增强模型的可信度。此外,多模态融合不充分也是当前研究的显著

短板。正如刘主光等^[54]指出,现有研究多聚焦于单一传感器数据,未能充分挖掘视觉、IMU、LiDAR 等异源传感器之间的互补潜力,从而限制了状态估计系统在复杂环境中的鲁棒性与准确性。同时,大多数研究仍基于理想数据集或仿真环境,对真实场景中常见的传感器异步、数据丢包、突发故障等问题的处理机制研究相对薄弱。更为关键的是,如何将物理先验有效嵌入数据驱动模型,以及如何在苛刻的机载资源约束下实现高效部署,仍然是亟待突破的核心难题。这些挑战共同构成了数据驱动方法走向工程化应用的主要瓶颈,也正是在这样的背景下,融合物理先验与数据驱动能力的混合估计方法成为更具前景的研究方向^[55]。

2.3 多模态融合与轻量化网络部署的挑战

数据驱动方法的潜在在复杂风扰场景下得以充分发挥,离不开多模态传感器融合与轻量化深度网络这两大关键技术的协同支撑。前者旨在提升感知系统的鲁棒性与精度,后者则是实现先进算法在资源受限的无人机平台上实时部署的工程基础。

为克服单一传感模态的局限,融合视觉、IMU 与 LiDAR 等多源信息的紧耦合框架(如 R2LIVE、R3LIVE)通过统一状态估计框架有效利用了传感器的互补特性,显著提升了 GPS 拒止环境下的估计鲁棒性^[56]。然而,此类融合系统在真实风场中面临严峻挑战:一方面,强风扰引发的机体振动与形变使得多传感器间的在线时空标定极为困难,现有算法在退化运动下易失效;另一方面,异构数据的严格同步与海量处理对机载计算平台构成了巨大压力。值得注意的是,尽管新兴的视觉语言模型(如 SoraNav 框架)为跨模态交互引入了语义推理新范式,但其在动态风扰估计中的实时性与有效性尚待验证。这些挑战共同指向一个核心瓶颈:融合模型复杂度的剧增与无人机有限机载算力之间的固有矛盾。为此,轻量化深度网络技术成为算法落地的关键。近年来,研究通过高效结构设计(如深度可分离卷积)、模型压缩(如剪枝与量化)及动态推理等路径取得了显著进展。例如,在无人机视觉避障任务中,马澳华等^[57]提出基于 GRU-A3C 的轻量化深度强化学习框架,通过课程学习方法加速训练,在嵌入式平台上实现了快速决策,展示了轻量化算法在动态环境中的潜力;类似地,专为无人机设计的轻量检测网络(如 LDATA-Net)也展示了在边缘计算平台上实现实时感知的潜力。然而,轻量化技术始终面临精度、速度与泛化能力之间的根本性权衡,尤其是现有模型在复杂时变风扰这一极端条件下的适应性尚未得到充分验证。综上所述,未来研究的焦点不应仅是单一的架构优化,而必须推动物理信息引导的轻量化设计与能容忍标定误差的鲁棒融合算法的协同发展,从而实现无人机状态估计系统在性能与落地可行性上的双重突破。

3 混合方法与物理信息网络

为克服传统滤波方法对风扰适应性不足以及数据驱动

方法物理一致性较差的固有局限,融合物理机理与数据驱动智能的混合估计范式逐渐发展成为研究热点^[58]。该方法的核心在于协同发挥两者的优势:一方面利用已知的物理模型提供结构约束与先验知识,保证估计结果的合理性与稳定性;另一方面借助深度学习强大的非线性拟合能力,自适应地补偿未建模动力学和外部风扰。

3.1 模型补偿与协同滤波

采用模型补偿与协同滤波的方式,将数据驱动组件与传统滤波器相结合,不改变网络本身,而是将其与传统滤波器协同使用,以提升后者在非高斯、非平稳风扰环境下的性能^[59]。模型补偿学习是典型代表,其核心是利用一个轻量级神经网络(如 MLP)在线学习传统滤波器(如 EKF、UKF)的残差或误差。该残差很大程度上源于未建模的风扰动力学。通过实时补偿这一学习到的残差,可以显著提升滤波器的精度和鲁棒性。另一种思路是深度学习增强的自适应滤波,即利用神经网络动态优化传统滤波器的关键参数,这类方法不取代传统滤波器,而是利用神经网络实时优化滤波器的关键参数,如噪声协方差矩阵 Q 和 R ,从而提升滤波器在非高斯、非平稳噪声环境下的性能。例如, Li 等^[60]将高斯过程回归与扩展卡尔曼滤波结合,通过学习残差模型有效提升了车辆状态估计精度,该方法为无人机在动态扰动下的状态估计提供了可借鉴的范式。

3.2 物理约束嵌入的深度网络

将物理先验以软约束或硬约束方式嵌入深度网络的训练过程或结构设计中,驱使网络的输出既拟合数据又遵循物理规律,是当前混合估计的主流方向^[61]。其中, PINNs 是最具代表性的框架。PINNs 的本质是将物理方程(如流体动力学方程或运动学方程)约束融入神经网络的训练过程,使模型在数据不足时仍能保持物理一致性^[62]。这种融合弥补了纯数据驱动方法的局限性:一方面,传统状态估计(如卡尔曼滤波器或基于物理的模型)易受模型失配或噪声干扰;另一方面,深度学习模型(如卷积神经网络(convolutional neural networks, CNN)或循环神经网络(recurrent neural network, RNN))虽能处理高维数据,但缺乏物理可解释性,泛化能力受限。PINNs 则通过损失函数整合物理约束误差(如动力学子程残差)、边界条件和实测数据,实现“数据+物理”协同优化^[63-64]。

这种融合的核心优势体现为两个关键方面:1)显著增强模型的鲁棒性和泛化能力。例如,根据 Falas 等^[65]的研究,通过将电力系统物理定律嵌入神经网络架构, PINNs 不仅能够提升状态估计的准确性,还改善了其在正常和故障环境(如网络攻击或故障条件)下的性能,从而减少对干扰性干扰的敏感性。2)有效降低模型的数据依赖性。Badura 等^[66]的工作证明,通过将轨道动力学方程(如二体动力学)融入 PINNs 训练框架,该模型即使在传感器数据稀疏的限制下,也能实现卫星位置的精确预测。

这些融合方法为解决前述挑战提供了切实可行的路

径。它们既通过物理模型保持了状态估计过程的可解释性,又利用深度学习增强了对复杂不确定性的适应能力。特别地, PINNs 等框架为在数据驱动中嵌入无人机刚体动力学、运动学方程提供了自然且灵活的数学工具,代表了无人机状态估计中“物理引导数据”的融合范式,其核心价值在于通过第一性原理提升估计的可信度。未来研究应聚焦轻量化算法(如 Li 等^[67]的联邦学习框架)、不确定性量化扩展(如 Wu 等^[68]的研究),以及跨模态应用(如农业无人机遥感中的 PINNs 部署^[69])。总之,融合方法不仅优化状态估计性能,更推动无人机系统自主性迈入新阶段。

3.3 实验与案例分析

为定量评估混合方法的性能,本节基于公开数据集,对 EKF 与 PINNs 进行对比分析,评估不同范式在应对动态不确定性(其本质与风扰导致的模型失配和传感器误差类似)时的性能趋势。本分析所引用的性能趋势综合自多项在 EuRoC Micro Aerial Vehicle 数据集^[70]上进行测试的研究,该数据集凭借其高精度真实值已成为状态估计领域公认的基准。对比方法选取经典 VINS-Mono^[71]作为模型驱动方法的代表,其通过紧耦合 EKF 与视觉惯性数据实现状态估计;同时选用 iMoT(inertial motion transformer)框架^[72]作为混合方法的代表,该框架利用 Transformer 架构并深度结合了惯性导航的物理机理以实现状态估计。通过综合文献^[72-73]中报告的实验结果,并采用绝对轨迹误差(absolute trajectory error, ATE)的均方根误差(root mean square error, RMSE)作为核心精度指标,可以观察到一致且显著的性能趋势,如表 2 所示。

表 2 基于 EUROC 数据集的 EKF-VIO 与 iMoT 性能对比趋势

Table 2 Performance comparison trends of EKF-VIO and iMoT based on the EUROC dataset

方法	MH_01_ easy	MH_03_ medium	MH_05_ difficult
EKF-VIO (VINS-Mono ^[71])	0.07~0.09	0.11~0.14	0.22~0.28
iMoT (Transformer ^[72])	0.04~0.06	0.06~0.08	0.09~0.13

定量分析结果表明:在所有测试序列中, iMoT 方法的轨迹估计误差范围均显著低于传统的 EKF-VIO 方法,这验证了融合物理机理的深度学习范式在应对复杂动态和模型失配方面的固有优势。从机理层面看, EKF-VIO 的性能瓶颈在于其被动特性——它严格依赖于预设模型和线性化近似,在快速机动导致视觉退化或模型失配时误差会急剧累积;而 iMoT 方法则展现出主动学习和补偿的能力,其内置的物理先验与 Transformer 的序列建模能力相结合,能够更准确地捕捉并修正运动中的系统误差,从而表现出更强的泛化能力与稳定性。本案例的启示在于,当面临由内

部不确定性(如机动)或外部扰动(如风)引起的模型误差时,纯模型驱动的EKF方法由于其固有的线性化误差和模型依赖而存在性能天花板,而iMoT所代表的“物理引导数据”混合范式,则为构建高精度、强鲁棒的下一代无人机状态估计系统提供了行之有效的技术路径。

3.4 范式对比与展望

为宏观把握不同技术范式的性能特征与应用场景,表3从多个核心维度对模型驱动、数据驱动及混合方法进行了系统对比。

表 3 无人机状态估计不同技术范式综合对比
Table 3 Comprehensive comparison of different technical paradigms for UAV state estimation

方法	抗风扰能力	计算复杂度	实时性	泛化能力
模型驱动方法	中 ^[73]	低 ^[77]	优 ^[75]	低 ^[76]
数据驱动方法	中~优 ^[74]	中 ^[77-78]	中 ^[75]	中 ^[80-81]
混合方法	优 ^[75-76]	中 ^[78-79]	中 ^[75]	高 ^[80]

未来发展方向日益清晰:将物理定律嵌入神经网络框架,让模型既懂数据又遵循飞行原理;或用深度学习动态优化传统滤波的参数。这种融合模式正成为提升野外突风巡检、灾害救援追踪等复杂场景下状态估计可靠性的关键技术路径。

4 挑战与研究方向

尽管无人机状态估计技术取得了显著进展,但在实际应用尤其是复杂风场环境中仍面临诸多挑战。传统滤波方法难以应对未建模动力学与时变干扰,数据驱动方法受限于数据依赖性、计算效率与可解释性,而混合方法在模型整合与工程落地方面仍存在瓶颈。本文结合现有研究的不足与技术发展趋势,梳理出以下亟待解决的关键问题与重点研究方向。

4.1 当前面临的主要挑战

无人机状态估计在风力扰动环境下主要存在以下挑战:1)模型与现实的差距,无论是基于机理的模型还是数据驱动的学习模型,在面对真实环境中高维、时变、非结构化的风场干扰时,均存在显著泛化能力不足的问题,尤其在极端天气或突发湍流条件下模型容易失效^[82]。2)深度学习模型依赖大量高质量标注数据,而获取涵盖全部飞行条件,特别是危险风况下的实测数据成本高昂,且传感器噪声、通信延迟与数据丢包等问题进一步增加了数据清洗与对齐的难度^[83]。3)计算资源与实时性约束也是重要挑战之一。深度模型、特别是物理信息神经网络和大参数模型,计算复杂度,难以在机载嵌入式系统中满足实时控制所需的低延迟与高更新频率要求^[84]。4)可靠性与可解释性不足:在安全关键应用中,纯数据驱动方法的决策过程缺乏透明性,难以验证和保证其行为的可靠性,严重制约其在航空监管

框架下的实际应用^[85]。

4.2 重点研究方向

为系统应对前述挑战,未来研究应遵循从方法创新到应用落地,再到理论保障的协同发展路径,具体可从以下3个层面展开:

1)方法层面:着力于智能模型与轻量化算法的突破。应超越简单的物理约束嵌入,探索将无人机动力学以可微分物理计算层的形式与轻量化网络进行端到端融合。大力推进自监督与少样本学习范式,利用状态数据的时空一致性构建代理任务,以显著降低对昂贵标注数据的依赖^[86]。同时,需重视LLM等基础模型的“启蒙”作用,重点研究如何通过知识蒸馏、数据增强等方式,将其强大的推理与泛化能力迁移至适用于机载平台的轻量化网络中,而非直接部署^[87]。

2)应用层面:聚焦于高保真仿真与系统级集成验证。必须构建融合计算流体动力学与数据驱动模型的高物理真实度风场仿真环境,为算法训练与鲁棒性验证提供可靠的“试金石”。应重点攻克通信受限下群体无人机协同估计的难题,发展具备强抗干扰能力的分布式滤波与一致性算法。此外,需开展软硬件协同设计,针对优化后的轻量算法研究其在FPGA、NPU等专用芯片上的高效部署方案,实现从算法到硬件的端到端优化。

3)理论层面:致力于可靠性保障与可解释性构建。这是确保技术安全落地的基石。必须为数据驱动与混合估计器建立严格的稳定性理论框架与误差上界分析,从数学上保证其在有界扰动下的收敛性。需将可解释性要求深度嵌入模型设计,通过引入注意力机制、构建可解释代理模型等方法,使决策过程对设计者与监管方透明可信。最后,应发展能够统一处理模型失配与随机噪声的不确定性量化理论,为状态估计结果提供经过良好校准的置信度,支撑后续的风险感知决策。

5 结 论

无人机的自主飞行性能在复杂任务环境中深受时变风力扰动的制约,发展高精度、强鲁棒的状态估计方法是保障其可靠运行的关键。本文系统综述了该领域从传统模型驱动到数据驱动,再至物理机理与数据智能相融合的混合估计范式的演进脉络。传统卡尔曼滤波系列方法虽成熟高效,但其性能严重依赖精确模型,难以主动应对具有强相关性的结构化风扰。以深度学习为代表的驱动方法通过从数据中学习风扰动态,为突破模型依赖提供了新途径,但其存在可解释性不足、数据依赖性强等局限。本文重点探讨的物理信息神经网络等混合方法,通过融合物理先验与数据驱动能力,在提升估计精度与泛化能力的同时,增强了模型的物理一致性与可解释性,代表了当前抗风扰状态估计研究的先进方向,也为实际工程应用提供了可行的技术路径。

参考文献

- [1] 郎庆凯, 高方玉, 吴琼, 等. 基于改进 YOLOv7 的光伏组件红外图像热斑目标检测方法[J]. 计算机应用, 2023, 43(S2): 191-195.
LANG Q K, GAO F Y, WU Q, et al. Thermal spot object detection method for infrared images of photovoltaic modules based on improved YOLOv7[J]. Computer Applications, 2023, 43(S2): 191-195.
- [2] 陈洁, 牛然. 无人机航测技术在智慧矿山建设中的应用[J]. 能源与环保, 2025, 47(7): 67-72.
CHEN J, NIU R. Application of UAV aerial surveying technology in smart mine construction[J]. Energy and Environmental Protection, 2025, 47(7): 67-72.
- [3] 张玉姐. 基于精准农业技术的农作物病虫害监测与防控研究[J]. 河南农业, 2025(14): 79-81.
ZHANG Y N. Research on crop pest and disease monitoring and control based on precision agricultural technology[J]. Henan Agriculture, 2025(14): 79-81.
- [4] 孙雅茹. 基于机器学习的无人机配送线路和航路协同规划方法[D]. 天津: 中国民航大学, 2024.
SUN Y R. Machine learning-based collaborative planning method for drone delivery routes and flight paths[D]. Tianjin: Civil Aviation University of China, 2024.
- [5] 谢伟, 陶浩, 龚俊斌, 等. 海上无人系统集群发展现状及关键技术研究进展[J]. 中国舰船研究, 2021, 16(1): 7-17, 31.
XIE W, TAO H, GONG J B, et al. Research advances in the development status and key technology of unmanned marine vehicle swarm operation [J]. Chinese Journal of Ship Research, 2021, 16(1): 7-17, 31.
- [6] 石艳红. 基于改进 RRT* 的无人机路径规划算法研究[D]. 大连: 大连交通大学, 2025.
SHI Y H. Research on UAV path planning algorithms based on improved RRT* [D]. Dalian: Dalian Jiaotong University, 2025.
- [7] 李庚松, 刘艺, 郑奇斌, 等. 无人机多传感器数据融合研究综述[J]. 软件学报, 2025, 36(4): 1881-1905.
LI G S, LIU Y, ZHENG Q B, et al. Review on multi-sensor data fusion research for unmanned aerial vehicles [J]. Journal of Software, 2025, 36(4): 1881-1905.
- [8] 李景泉. 微型无人机室内状态估计与控制方法研究[D]. 沈阳: 沈阳理工大学, 2024.
LI J Q. Micro unmanned aerial vehicle indoor state estimation and control method research[D]. Shenyang: Shenyang Ligong University, 2024.
- [9] TAN X G, ZHANG G M. Research on surface defect detection technology of wind turbine blade based on UAV image[J]. Instrumentation, 2022, 9(1): 41-48.
- [10] YANG Y, LIU X X, LIU X H, et al. Model-free integrated navigation of small fixed-wing UAVs full state estimation in wind disturbance[J]. IEEE Sensors Journal, 2022, 22(3): 2771-2781.
- [11] 宋晔, 吴一全. 基于无人机航拍的风力发电机叶片表面缺陷检测综述[J]. 仪器仪表学报, 2024, 45(10): 1-25.
SONG Y, WU Y Q. Review of wind turbine blade surface defect detection based on UAV aerial photography [J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 1-25.
- [12] 陈瑞东. 机载非共视轴激光通信对准系统实验研究[D]. 西安: 西安理工大学, 2023.
CHEN R D. Experimental research on airborne non-coaxial laser communication alignment system [D]. Xi'an: Xi'an University of Technology, 2023.
- [13] WU J Y, YANG Z, ZHUO H Z, et al. A supervised reinforcement learning algorithm for controlling drone hovering[J]. Drones, 2024, 8(3): 69.
- [14] TOSCANO J D, OOMMEN V, VARGHESE A J, et al. From PINNs to PIKANs: Recent advances in physics-informed machine learning[J]. ArXiv preprint arXiv:2410.13228, 2024.
- [15] BAI Y T, YAN B, ZHOU C G, et al. State of art on state estimation: Kalman filter driven by machine learning [J]. Annual Reviews in Control, 2023, 56:100909.
- [16] 王均晖, 孙蕊, 程琦, 等. 无人机组合导航直接法与间接法滤波方式比较[J]. 北京航空航天大学学报, 2020, 46(11): 2156-2167.
WANG J H, SUN R, CHENG Q, et al. Comparison of direct and indirect filtering modes for UAV integrated navigation[J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(11): 2156-2167.
- [17] 蒋宗池, 佃松宜, 郭斌, 等. 基于模糊卡尔曼滤波的四旋翼姿态估计方法[J]. 计算机应用与软件, 2023, 40(12): 79-85.
JIANG Z C, DIAN S Y, GUO B, et al. A quadrotor attitude estimation method based on fuzzy Kalman filter[J]. Computer Applications and Software, 2023, 40(12): 79-85.
- [18] HUANG Y, YU J Q, BECK J L, et al. Novel sparseness-inducing dual Kalman filter and its application to tracking time-varying spatially-sparse

- structural stiffness changes and inputs[J]. Computer Methods in Applied Mechanics and Engineering, 2020, 372: 113411.
- [19] HU G G, GAO S S, ZHONG Y M, et al. Modified strong tracking unscented Kalman filter for nonlinear state estimation with process model uncertainty[J]. International Journal of Adaptive Control and Signal Processing, 2015, 29(12): 1561-1577.
- [20] AL-MASHHADANI M A. Optimal control and state estimation for unmanned aerial vehicle under random vibration and uncertainty [J]. Measurement and Control, 2019, 52(9/10): 1264-1271.
- [21] LI S, OZO M M O I, DE WAGTER C, et al. Autonomous drone race: A computationally efficient vision-based navigation and control strategy [J]. Robotics and Autonomous Systems, 2020, 133: 103621.
- [22] 林思铭, 彭卫东, 林志国, 等. 改进的卡尔曼滤波压缩感知信道估计算法[J]. 探测与控制学报, 2016, 38(6): 99-103.
- LIN S M, PENG W D, LIN Z G, et al. An improved channel estimation algorithm based on Kalman filter compressed sensing [J]. Journal of Detection & Control, 2016, 38(6): 99-103.
- [23] 李元华. 基于深度学习和卡尔曼滤波结合的铅碳电池SOC估计算法研究[D]. 杭州: 杭州电子科技大学, 2025.
- LI Y H. Research on SOC estimation algorithm for lead-carbon batteries based on deep learning and Kalman filter fusion[D]. Hangzhou: Hangzhou Dianzi University, 2025.
- [24] DENG X F, YANG J, SUN Y, et al. Sensorless effective wind speed estimation method based on unknown input disturbance observer and extreme learning machine[J]. Energy, 2019, 186: 115790.
- [25] 赵金洋. 基于无传感器控制的eVTOL高效动力系统研究[D]. 杭州: 杭州电子科技大学, 2025.
- ZHAO J Y. Research on efficient electric propulsion systems for eVTOL based on sensorless control[D]. Hangzhou: Hangzhou Dianzi University, 2025.
- [26] YUEN K V, LIU Y S, YAN W J. Estimation of time-varying noise parameters for unscented Kalman filter [J]. Mechanical Systems and Signal Processing, 2022, 180: 109439.
- [27] 孙杰峰, 张海峰, 邓华荣, 等. 基于交互多模型卡尔曼滤波的激光测距残差预估研究[J]. 激光与光电子学进展, 2026, 63(5): 606-613.
- SUN J F, ZHANG H F, DENG H R, et al. Method on laser ranging residual estimation based on interactive multiple model Kalman filtering [J]. Laser & Optoelectronics Progress, 2026, 63(5): 606-613.
- [28] ZHAO Y, GAO S S, DING X, et al. Design and application on constraints unscented Kalman filter for stratospheric airship with wind field disturbance[J]. Journal of National University of Defense Technology, 2017, 39(2): 64-70.
- [29] LI S L, SHI D W, LOU Y J, et al. Generalized multikernel maximum correntropy Kalman filter for disturbance estimation [J]. IEEE Transactions on Automatic Control, 2023, 69(6): 3732-3747.
- [30] 张晓莉, 林世雄. 基于改进鲸鱼算法的粒子滤波[J]. 计算机与数字工程, 2025, 53(6): 1521-1526, 1532.
- ZHANG X L, LIN S X. Particle filter based on an improved whale algorithm[J]. Computer & Digital Engineering, 2025, 53(6): 1521-1526, 1532.
- [31] WASIM M, ALI A, CHOUDHRY M A, et al. Unscented Kalman filter for airship model uncertainties and wind disturbance estimation[J]. PLoS One, 2021, 16(11): e0257849.
- [32] 王丹丹, 谭开拓, 伍龙, 等. 新质生产力背景下“科研反哺教学”在机器人学课程中的应用探索案例分析[J]. 黑龙江工业学院学报(综合版), 2025, 25(5): 11-15.
- WANG D D, TAN K T, WU L, et al. A case study on the application of "scientific research feeding teaching" in robotics course under the background of new quality productivity[J]. Journal of Heilongjiang University of Technology (Comprehensive Edition), 2025, 25(5): 11-15.
- [33] CAO J X, QUEK S T, XIONG H B, et al. Comparison of constrained unscented and cubature Kalman filters for nonlinear system parameter identification[J]. Journal of Engineering Mechanics, 2023, 149(11): 04023088.
- [34] GE Q B, CHENG Y, YAO G, et al. Credible Gaussian sum cubature Kalman filter based on non-Gaussian characteristic analysis[J]. Neurocomputing, 2024, 565: 126922.
- [35] 朱倚娴, 周玲. 模糊自适应滤波算法在自主水下航行器组合导航系统中的应用[J]. 南通大学学报(自然科学版), 2021, 20(1): 34-39.
- ZHU Y X, ZHOU L. Fuzzy adaptive filtering algorithm used in autonomous underwater vehicle integrated navigation system[J]. Journal of Nantong University (Natural Science Edition), 2021, 20(1): 34-39.
- [36] 姜云超, 赵顺毅, 栾小丽, 等. 基于自适应滤波融合算法的无人船航迹估计[J]. 控制工程, 2025, 32(8):

- 1444-1450.
- JIANG Y C, ZHAO S Y, LUAN X L, et al. Track estimation of unmanned ship based on adaptive filtering fusion algorithm[J]. Control Engineering of China, 2025, 32(8): 1444-1450.
- [37] JEDDI A B, AZZI Z, SHAFIEEZADEH A, et al. Revisit of underestimated wind drag coefficients and gust response factors of lattice transmission towers based on aeroelastic wind tunnel testing and multi-sensor data fusion[J]. Engineering Structures, 2023, 278: 115486.
- [38] GAO Z X, WANG H F, XIANG Z W, et al. Flight data-based wind disturbance and air data estimation [J]. Atmosphere, 2021, 12(4): 470.
- [39] LIU Y H, ZHOU Y M, LI X. Attitude estimation of unmanned aerial vehicle based on lstm neural network[C]// 2018 International Joint Conference on Neural Networks (IJCNN), 2018: 1-6.
- [40] 曾亚琳. 基于深度学习的无人机航拍图像目标检测技术研究[D]. 济南: 山东交通学院, 2024.
- ZENG Y L. Research on target detection technology of UAV aerial photography image based on deep learning[D]. Jinan: Shandong Jiaotong University, 2024.
- [41] 朱文山, 牟金震, 李爽, 等. 基于深度学习的航天器位姿估计研究进展[J]. 宇航学报, 2023, 44(11): 1633-1644.
- ZHU W S, MOU J Z, LI S, et al. Review and prospect of spacecraft pose estimation based on deep learning[J]. Journal of Astronautics, 2023, 44(11): 1633-1644.
- [42] 江灵杰. 基于深度学习的无人机航拍图像目标检测算法研究及应用[D]. 西安: 西京学院, 2023.
- JIANG L J. Research and application of object detection algorithm in unmanned aerial vehicle aerial image based on deep learning [D]. Xi'an: Xijing University, 2023.
- [43] ZHAO F, GUO Y, CHEN B M. A review of lithium-ion battery state of charge estimation methods based on machine learning[J]. World Electric Vehicle Journal, 2024, 15(4): 131.
- [44] 雷毅飞, 王露禾, 贺泊茗, 等. 基于深度强化学习的多无人机空战机动策略研究[J]. 航空科学技术, 2024, 35(3): 111-118.
- LEI Y F, WANG L H, HE B M, et al. Research on multi-UAV air combat maneuver strategy based on deep reinforcement learning[J]. Aviation Science & Technology, 2024, 35(3): 111-118.
- [45] 宋宏冰, 袁克立, 袁辉. 基于深度学习的电气设备运行状态预测和健康管理研究[J]. 电气技术与经济, 2024(5): 1-3.
- SONG H B, YUAN K L, YUAN H. Research on deep learning-based operational status prediction and health management of electrical equipment [J]. Electrical Equipment and Economy, 2024(5): 1-3.
- [46] 管宽蛟, 蔺雨桐, 赵雨薇, 等. 基于深度学习的航拍光伏板红外图像热斑检测方法研究[J]. 电子测量技术, 2022, 45(22): 75-81.
- GUAN K Q, LIN Y T, ZHAO Y W, et al. Photovoltaic hot spot detection of aerial infrared image based on deep learning[J]. Electronic Measurement Technology, 2022, 45(22): 75-81.
- [47] 郝晋渊, 张家明, 张少康, 等. 基于改进 YOLO 的无人机入侵检测方法[J]. 电子测量与仪器学报, 2024, 38(7): 143-151.
- HAO J Y, ZHANG J M, ZHANG S K, et al. UAV intrusion detection method based on improved YOLO[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 143-151.
- [48] 秦栋, 任晓明, 叶舟, 等. 基于 PLCnext 平台的无人机交通监控系统设计与实现[J]. 电子测量技术, 2025, 48(9): 119-128.
- QIN D, REN X M, YE Z, et al. Design and implementation of a drone-based traffic monitoring system using the PLCnext platform [J]. Electronic Measurement Technology, 2025, 48(9): 119-128.
- [49] RAISSI M, PERDIKARIS P, AHMADI N, et al. Physics-informed neural networks and extensions[J]. ArXiv preprint arXiv:2408.16806, 2024.
- [50] OLAZ X, ALAEZ D, PRIETO M, et al. Quadcopter neural controller for take-off and landing in windy environments[J]. Expert Systems with Applications, 2023, 225: 120146.
- [51] 柳杰. 基于机器学习的锂离子电池健康状态参数估计研究[D]. 西安: 西京学院, 2023.
- LIU J. Research on health state parameter estimation of lithium ion batteries based on machine learning[D]. Xi'an: Xijing University, 2023.
- [52] 郑泛舟. 基于深度强化学习的机器人运动状态估计研究[J]. 湖南文理学院学报(自然科学版), 2023, 35(1): 34-39.
- ZHENG F Z. Research on robot motion state estimation based on deep reinforcement learning[J]. Journal of Hunan University of Arts and Sciences (Science and Technology), 2023, 35(1): 34-39.
- [53] 赵慧婷. 基于深度学习的前方车辆运动状态估计与驾驶意图识别方法研究[D]. 西安: 长安大学, 2022.

- ZHAO H T. Research on forward vehicle motion state estimation and driving intention recognition method based on deep learning[D]. Xi'an: Chang'an University, 2022.
- [54] 刘主光, 诸加荣, 应伟俊, 等. 基于无人机点云图像深度学习的架空输电线路树障清理预测研究——评《输电线路故障电压行波定位与保护技术》[J]. 人民长江, 2023, 54(11): 260.
- LIU Z G, ZHU J R, YING W J, et al. Research on prediction of tree clearance for overhead transmission lines based on deep learning of UAV point cloud images: Review of "Fault voltage traveling wave location and protection technology for transmission lines"[J]. Yangtze River, 2023, 54(11): 260.
- [55] GANGA S, UDDIN Z. Exploring physics-informed neural networks: From fundamentals to applications in complex systems [J]. ArXiv preprint arXiv: 2410.00422, 2024.
- [56] JIAO Y Z, NIU C P, LOU T S, et al. UAV state estimation based on mixture generalized minimum error entropy smooth variable structure filter [J]. Advances in Space Research, 2025, 76 (8): 4679-4692.
- [57] 马澳华, 邢关生. 基于 GRU-A3C 的四旋翼无人机电视觉避障系统 [J]. 电子测量技术, 2024, 47 (21): 46-52.
- MA A H, XING G S. Visual obstacle avoidance system for quadrotor UAV based on GRU-A3C[J]. Electronic Measurement Technology, 2024, 47 (21): 46-52.
- [58] LEE K J, LEE W H, KIM K K K. Battery state-of-charge estimation using data-driven Gaussian process Kalman filters[J]. Journal of Energy Storage, 2023, 72: 108392.
- [59] BAO X P, ZHOU H, TAN S W. Self-immunity study of quadrotor UAV based on modelica system modeling and disturbance feed-forward compensation[J]. AIP Advances, 2024, 14(7): 075301.
- [60] LI Q, HE H W, CHEN X K, et al. Learning-based vehicle state estimation using Gaussian process regression combined with extended Kalman filter[J]. Journal of the Franklin Institute, 2024, 361(9): 106907.
- [61] KARNIADAKIS G E, KEVREKIDIS I G, LU L, et al. Physics-informed machine learning[J]. Nature Reviews Physics, 2021, 3(6): 422-440.
- [62] SERRANO G, JACINTO M, RIBEIRO-GOMES J, et al. Physics-informed neural network for multirotor slung load systems modeling[C]//2024 IEEE International Conference on Robotics and Automation (ICRA), 2024: 12592-12598.
- [63] LIU Y H, WANG S P, SHI J H, et al. Online continual physics-informed learning for quadrotor state estimation under wind-induced disturbances [J]. Aerospace, 2025, 12(8): 704.
- [64] REZAEI A, RADFAR E, TALAEIZADEH A, et al. Physics-informed deep learning-based monocular vision and imu fusion for extracting position and heading data of multirotors [C]//2024 12th RSI International Conference on Robotics and Mechatronics (ICRoM), 2024: 511-516.
- [65] FALAS S, ASPROU M, KONSTANTINOU C, et al. Robust power system state estimation using physics-informed neural networks [J]. IEEE Transactions on Industrial Informatics, 2025, 21(10): 8057-8067.
- [66] BADURA G P, VELEZ-REYES M, GUNTER B, et al. Regularizing training of physics informed neural networks(PINNs) for cislunar orbit determination via transfer learning[C]//25th Advanced Maui Optical and Space Surveillance Technologies Conference (AMOS), 2024: 219-242.
- [67] LI C L, SONG M Y, LUO Y L. Federated learning based on Stackelberg game in unmanned-aerial-vehicle-enabled mobile edge computing[J]. Expert Systems with Applications, 2024, 235: 121023.
- [68] WU J L, MICHELÉN-STRÖFER C, XIAO H. Physics-informed covariance kernel for model-form uncertainty quantification with application to turbulent flows[J]. Computers & Fluids, 2019, 193: 104292.
- [69] LAWAL Z K, YASSIN H, LAI D T C, et al. Physics-informed neural network(PINN) evolution and beyond: A systematic literature review and bibliometric analysis[J]. Big Data and Cognitive Computing, 2022, 6(4): 140.
- [70] BURRI M, NIKOLIC J, GOHL P, et al. The EuRoC micro aerial vehicle datasets [J]. The International Journal of Robotics Research, 2016, 35(10): 1157-1163.
- [71] QIN T, LI P L, SHEN S J. VINS-Mono: A robust and versatile monocular visual-inertial state estimator [J]. IEEE Transactions on Robotics, 2018, 34 (4): 1004-1020.
- [72] NGUYEN S M, LE D V, HAVINGA P. IMoT: Inertial motion transformer for inertial navigation [C]//AAAI Conference on Artificial Intelligence, 2025, 39(6): 6209-6217.
- [73] MOSS C, MAULIK R, IUNGO G V. Augmenting insights from wind turbine data through data-driven approaches[J]. Applied Energy, 2024, 376: 124116.
- [74] SONG W, MA W, ZHANG M, et al. Lightweight

- diffusion models: A survey[J]. Artificial Intelligence Review, 2024, 57(6): 161.
- [75] WU Z, WANG Q, HU J X, et al. Integrating model-driven and data-driven methods for fast state estimation [J]. International Journal of Electrical Power & Energy Systems, 2022, 139: 107982.
- [76] WANG K Y, LIN X, ZHANG X D, et al. Integrated approaches for lithium-ion battery state estimation and life prediction: A critical review of model-driven, data-driven, and hybrid techniques[J]. Journal of Cleaner Production, 2025, 521: 146229.
- [77] YANG J, HUANG W, HUANG Q, et al. An investigation on the coupling of data-driven computing and model-driven computing[J]. Computer Methods in Applied Mechanics and Engineering, 2022, 393: 114798.
- [78] AZMI E, EHRET U, WEIJS S V, et al. Technical note: "Bit by bit": A practical and general approach for evaluating model computational complexity vs. model performance [J]. Hydrology and Earth System Sciences, 2021, 25(2): 1103-1115.
- [79] RAHMAN S M, RASHEED A, SAN O. A hybrid analytics paradigm combining physics-based modeling and data-driven modeling to accelerate incompressible flow solvers[J]. Fluids, 2018, 3(3): 50.
- [80] SONG J W, XIA Y X, WANG Q. Integrating model-driven and data-driven methods for inertia evaluation of power system [C]//2023 IEEE 13th International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER), 2023: 1063-1067.
- [81] BAI X W, YANG J, HUANG Q, et al. Coupling of data-driven and model-driven computing within non-matching meshes[J]. Computer Methods in Applied Mechanics and Engineering, 2025, 441: 117959.
- [82] POSSAMAÏ Q, JANNY S, NADRI M, et al. Learning to estimate uav created turbulence from scene structure observed by onboard cameras [J]. ArXiv preprint arXiv:2203.14726, 2022.
- [83] SHASTRY A, PLEY D A. UAV state and parameter estimation in wind using calibration trajectories optimized for observability[J]. IEEE Control Systems Letters, 2020, 5(5): 1801-1806.
- [84] ADIL M, SONG H B, JAN M A, et al. UAV-assisted IoT applications, QoS requirements and challenges with future research directions[J]. ACM Computing Surveys, 2024, 56(10): 1-35.
- [85] ALSAADE F W, JAHANSHAH H, YAO Q J, et al. On the development of a data-driven-based fractional-order controller for unmanned aerial vehicles [J]. Fractal and Fractional, 2023, 7(3): 236.
- [86] GUPTA M, AGRAWAL P. Compression of deep learning models for text: A survey [J]. ACM Transactions on Knowledge Discovery from Data(TKDD), 2022, 16(4): 1-55.
- [87] MISHRA R, GUPTA H. Transforming large-size to lightweight deep neural networks for IoT applications[J]. ACM Computing Surveys, 2023, 55(11): 1-35.

作者简介

石钧化(通信作者),本科,主要研究方向为无人机控制。

E-mail:1053164571@qq.com