

文章编号:1671-1637(2026)04-0090-18

面向低空交通管控平台的航迹实时异常检测与预测修正模型

张建平^{1,2}, 罗创^{1,2}, 张光远^{*1,2}, 王致远^{1,2}, 陈运翔^{1,2}

(1. 西南交通大学 交通运输与物流学院, 四川 成都 610031; 2. 低空交通智能管控四川省重点实验室, 四川 成都 610031)

摘要:构建了一种面向低空交通管控平台的航迹异常检测与修正一体化端到端模型,以统计离群、物理包线、形态模式和序列残差4类行为分量融合形成统一异常分数,并结合特征融合模块以及自适应阈值和权重优化实现异常判定;以单向双层长短期记忆网络预测结合注意力机制作为时序骨干,融入可微分物理积分器、自适应噪声估计与卡尔曼更新,获得预测重构序列;设计了可回传损失函数,并采用一致性蒸馏对分支输出口径,最终形成端到端的物理感知卡尔曼长短时记忆网络模型。研究表明:在异常检测任务中,相较于深度基线模型,本研究模型的固定阈值下的调和均值分数F1、平均精确率-召回率曲线下面积AUPRC和ROC曲线下面积AUROC分别提升了5.95%、4.16%和2.38%;在预测修正任务中,相较于仅滤波方法和仅预测模型,均方根误差分别降低了15.2%和21.7%;在实时部署方面,优选32窗口时,模型计算延迟较最佳F1值对应的64窗口下降了76.9%,而F1值仅下降了0.57%。该模型能够在毫秒级时延约束下兼顾异常检测可靠性与航迹实时纠偏能力,可为低空交通管控平台航迹实时异常检测及预测修正功能的开发提供有效方法支撑。

关键词:低空交通;航迹异常检测;端到端模型;深度学习算法;航迹预测修正;低空交通管控平台;无人驾驶航空器

中图分类号:U8 文献标志码:A DOI:10.19818/j.cnki.1671-1637.2026.166

Real-time track anomaly detection and prediction correction model for low-altitude traffic control platform

ZHANG Jian-ping^{1,2}, LUO Chuang^{1,2}, ZHANG Guang-yuan^{*1,2}, WANG Zhi-yuan^{1,2}, CHEN Yun-xiang^{1,2}

(1. School of Transportation and Logistics, Southwest Jiaotong University, Chengdu 610031, Sichuan, China; 2. Low-altitude Traffic Intelligent Control Key Laboratory of Sichuan Province, Chengdu 610031, Sichuan, China)

Abstract: An end-to-end integrated model of track anomaly detection and correction for low-altitude traffic control platforms was developed. Four types of behavioral components, such as, statistical outliers, physical envelopes, morphological patterns, and sequence residuals, were fused to form a unified anomaly score, and anomaly identification was achieved by combining a feature fusion

出版历程:2025-08-25 收稿,2025-12-09 修回,2026-01-23 录用

基金项目:国家重点研发计划(2022YFB4300903);国家自然科学基金民航联合研究基金重点项目(U2433217);国家自然科学基金项目(52472332);四川省重大科技专项揭榜挂帅项目(2024ZDZX0044);四川省自然科学基金项目(2025ZNSFSCO394)

作者简介:张建平(1976-),男,安徽芜湖人,研究员,博士生导师,工学博士,E-mail:zhangjp@swjtu.edu.cn。

*通信作者:张光远(1979-),男,辽宁庄河人,正高级实验师,博士生导师,工学博士,E-mail:gyzhang@swjtu.edu.cn。

引用格式:张建平,罗创,张光远,等.面向低空交通管控平台的航迹实时异常检测与预测修正模型[J].交通运输工程学报,2026,26(4):90-107.

Citation: ZHANG Jian-ping, LUO Chuang, ZHANG Guang-yuan, et al. Real-time track anomaly detection and prediction correction model for low-altitude traffic control platform[J]. Journal of Traffic and Transportation Engineering, 2026, 26(4): 90-107.

module, adaptive thresholding, and weight optimization. A unidirectional two-layer long short-term memory prediction network combined with an attention mechanism was employed as the temporal backbone, and a differentiable physical integrator, adaptive noise estimation, and Kalman update were incorporated to obtain predicted reconstruction sequences. A back-propagatable loss function was designed, and consistency distillation was adopted to align the outputs of different branches, ultimately forming an end-to-end physics-aware Kalman long short-term memory network model. The results show that in the anomaly detection task, compared with deep baseline models, the harmonic mean score (F1), area under the average precision-recall curve (AUPRC), and area under the ROC curve (AUROC) of the developed model under a fixed threshold increase by 5.95%, 4.16%, and 2.38%, respectively. In the prediction correction task, compared with a filtering-only method and a prediction-only model, the root mean square error (RMSE) decreases by 15.2% and 21.7%, respectively. In terms of real-time deployment, when the optimal window size is 32, the computational latency decreases by 76.9% compared with the window size of 64 corresponding to the best F1 value, while the F1 value decreases by only 0.57%. The model can balance the anomaly detection reliability and real-time trajectory correction ability under millisecond-level latency constraints and can provide effective methodological support for the development of real-time trajectory anomaly detection and prediction correction functions of low-altitude traffic control platforms.

Keywords: low-altitude traffic; track anomaly detection; end-to-end model; deep learning algorithm; trajectory prediction and correction; low-altitude traffic control platform; unmanned aerial vehicle

Publication history: Received 2025-08-25; Received in revised form 2025-12-09; Accepted 2026-01-23

Funding: National Key R&D Program of China (2022YFB4300903); Key Program of National Natural Science Foundation of China Civil Aviation Joint Research Fund (U2433217); National Natural Science Foundation of China (52472332); Sichuan Provincial Major Science and Technology Special Project (2024ZDZX0044); Sichuan Provincial Natural Science Foundation of China (2025ZNSFSCO394)

* **Corresponding author:** ZHANG Guang-yuan, senior engineer, PhD, E-mail: gyzhang@swjtu.edu.cn.

0 引言

近年来,中国低空经济快速发展,以无人驾驶航空器(无人机)为代表的低空飞行活动增长迅猛,确保对低空飞行活动的有效监控。一旦因监控不力造成安全事故,将严重阻碍低空经济健康有序地发展。低空飞行活动逐步呈现大流量、高时变、复杂、异构的运行态势,传统“靠人管”的空中交通监控模式及自动化监控系统存在能力极限,监控模式亟需实现“靠人管”向“靠机器管”的转变,监控系统亟需实现“自动化”向“智能化”的转型。

2018年11月,依托无人机网联报送飞行动态的空中交通管控平台中国民用航空局(民航局)无人驾驶航空器空管信息服务系统(UTMISS)在深圳地区上线运行,开创军方、民航、公安共享无人机监视数据的高效协同监管模式。自2020年5月1日起,UTMISS开始接收全国范围的民用轻小型及农林

植保型无人机实时飞行动态数据;截至2023年底,全国范围共有31家整机制造商生产的272款民用无人机具备向UTMISS报送实时飞行动态数据的功能,UTMISS全年保障累计25720.7万飞行架次、2310.9万飞行小时的民用无人机飞行活动,日均保障70.5万飞行架次、6.3万飞行小时。2024年1月1日,接替UTMISS接收无人机网联报送数据的民航局无人驾驶航空器综合管理平台(UOM)上线运行,承担国家无人驾驶航空器一体化综合监管服务平台重要使命;随后,安徽省、成都市等地的区域性低空交通管控平台伴随低空经济大潮纷纷涌现。

随着低空交通管控平台朝着智能化、网联化方向不断拓展,一些安全隐患逐步暴露出来。平台通过接收无人机网联报送的飞行动态数据实现监控功能,而无人机机载端本身存在定位误差,加之通信链路长、数据处理并发量大,平台端经常出现无人机航迹位置跳变、高度异常、速度异常等现象,直接影响

无人机态势感知与决策指挥的可靠性,若不及时发现甚至将引发安全事故。对于日益涌现的低空飞行活动,要想管得住,前提是看得见、看得准。因此,开发低空交通管控平台的航迹实时异常检测及预测修正功能,成为提升平台可靠性、可用性的当务之急。

鉴于中国民航现行的管制自动化系统依赖与飞行计划的一致性比对进行航迹异常检测,依赖多源监视数据融合处理完成航迹预测修正^[1-2],而低空交通管控平台主要依靠网联报送方式采集航迹,绝大多数目标为无人机消费类飞行活动,并无飞行计划,因此现行民航管制自动化系统的技术体制对于解决平台航迹异常检测及实时修正问题并不适用。目前,随着中国无人机生产研制技术的快速发展,在无人机机载端基于人工智能的航迹异常检测及预测修正技术迭代迅猛、引人注目,尽管尚不能有效解决低空交通管控平台因机、站、链等综合因素导致的航迹异常检测及实时修正问题,却为问题的解决提供了有益思路。在数据异常判定方面,张鼎开等^[3]将异常时间时空范围和影响范围掩码引入时序异常检测模型,学习交通流中的异常数据特征,发掘了模型在交通数据中的泛用性;Pang等^[4]提出深度弱监督异常检测网络以成对关系学习缓解弱标签困境,提升判别性;Chen等^[5]构建了具有语义特征的共形时间序列模型,将共形推断迁移至表征空间并实现动态加权;另有基于加权分位数的自适应共形异常检测,通过加权分位输出可解释参数值以支持流式监测^[6]。然而,现有方法仍难将无人机平台侧网联数据的相关关键异质证据统一投影到同一可学习分数,并在规则前提下在端到端目标中进行协同优化,并且现有的数据异常处理方式,多以后处理为主,阈值与权重难与特征共同反传,且对概念漂移下的多证据一致性约束不足。在异常检测与预测修正方面,Zeng等^[7]构造的基于神经微分方程连续与离散模型,打通动力学积分与学习框架;Ni等^[8]使用了自适应卡尔曼滤波网络以超网络快速调制增益适配噪声漂移;Shen等^[9]利用了卡尔曼 Transformer 模型,以 Transformer 学习卡尔曼增益弱化对先验噪声的依赖,结果表明深度学习模型和滤波结合能对航迹预测的判定精度较高。然而,目前研究多聚焦估计精度,难以把异常检测和修正双功能闭环,不能够实现在可微滤波中对时变噪声与传感器退化联合优化,同时无法满足高环境复杂度、机动的无人机航迹预测所需的泛化性。在工程化方面,Chen等^[10]阐述了

可微粒子滤波的设计抉择与端到端训练管线;Wan等^[11]提出具有扩散模型的动态系统的可微状态估计模型,将扩散模型引入状态估计以刻画非高斯后验;Reis等^[12]提出面向边缘设备的低空飞行器实时故障检测框架,强调时延与能耗约束;Ahmad等^[13]构建支持滑窗与噪声重估的在线自适应卡尔曼滤波(Kalman Filter, KF)。然而,当前研究普遍缺少检测到修正再到可控回退的一体化可维护框架与强门控数据可信机制,且大部分模型的训练及推理的开销较大、工程侧难以满足毫秒级约束。

综上,现有以无人机机载传感器为中心的航迹异常检测方法虽在单机侧有效,但面对低空管控平台的网联化数据特征,数据异常证据没有统一的度量指标且大部分参数无规范化取值,难以准确判定航迹行为异常;当前预测修正模型所使用的深度学习模型加滤波的方法,通常是松耦合级联形式,无法链接异常检测和修正双功能,也无法针对滤波进行更新优化;同时,现有研究所用的异常检测和修正模型框架算力开销较大,难满足毫秒级工程约束。针对上述问题,本研究提出端到端的物理感知卡尔曼长短时记忆网络(End-to-end Physics-aware Kalman LSTM, E2P-AKL)模型,经实际数据验证对于开发低空交通管控平台的航迹实时异常检测及预测修正功能具备有效性。

1 E2P-AKL 模型

1.1 模型框架实现

模型功能构想如图1所示。构建异常检测到预测修正一体化的端到端模型框架,在异常检测架构中,以统计离群、物理包线、形态模式与序列残差4种行为分量为基础,形成可在 $[0,1]$ 区间直接比较与调度的统一异常分数,加入自适应阈值和权重获得稳定的异常与非异常二分类标签,用作弱监督信号。在训练过程中,以损失约束形式进入训练,并通过端到端反传间接调节特征融合模块,该模块结合反传特征和预测修正框架中学习到的序列特征,输入进分类头触发异常判定。在预测修正架构中,采用单向双层 LSTM 结合注意力机制作为时序骨干,以捕获多尺度依赖与关键时刻权重,引入可微分物理积分器,在速度、位置、爬升率等运动学量之间建立可反传的耦合约束,从而在端到端训练中显式注入物理先验,同时通过自适应噪声估计参数化卡尔曼滤波过程中的观测与过程噪声,并实施卡尔曼更新以融合观测与先验,输出预测、重构序列及其不确定

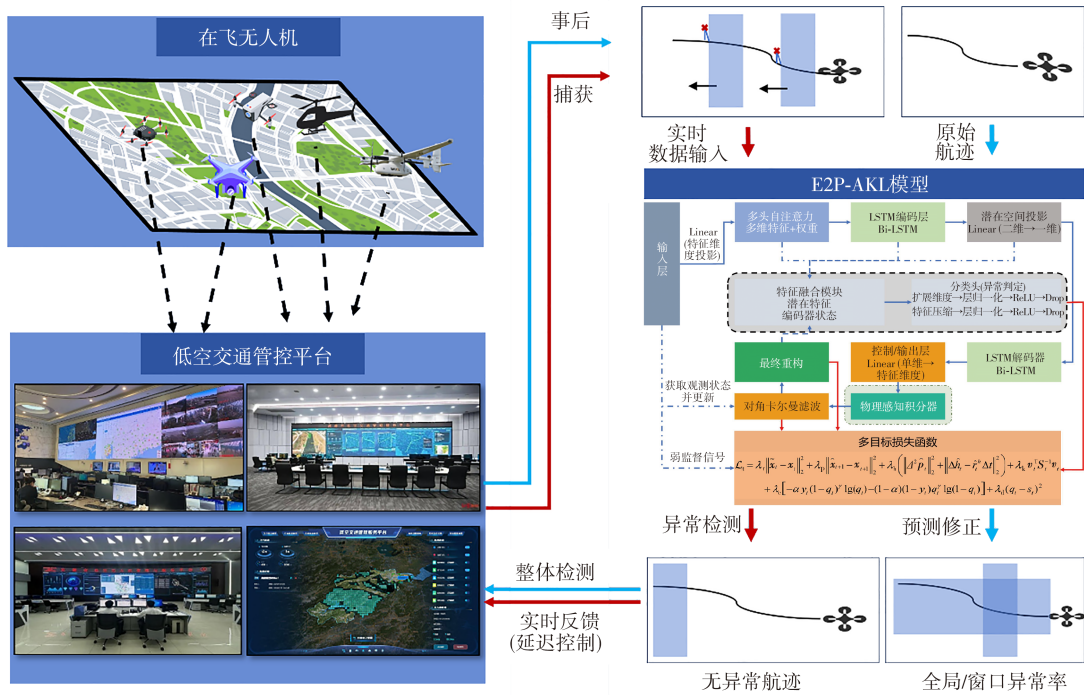


图 1 低空交通管控平台嵌入航迹实时异常检测及预测修正功能构想

Fig. 1 Conceptual of real-time anomaly detection and prediction correction function

定度表征。围绕上述模块设计可回传的多目标损失函数,并采用一致性蒸馏对齐分支输出口径,使分类头输出与预测修正模块输出在同一语义刻度下协同优化与推理,最终构建了E2P-AKL模型框架。整个结构从输入窗口到损失函数单图反向传播,在一个

可微框架内实现异常判定与预测修正的有机融合,减少级联误差与延迟传播。在模型使用过程中,模型不再依赖弱监督信号,使用训练过程中学习到的参数特征,实现异常检测与预测修正的完整功能。模型整体功能如图 2 所示。

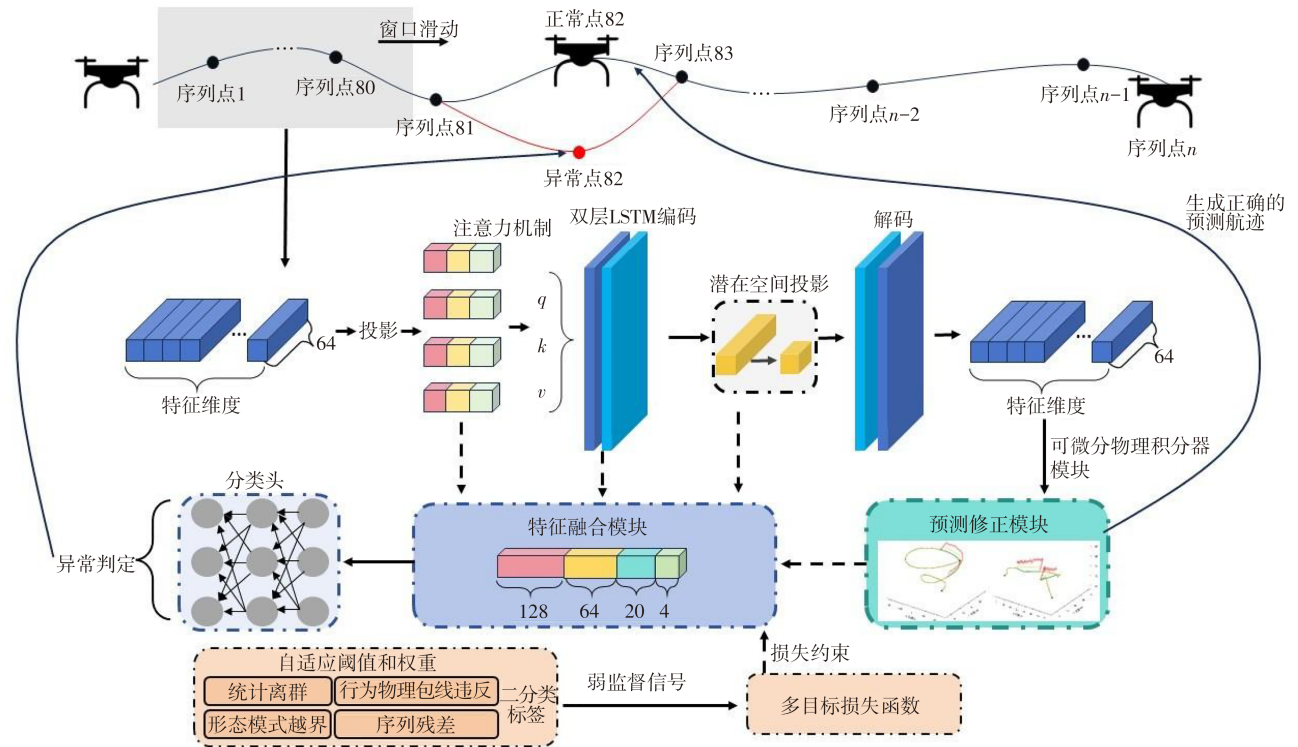


图 2 模型功能实现示意

Fig. 2 Schematic of model function implementation

为将骨干、物理、滤波、残差、形态等多源线索统一到同一判别空间,构建特征融合模块,把骨干注意力表征 \tilde{h}_t 、KF 一致性与不确定度进行拼接,经两层感知器与层归一化得到融合表示 $\tilde{\phi}_t$ 。在其上连接线性与乙状函数,输出为 $q_t \in (0, 1)$ 。

在多分支输出的检测框架中,不同分支的分类头和预测修正输出的内容,往往仅面向各自的特征空间进行异常判定,虽然能够丰富判别的多样性,但其输出尺度与数值口径可能存在显著差异,本研究在训练过程中引入了一致性蒸馏约束,将多分支分类头的输出和重构预测输出统一对齐至同一口径^[14-15]。一致性蒸馏仅在训练阶段发挥作用,推理阶段并不会引入额外计算开销,因此能够在不损害实时性的前提下提升多分支融合的判别性能。

总损失由 6 部分加权求和:重构权重 λ_r 下的损失、一步预测权重 λ_p 下的损失、物理平滑性权重 λ_p 下的损失、KF 一致性权重 λ_k 下的损失、分类损失 λ_c 权重下的损失、温和一致性蒸馏权重 λ_d 下的损失。前 4 项保障时序重构、前视预测与物理及滤波自治,分类项把人工标签注入并兼顾类不平衡;蒸馏项以小权重将分类输出 q_t 的排序牵引到与统一分数 s_t 一致,从而让训练的概率刻度与实际使用模型时的判别刻度对齐并且不冲突。优化器采用权重衰减的自适应矩估计(Adam with Weight Decay, AdamW)用于损失梯度下降^[16],预测能力使用标签强制加逐步

放宽的原则,减小曝光偏差。损失函数计算公式如下

$$\mathcal{L}_t = \lambda_r \|\tilde{x}_t - x_t\|_2^2 + \lambda_p \|\hat{x}_{t+1} - x_{t+1}\|_2^2 + \lambda_p \left(\|\Delta^2 \hat{p}_t\|_2^2 + \|\Delta \hat{h}_t - \hat{r}_{h,t} \Delta t\|_2^2 \right) + \lambda_k v_t^T S_t^{-1} v_t + \lambda_c [-\alpha y_t (1 - q_t)^\gamma \lg(q_t) - (1 - \alpha)(1 - y_t) q_t^\gamma \lg(1 - q_t)] + \lambda_d (q_t - s_t)^2 \quad (1)$$

式中: x_t 为时刻 t 的真值状态向量; \tilde{x}_t 为由编码器和解码器对 x_t 重建结果; \hat{x}_t 为预测分支对 t 时刻的预测状态; \hat{p}_t 为 \hat{x}_t 中的位置分量; Δ^2 为二阶离散差分算子; \hat{h}_t 为预测 t 时刻的高度; $\hat{r}_{h,t}$ 为预测的爬升率; Δt 为采样时间间隔; v_t 为 KF 模块中的残差; S_t 为创新协方差矩阵; α 为类不平衡权重与聚焦因子; q_t 为分类输出; s_t 为统一分数。

整套结构在单一计算图中进行反向传播,形成异常检测加预测修正的端到端模型框架。LSTM、注意力、融合层与分类头自然可微;运动积分器由线性更新与旋转矩阵组成,对 $(v_t, \theta_t, r_{h,t})$ 的梯度稳定;KF 模块通过解线性方程与乔列斯基因式分解实现对增益与创新的稳定反传,避免显式求逆带来的病态。训练中对梯度实施全局裁剪,对极端残差采用胡贝(Huber)截断,噪声协方差使用 Softplus 和对角低秩参数化以保证正定^[17]。实现端到端可微、数值稳定、语义一致的 E2P-AKL 模型。模型结构如图 3 所示。

在 E2P-AKL 模型中,原始航迹特征首先经过

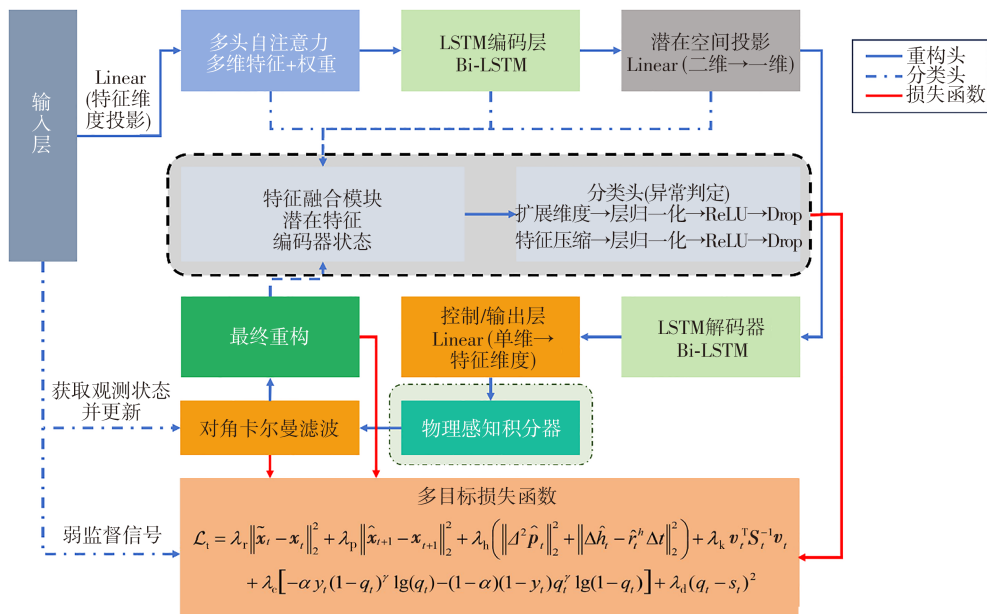


图 3 模型结构

Fig. 3 Model structure

编码器提取时序表示,随后通过物理感知卡尔曼更新模块与预测修正分支进行联合建模,生成异常判定结果与修正后的轨迹。训练阶段,模型的多任务损失同时包含了异常检测精度约束、轨迹预测误差约束以及一致性蒸馏正则项。反向传播过程中,损失梯度能够跨越物理积分器、噪声自适应估计与LSTM表征层,逐层传回到最前端的特征编码部分,编码器学到的表示更贴合后续异常判定与修正需要,物理模块的参数在检测与修正性能的双重反馈下自适应更新,该模型设计使检测与修正共享表征与不确定性,使整个系统能够在同一优化框架中实现较低时延的异常检测与轨迹修正。

1.2 质量检测

本研究基于累计飞行时长、经纬度和飞行状态信息,提取了时间间隔、位置距离、速度、加速度、高度变化率和航迹角变化率等衍生特征,在获得衍生特征后,对数据本身的可信度进行定量评估,以降低链路、传感器等非行为因素带来的误判风险。此节为数据清洗工作,判断目标设置较为宽泛,满足正常物理约束和数据一致性后则进入下一个异常判定阶段。本研究设计了平台所采集的航迹数据质量、速度一致性、时间一致性、数据完整性和物理合理性的5类指标,并进一步结合物理合理性检查形成总体质量评分。

对于航迹数据质量,采用两点之间的经纬度球面距离是否满足物理合理性来评判数据质量,在此由于采样点间隔为2 s,运行速度不超越 $50 \text{ m} \cdot \text{s}^{-1}$,航迹数据质量评分定义为

$$Q_{\text{track},i} = \begin{cases} 1 & d_i \leq 100 \text{ m} \\ 0 & d_i > 100 \text{ m} \end{cases} \quad (2)$$

式中: $Q_{\text{track},i}$ 为第*i*个采样点的航迹数据质量评分; d_i 为第*i*个采样点与前一采样点之间的球面距离。

为了评估位置计算速度与设备速度的一致性,本研究引入速度一致性指标 $Q_{\text{spd},i}$,其计算表达式为

$$Q_{\text{spd},i} = \frac{1}{1 + |v_{\text{calc},i} - v_i|/10} \quad (3)$$

式中: v_i 为第*i*个采样点的设备速度; $v_{\text{calc},i}$ 为第*i*个采样点的计算速度。

为了衡量累计时长的合理性,定义时间一致性指标,即时间戳单调递增的比例,计算方式如下

$$Q_{\text{time}} = \frac{1}{N-1} \sum_{i=2}^N \mathbb{I}(\Delta t_i \geq 0) \quad (4)$$

式中: Q_{time} 为整条航迹的时间一致性评分; $\mathbb{I}(\cdot)$ 为指示函数; Δt_i 为采样时间间隔; N 为单轨迹采样点数。

由低空交通管理与服务平台下放的数据,在传输过程中同时存在丢失情况,连续的序列数据中会传输空值,为评估数据完整性,研究选择关键字段集合 \mathcal{K} ,计算每一行非空字段的比例,定义如下

$$Q_{\text{comp},i} = \frac{\sum_{k \in \mathcal{K}} \delta_{i,k}}{|\mathcal{K}|} \quad (5)$$

式中: $Q_{\text{comp},i}$ 为第*i*个采样点的数据完整性评分; $\delta_{i,k}$ 为二值判定值,若第*i*个采样点在第*k*个字段中不是空值则 δ 为1,否则为0。

研究还对速度、高度、航迹角设定物理阈值,若违反则按规则施加惩罚因子,规则设定为,速度超越飞行器物理极限,高度为负值,航迹角越过 -360° 到 360° 范围内。据此得到物理合理性指标 $Q_{\text{phys},i}$ 为

$$Q_{\text{phys},i} = \prod_{\beta \in B} \lambda_{\beta} \quad (6)$$

式中: λ_{β} 为对应物理约束的惩罚系数。

综合评分 Q 的定义为

$$Q = \prod_k Q_{k,i} = \mathbb{I}(\min_k Q_{k,i} = 1) \quad (7)$$

式中: $Q_{k,i}$ 为第*i*个采样点的第*k*项质量评价指标。

本研究应用场景中仅有少部分数据出现质量异常,而较多的异常主要源于行为,此处采用强门控策略,以轨迹为单位,仅保留轨迹级质量分为1的样本进入后续流程,其余直接删除,不参与训练、验证、测试。清洗后的数据不会引入系统性偏置,且能显著降低后续标签噪声与误报风险。此节只判数据可信,不判行为异常其中 $Q_{k,i}$ 只用于数据健康度、完整性与数据剔除,不输出飞行异常的结论,相应的行为越界判定在下一节内完成。

1.3 异常分数检测

在通过第1.2节的轨迹级门控后,本研究仅在质量达标的样本, Q_{overall} 为1的前提下判定飞行行为异常。丢包等链路层问题不再作为行为异常的一部分,时间间隔异常仅保留为监测量而不参与融合。本研究构造四类行为分量:统计离群、行为物理包线违反、形态模式越界、序列残差,并在融合后将连续分数投影为异常值。

在统计离群方面,以标准化残差衡量特征偏离稳态统计的程度,先对特征计算标准化残差(z -score),再通过阈值归一与加权聚合得到统计离群分数。当序列状态出现轻度漂移时,统计量的微小偏移即可被快速捕捉,从而提升对早期异常的灵敏性。离群计算方式为

$$\begin{cases} z_{f,i} = \frac{|x_{f,i} - \mu_f|}{\sigma_f} & f \in \mathcal{F} \\ s_{\text{stat},i} = \min \left\{ 1, \sum_{f \in \mathcal{F}} \left[\alpha_f \max \left\{ 0, \frac{z_{f,i} - \tau_z}{\tau_z} \right\} \right] \right\} \\ \sum_f \alpha_f = 1 \end{cases} \quad (8)$$

式中: $x_{f,i}$ 为第 i 点特征 f 的取值; μ_f, σ_f 分别为特征 f 的均值与标准差; \mathcal{F} 为统计监测特征值; τ_z 为统计阈值; α_f 为特征内权重; $s_{\text{stat},i}$ 为第 i 点的离群值。

作为硬约束层面的安全判据, 行为物理包线分数专注于机型操作上限, 由上报的制造商编号识别机型, 从而判断速度、加速度、爬升率、转弯率上限值。采用乘性惩罚的互补量构造, 若速度上限、加速度上限与爬升率上限同时被触发, 整体分数将显著上升, 反映更高的运行风险级别, 呈现多重越界叠加效应。物理包线异常分数 $s_{\text{phys},i}$ 计算为

$$s_{\text{phys},i} = 1 - \prod_{c \in \mathcal{C}} \lambda_{c,i} \quad \lambda_{c,i} \in (0, 1] \quad (9)$$

式中: \mathcal{C} 为包线约束集合; $\lambda_{c,i}$ 为第 i 点对约束 c 的满足度。

首先确定每种机型的物理参数特征, 若当前机型存在特定的物理上限值, 则直接使用, 若不存在时, 以当前训练集和该机型品牌参考值为基础, 先对瞬时量做 5 点滑窗平滑, 再取绝对值的 99.9% 分位并乘以安全裕度 η 得到替代上限, η 为误差预算下的安全裕度值, 计算公式如下

$$\begin{cases} \eta = \eta_{\text{noise}} + \eta_{\text{late}} + \eta_{\text{stat}} \\ \eta_{\text{noise}} = \frac{z_{0.999} \sigma_i}{Q_{0.999}(X_i)} \\ \eta_{\text{late}} = \frac{\Delta X_{i,\text{max}}(\Delta t)}{Q_{0.999}(X_i)} \\ \eta_{\text{stat}} = \frac{\hat{b}_{0.999}^{\text{up}} - \hat{b}_{0.999}}{\hat{b}_{0.999}} \end{cases} \quad (10)$$

式中: X_i 为第 i 项物理量; $Q_{0.999}(\cdot)$ 为与当前机型相同类别的样本上进行的估计, 取 99.9% 分位数; η_{noise} 为测量噪声项, 考虑传感器高分位噪声相对量级; σ_i 为噪声标准差; $z_{0.999}$ 为正态近似下的 99.9% 分位系数; η_{late} 为时延项, 表示考虑采样间隔 Δt 与执行时延导致的最大跃变量; η_{stat} 为统计不确定项, 表示考虑 99.9% 分位估计的上置信界; $\hat{b}_{0.999}^{\text{up}}$ 为置信上界; $\hat{b}_{0.999}$ 为分位数估计量。

在此基础上, 包线计算公式如下

$$V_{\text{phys},k} = Q_{0.999}(\|v\|, Q = 1, p_{\text{data},k})(1 + \eta) \quad (11)$$

式中: $V_{\text{phys},k}$ 为 k 类机型速度上限; $p_{\text{data},i}$ 为第 i 类机型下正常飞行和机动飞行的航迹数据。

加速度、爬升率与转弯角速度的上限, 以此类推。为抑制偶发尖峰, 越界判定采用平滑后的值并要求最小持续时长为 3 个采样点时间跨度。

作为软约束的形态模式越界, 模式分数衡量机动强度与几何形态的异常程度。即便未触及包线的硬阈值, 只要逼近上限或出现异常节律组合, 也对其赋予较高异常分数。

$$\begin{cases} s_{\text{pat},i} = \max \left\{ \frac{|\omega_i|}{\Omega_{\text{ref}}}, \frac{|r_{h,i}|}{R_{\text{ref}}}, \frac{|a_i|}{A_{\text{ref}}} \right\} \wedge 1 \\ \Omega_{\text{ref},k} = Q_{0.995}(\|\omega\|, Q = 1, p_{\text{data},k}) \\ R_{\text{ref},k} = Q_{0.995}(\|r^h\|, Q = 1, p_{\text{data},k}) \\ A_{\text{ref},k} = Q_{0.995}(\|a\|, Q = 1, p_{\text{data},k}) \end{cases} \quad (12)$$

式中: $s_{\text{pat},i}$ 为第 i 个点的形式模式分数; $\omega_i, r_{h,i}, a_i$ 分别为第 i 个点的航迹角变化率、爬升率与加速度; $A_{\text{ref},k}, R_{\text{ref},k}, \Omega_{\text{ref},k}$ 分别为航迹角变化率、爬升率、加速度的机型 k 参考基础上界。

序列残差分数用于捕捉渐进漂移与周期性抖动等具有时间相关性的异常, 以重构的平方误差作为残差, 并进行稳健标准化映射到 $[0, 1]$, 序列残差分数定义如下

$$\begin{aligned} s_{\text{seq},i} &= \Phi \left(\frac{r_i - \mu_r}{\sigma_r} \right) \\ r_i &= \|x_i - \hat{x}_i\|_2^2 \end{aligned} \quad (13)$$

式中: $s_{\text{seq},i}$ 为第 i 采样点残差分数; $\Phi(\cdot)$ 为归一函数; r_i 为第 i 重构平方残差; x_i 为观测值; \hat{x}_i 为重构值; μ_r 和 σ_r 分别为训练集均值和标准差。

在融合阶段, 4 个分量以凸组合形成统一异常分数, 计算方式如下

$$\begin{cases} s_i = Q(\beta_{\text{phys}} s_{\text{phys},i} + \beta_{\text{stat}} s_{\text{stat},i} + \beta_{\text{pat}} s_{\text{pat},i} + \beta_{\text{seq}} s_{\text{seq},i}) \\ \sum \beta = 1 \quad Q \in (0, 1] \end{cases} \quad (14)$$

式中: s_i 为第 i 点统一异常分数; $\beta_{\text{phys}}, \beta_{\text{stat}}, \beta_{\text{pat}}, \beta_{\text{seq}}$ 均为四行为分量融合权重。

权重在验证集上通过随机搜索选择, 适度提高, 以保证法规越界类风险获得更高敏感性。最终, 连续异常分数以驱动后续的模型预测修正策略。为与本研究的建模目标保持一致, 统一异常分数 s_i 直接用于二分类决策, 当分数超过单一阈值 τ 时判为异常, 否则为非异常。

$$\hat{y}_i = 1 \{s_i \geq \tau\} \quad (15)$$

式中: \hat{y}_i 为第 i 个采样点的二分类预测标签, 异常序列标记为 1, 非异常标记为 0。

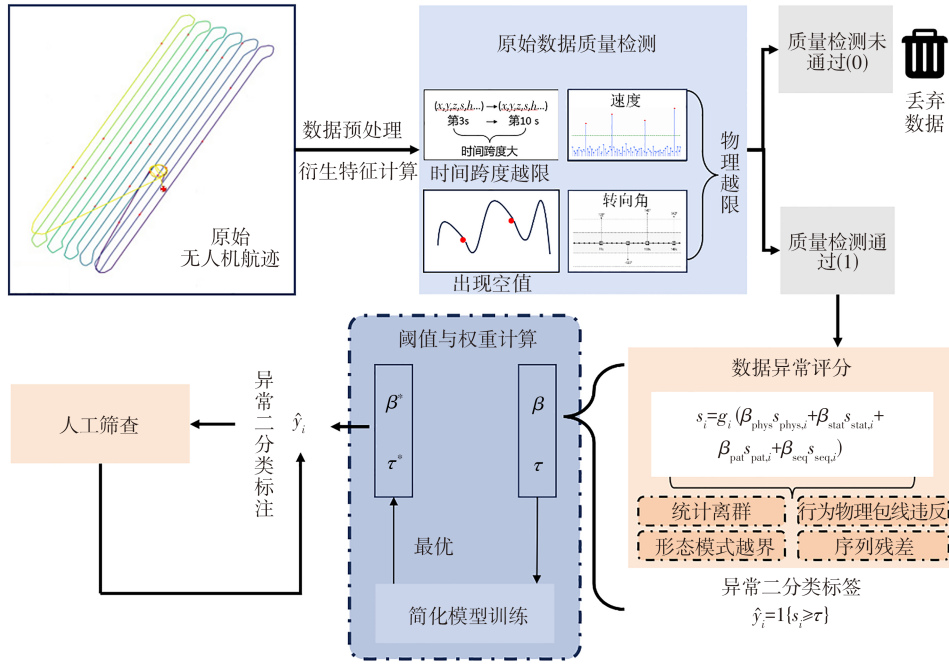


图 4 异常检测框架

Fig. 4 Anomaly detection framework

异常检测框架如图 4 所示。

综上,本研究运用点级二分类判定准则,将统一异常分数转化为可执行的二元决策,阈值 τ 的数据驱动选择,将在试验设计部分呈现。

1.4 阈值与权重选择

本节在前文超参数设定的基础上,给出统一异常分数的融合权重 β 与二分类判别阈值 τ 的确定方法。所有可学习超参数均在验证集上选择并冻结,定义阈值候选集与搜索流程。

为便于表述,将之前章节中的统一异常分数写作

$$\begin{cases} s_i(\beta) = \sum_{k=1}^4 \beta_k s_{k,i} \\ \beta \in \Delta_4: = \{ \beta_k \geq 0, \sum_{k=1}^4 \beta_k = 1 \} \end{cases} \quad (16)$$

为保证阈值选择的稳健性,采用 0.1 间隔网格扫描确定阈值取值,最终的最佳阈值定义为

$$\tau^* = \operatorname{argmax}_{\tau \in T} U(\beta, \tau) \quad (17)$$

式中: $U(\beta, \tau)$ 为在验证集上使用模型性能评估得到的综合效用。

融合权重 β 采用 0.1 粒度在 4 维单纯形 Δ_4 上离散取值,其表达式为

$$\beta_{0.1} = \left\{ \beta: \beta_k \in \{0, 0.1, \dots, 1.0\}, \sum_{k=1}^4 \beta_k = 1 \right\} \quad (18)$$

权重与阈值的经验最优解以两层最大化形式

给出

$$\beta^* = \operatorname{argmax}_{\beta \in \beta_{0.1}} \max_{\tau \in T} U(\beta, \tau) \quad (19)$$

将得到的 (β^*, τ^*) 冻结于测试与实际测试阶段,若在求最优解求解时,多组 (β, τ) 给出相同 U , 则选择欧几里得范数最小的 β 作为平局破坏准则,可提升当前阈值和权重选择的跨数据集泛化性。

1.5 预测修正模型

预测模型骨干采用单向双层 LSTM, 处理输出窗口 $X \in \mathbb{R}^{W \times d}$ 的时间序列, 逐步输出隐状态 h_t , 并通过注意力得到加权上下文 \tilde{h}_t 。该设计在保持参数量与时延可控的前提下, 可兼顾突变机动与缓变趋势。

为显式刻画速度与位置、爬升与高度的一致性, 建立物理感知型积分器, 适配当前的飞行器物理特征。骨干表征 \tilde{h}_t 先回归出运动量估计 $(v_t, \theta_t, r_{h,t})$, 再进入可微分欧拉积分器传播离散状态, 离散状态定义为

$$z_t = (x_t, y_t, h_t, v_{x,t}, v_{y,t}, v_t^h)^T \quad (20)$$

水平速度分量由旋转矩阵生成

$$\begin{cases} \begin{bmatrix} v_{x,t+1} \\ v_{y,t+1} \end{bmatrix} = \mathbf{R}(\theta_t) \begin{bmatrix} v_t \\ 0 \end{bmatrix} \\ \mathbf{R}(\theta) = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \end{cases} \quad (21)$$

式中: $\mathbf{R}(\cdot)$ 为旋转矩阵; θ 为位置倾角。

位置与高度按 $x_{t+1} = x_t + v_{x,t}\Delta t$, $y_{t+1} = y_t + v_{y,t}\Delta t$, $h_{t+1} = h_t + v_{h,t}\Delta t$ 更新。积分器参与反向传播,使网络在学习判别与重构的同时,被动满足基本运动学约束,显著降低物理噪声影响的风险。

在积分先验上引入 KF 模块以抵御观测噪声与间歇异常^[18]。采用离散匀速模型并允许过程噪声吸收未建模扰动,状态方程定义如下

$$\begin{aligned} \mathbf{z}_{t+1} &= F_t \mathbf{z}_t + \mathbf{w}_t & \mathbf{w}_t &\sim \mathcal{N}(0, \mathbf{Q}) \\ F_t &= \begin{bmatrix} I_3 & \Delta t I_3 \\ 0 & I_3 \end{bmatrix} \end{aligned} \quad (22)$$

式中: F_t 为状态转移矩阵; $\mathbf{w}_t \sim \mathcal{N}(0, \mathbf{Q})$ 为过程噪声, \mathbf{Q} 为过程协方差矩阵; I_3 为单位阵。

数据传输过程中,飞行器的位置速度均可得,将传感器给出的经纬度、高度、全向速度一并作为观测向量,得到观测方程,其定义为

$$\mathbf{y}_t = (x_{\text{sensor},t} \ y_{\text{sensor},t} \ h_{\text{sensor},t} \ v_{x,t} \ v_{y,t} \ v_{h,t})^T = H\mathbf{z}_t + \mathbf{v}_t \quad \mathbf{v}_t \sim \mathcal{N}(0, \mathbf{R}), \quad H = I_6 \quad (23)$$

式中: $x_{\text{sensor},t}$ 、 $y_{\text{sensor},t}$ 、 $h_{\text{sensor},t}$ 分别为传感器输出经纬度及高度; \mathbf{y}_t 为观测向量; H 为观测矩阵; $\mathbf{v}_t \sim \mathcal{N}(0, \mathbf{R})$ 表示观测噪声。

为保证卡尔曼滤波在实际平台上的平稳性与一致性,在模型与数值层面采用了成套约束与自适应机制。观测协方差矩阵采用分层置信度建模,位置量的噪声方差依据传感器质量实时设定,速度项为由网络输出的地速—航向—爬升率推得的速度伪测量,其方差随网络不确定度或残差大小自适应放大,从源头抑制高不确定观测对滤波的扰动。同时,采用创新一致性校准,以残差的滑窗协方差与理论残差协方差对齐,在线微调 \mathbf{R} , 确保统计一致。残差的计算方式为

$$\nu_t = \mathbf{y}_t - H\hat{\mathbf{z}}_{t|t-1} \quad (24)$$

表 1 试验环境与关键参数配置

Table 1 Experimental environment and key parameter configuration

配置项	说明	配置项	说明
GPU	NVIDIA RTX 3090 (24 GB)	内存	16 GB
CPU	Intel Xeon Gold 6226R (16 核, 2.9 GHz)	CUDA	版本号: 11.8
初始学习率	0.001, 在验证集性能无提升时按 0.5 衰减	cuDNN	版本号: v8.9.0
窗口大小	64	PyTorch	版本号: 2.0.0
潜在表示维度	64	训练轮数	100
批次大小	128	隐藏层维度	128

2.2 数据预处理

2.2.1 数据来源与原始格式

本研究所使用的数据来自无人机厂商向低空交通管控平台上报的运行记录,选择平台 2024 年 6 月

之后,配备异常观测门控,当残差的卡方统计量超出阈值时,降低该时刻观测权重或直接拒收,避免离群点导致耦合发散。数值实现上,协方差更新采用 Joseph 形式以保证非负定,在出现数值不良时进行对称化与微小对角通胀的数值正则。

$$\begin{cases} S_t = HP_{t|t-1}H^T + R \\ K_t = P_{t|t-1}H^T S_t^{-1} \\ \hat{\mathbf{z}}_{t|t} = \hat{\mathbf{z}}_{t|t-1} + K_t(\mathbf{y}_t - H\hat{\mathbf{z}}_{t|t-1}) \\ P_{t|t} = (I - K_t H)P_{t|t-1}(I - K_t H)^T + K_t R K_t^T \end{cases} \quad (25)$$

式中: $\hat{\mathbf{z}}_{t|t-1}$ 和 $\hat{\mathbf{z}}_{t|t}$ 分别为先验及后验状态; $P_{t|t-1}$ 和 $P_{t|t}$ 分别为先验及后验协方差矩阵; S_t 为创新协方差矩阵; K_t 为卡尔曼增益矩阵。

以上策略与实际收取到特征提取的解算管道协同,使得观测融合在物理可解释的前提下具备鲁棒门控、统计一致与数值稳定,整体保证滤波在长期运行中的平稳、可复现。

2 试验设计与结果分析

2.1 试验环境与参数

本研究在统一的硬件与软件环境下开展所有模型训练与评估(见表 1)。硬件环境包括图形处理器(Graphics Processing Unit, GPU)与多核中央处理器(Central Processing Unit, CPU),软件环境基于 Python 与深度学习框架 PyTorch。试验过程中,除特别说明外,均采用相同的优化器、学习率设定和批量大小。为消除算力差异带来的偏置。本研究试验环境与某低空交通管控平台保持同构且同配,采用与平台一致的 CPU、GPU、内存、CUDA、cuDNN、依赖栈,算法模型均通过同一 API 接口调用。后续章节中不同窗口大小的推理时间对比可视为平台侧可复现的生产级结果。

26 日一天中的 8 000 条连续的无人机飞行轨迹序列,选取 60% 作为训练集,20% 作为验证集,20% 作为测试集。低空交通管控平台以批次的形式接收无人机状态数据,每一条记录均对应于某一时刻的无人

机运行状态。在原始数据中,所有记录以离散方式存储,即同一飞行任务的多条状态点并未顺序排列,而是混杂于全量数据中。因此,在进行建模之前,需要首先根据飞行序列号字段对数据进行分组,该字段在数据格式中以唯一字符串形式表示,每次无人机起飞均生成一个新的序列号。例如,序列号 METNFP33052281533484-20240626-35177522 表示某无人机在 2024 年 6 月 26 日的一次完整飞行任

务,其他内容均为随机生成的识别编码,无实际含义。

完成分组后,再依据累计飞行时长对同一飞行序列内的数据进行排序,从而恢复无人机的完整航迹轨迹。为确保建模阶段输入序列具有足够的时序长度,本研究仅保留长度不少于 1 000 条序列长度的完整航迹作为训练与评估样本。原始数据字段含义示例如表 2 所示。

表 2 原始数据字段

Table 2 Raw data field

字段	含义	字段	含义	字段	含义	字段	含义	字段	含义
河北省保定市容城县	飞行位置	4370	海拔高度(精确到小数点后 2 位,乘 10^2 后传输)	1	坐标系类型 1: WGS-84 2:CGCS2000 3:GLONASS- PZ90	155	航迹角(精确到小数点后 1 位,乘 10 后传输)	50	累计飞行时长(s)
23	实时飞行速度(精确到小数点后 1 位,乘 10 后传输)	1270	飞行高度(精确到小数点后 2 位,乘 10^2 后传输)	56d6133f-bc26-44bb-a842-ff39dff865d2	Uid 生成的字符串	2	违规标志 0:正常;1:未注册;2:未上报;3:未在申请空域内	0	是否发送给公安 0:不发送 1:发送
4104baffof9kl0099901	无具体含义	390217536	当前位置的纬度(精确到小数点后 7 位,乘 10^7 后传输)	1159842275	当前位置经度(精确到小数点后 7 位,乘 10^7 后传输)	39.0217536	当前位置的纬度(精确到小数点后 7 位)	115.9842275	当前位置的经度(精确到小数点后 7 位)
914403007954257495	制造商代码	3N3BJ7Q01200H5-20231126-65kG7z2	飞行记录编号	2023-11-26 15:10:19	系统接受时间	20231126151019	时间戳	UAS-DEFAULT	实名登记号(无登记号时以 UAS-DEFAULT 填充)

2.2.2 特征计算

在对无人机运行数据进行处理时,需要将原始字段转化为具有物理意义的导出量,以支持后续的异常检测与预测模型。本研究基于累计飞行时长、经纬度和飞行状态信息,提取了时间间隔、位置距离、速度、加速度、高度变化率和航迹角变化率等衍生特征。

对于时间间隔的计算,本研究采用累计飞行时长字段,通过相邻样本的差分获得单点的时间间隔。当为首个样本时,取固定值以避免除零问题,其定义为

$$\Delta t_i = \begin{cases} 0.1 & i = 1 \\ t_i - t_{i-1} & i \geq 2 \end{cases} \quad (26)$$

式中: t_i 为第 i 个采样点的累计飞行时长。

之后,为了刻画无人机相邻点之间的地理位置变化,采用 Haversine 公式计算球面距离。设地球半径 $R=6\,371\,000$ m,经纬度坐标分别定义为 (φ, λ) ,

则邻点间的距离可表示为

$$\begin{cases} \Delta\varphi = \varphi_i - \varphi_{i-1} \\ \Delta\lambda = \lambda_i - \lambda_{i-1} \\ o = \sin^2\left(\frac{\Delta\varphi}{2}\right) + \cos(\varphi_{i-1})\cos(\varphi_i)\sin^2\left(\frac{\Delta\lambda}{2}\right) \\ \iota = 2\arctan\left[2(\sqrt{o}, \sqrt{1-o})\right] \\ \xi = R\iota \end{cases} \quad (27)$$

式中: φ_i 和 λ_i 分别为第 i 个采样点的弧度制纬度和经度; $\Delta\varphi$ 和 $\Delta\lambda$ 分别为相邻采样点的纬度差与经度差; o 为 Haversine 公式的中间变量; ι 为中心角; ξ 为换算后的运动距离。

基于距离与时间间隔,可以进一步推导出位置计算速度,其定义为

$$v_{\text{calc},i} = \frac{\xi_i}{\Delta t_i} \quad (28)$$

式中: ξ_i 为第 i 个点与其下一个点之间的距离; $v_{\text{calc},i}$ 为基于位置计算得到的瞬时速度,对于每条序列的

第一个点,设置其计算速度为0。

在此基础上,为刻画速度的变化趋势,本研究计算了相邻时刻的加速度,其计算公式为

$$a_i = \frac{v_i - v_{i-1}}{\Delta t_i} \quad (29)$$

式中: a_i 为第*i*个采样点的加速度; v_i 为在实时飞行速度字段中,无人机传感器实时上报的实际速度。

对于第一个采样点,其加速度为0。

同样,可以利用高度变化推导出爬升或下降速度,即高度变化率,定义为

$$r_{h,i} = \frac{h_i - h_{i-1}}{\Delta t_i} \quad (30)$$

式中: $r_{h,i}$ 为第*i*个采样点的高度变化率; h_i 为飞行高度字段中记录的每个采样点的实时飞行高度。

对于第一个序列其高度变化率取0。

对于航迹角变化率,首先需要对角度差进行归一化以避免跨越 0° 或 360° 的跳变,考虑时间间隔后得到的角速度为

$$\omega_i = \frac{\Delta \phi_i}{\Delta t_i} \quad (31)$$

式中: ω_i 为第*i*个采样点的航迹角变化率; $\Delta \phi_i$ 为跨越修正后的航迹角差。

同样第一个采样点的角速度设定为0。

2.2.3 数据集构建

首先根据第1.2节的质量评分实现数据强门控,之后对每条合格航迹采用滑动窗口切片,窗口长度定义为 W ,步长定义为 S ,在索引 $[i, i + W - 1]$ 上取第一个窗口,在 $[i + S, i + S + W - 1]$ 上取下一个窗口,直至覆盖整条航迹,得到窗口集合 $\{W_j\}$ 。对于第*j*个样本,定义输入张量为

$$X_j \in \mathbb{R}^{W \times d} \quad (32)$$

式中: W 为行维,代表时间轴; d 为列维,代表物理特征,列维包含第2.2.1节中的核心物理特征。

标签生成依托统一异常分数 s_i 的点对点二分类规则,在使用简化模型通扫阈值选择之后,得到的异常判定,再通过人工介入的方式,针对特定品牌下的特殊机型,对高机动性飞行情况进行鉴定,以提升模型区分强机动与真正异常的能力。

最后,按飞行序列号为最小单元执行无泄露划分,将窗口样本按照60%、20%、20%划分为训练、验证、测试3部分,禁止同一航迹跨分区,同时对不同机型做分层,保持不同场景统计分布近似一致。得到3套 (X, y) 窗口级监督样本,其中训练集用于模型参数学习与损失权重、规范化统计的拟合,验证集

用于融合权重与阈值的选择与早停,测试集仅用于最终客观评估。

2.3 阈值与权重计算

为了研究融合权重 β 与二分类判别阈值对整体性能的影响,本章首先基于第1.1节提出的端到端模型,构建了一个简化试验框架。该框架由LSTM提取潜在表示,并通过异常分数头与轻量分类头分别输出统一异常分数与分类置信度。简化模型具备完整闭环,但剔除了复杂预测修正与多模块耦合,以避免非核心因素干扰。

考虑到本研究任务中存在异常样本比例较少、低误报约束、实时检测需求等特征,选取平均精确率-召回率曲线下面积(Area Under the Precision-recall Curve, AUPRC)、ROC曲线下面积(Area Under the Receiver Operating Characteristic Curve, AUROC)、F1值为固定阈值下的调和均值分数,真阳性率(True Positive Rate, TPR)、假阳性率(False Positive Rate, FPR)、TPR@FPR=0.5%和TPR@FPR=1%(在限制FPR分别小于等于0.5%和1%的条件下,曲线上满足条件的最大TPR)。以上指标的联合使用,可以从整体判别性能、单一阈值性能和安全约束性能3方面全面评价模型效果。

试验在测试集中值0.5上左右分布,跨间隔递增的方式通扫所有组合排列,并与 $\beta=0$ 和 $\beta=1$ 两类基线进行对比,能够较为全面地表达指标与 β 之间的变化关系,对每组组合均计算上述5类指标,绘制指标随 β 变化的折线图,其中不同 τ 值分别对应不同曲线。

如图5所示,AUPRC随 β 的变化呈现典型的中间优于两端趋势。无论 τ 取值如何, $\beta \approx 0.5 \sim 0.6$ 区间均显著优于 $\beta=0$ 或 $\beta=1$ 。测试集中,最优结果出现在 $\beta=0.55$, $\tau=0.47$,AUPRC达到0.80,相比于 $\beta=0$ 与 $\beta=1$ 两类基线分别提升了约8%与16%。AUROC在 β 不同区间波动不大,但同样在 $\beta \approx 0.55$ 时达到最高值0.925。说明融合策略在保持全局区分性的同时,也能带来稳健提升。图形也显示在严格限制误报率为1%时的检测能力。最优组合 $\beta=0.55$, $\tau=0.47$ 时,TPR达到0.60,比两类基线分别高出0.08与0.14,验证该组合在安全敏感场景下的优势。进一步收紧误报率至0.5%后,整体检测率有所下降,但最优点仍位于 $\beta \approx 0.55$ 附近,此时TPR为0.48,较基线仍保持显著优势。

基于此,本研究后续所有试验与部署均固定采用 $\beta=0.55$, $\tau=0.47$ 作为默认融合配置。

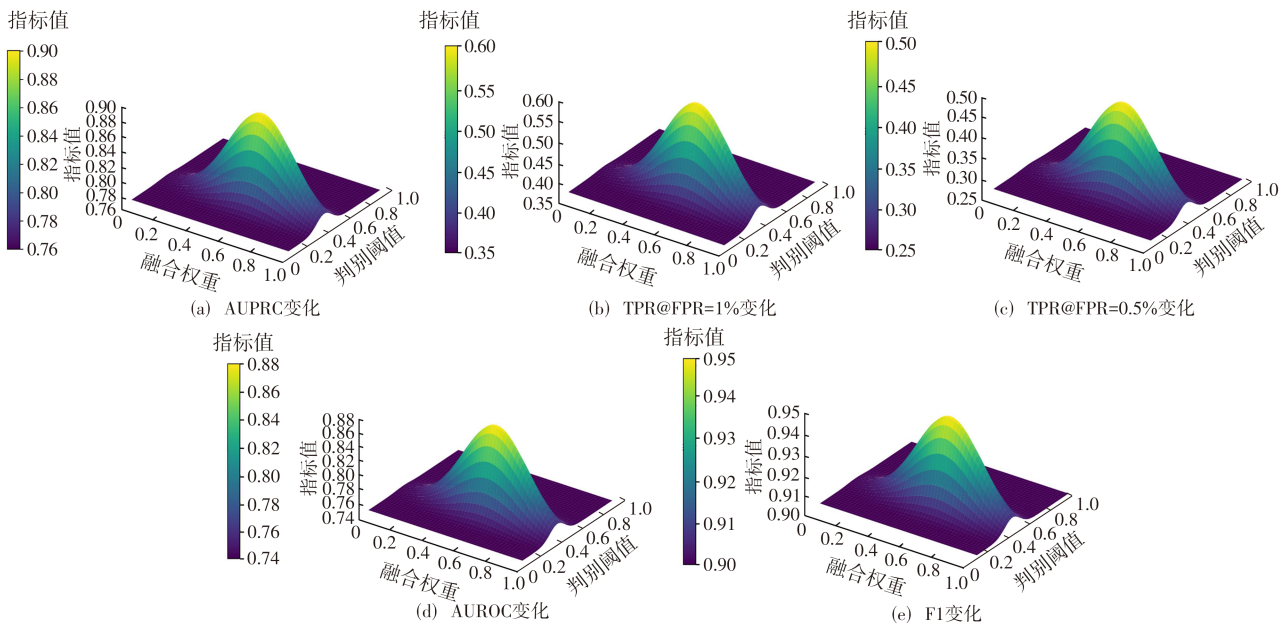


图5 随阈值与权重组合变化下的各指标值

Fig. 5 Values of each indicator under the change of threshold and weight combination

为验证物理包线中安全裕度 η 的稳健性,在保持数据清理强门控、模型结构与训练设置不变的前提下,固定 β 和 τ ,仅对安全裕度 η 网格扫描与细化搜索,在当前数据中 $\eta_{\text{noise}} \in [0.02, 0.05]$, $\eta_{\text{late}} \in [0.01, 0.03]$, $\eta_{\text{stat}} \in [0.02, 0.05]$,据此计算 $\eta \in [0.05, 0.15]$,搜索步长为 0.01,试验得到的 AUROC 与 AUPRC 的相对波动均小于 1.5%,在固定阈值条件下的 FPR 变化低于 0.3%,该区间内模型整体性能变化极小,满足试验所需的稳定性,根据第 1.3 节中对 η 定义, η 取 0.1 是在本数据集的误差预算区间中点位选择,既满足工程安全冗余,也避免过度保守带来的误检。

2.4 异常检测对比试验

为验证所提出的 E2P-AKL 模型在异常检测任务中的有效性,本研究选取常见的基线方法进行对比,包括:长短期记忆自编码器(Long Short-term Memory Autoencoder, LSTM-AE)^[19]、卷积长短期记忆网络(Convolutional Long Short-term Memory, ConvLSTM)^[20]、基于卷积循环重建的多变量时间

序列异常检测(Multivariate Time-series Anomaly Detection via Convolutional Recurrent Reconstruction, MSCRED)^[21]、孤立森林(Isolation Forest)与单类支持向量机(One-class Support Vector Machine, One-class SVM)。此外,还引入第 2.3 节中去除物理感知与卡尔曼结构的内部简化版本。

所有模型均在相同数据划分下训练与评测。阈值和权重使用第 2.3 节当中的最优融合配置。在此试验中也采用第 2.3 节当中的 5 项指标作为评价依据,试验结果如表 3 所示。

可以看出, E2P-AKL 在所有指标上均表现最佳。其在精确率为 0.903、召回率为 0.845 的基础上实现了调和均值分数 $F1=0.873$,明显优于其他方法。同时本研究采用全指标热力图来展示多维性能,结果如图 6 所示。

为了突出代表性指标的提升情况,将 E2P-AKL 与次优深度基线 MSCRED 进行逐项对比 F1 值由 0.824 增加到 0.873,提升约 5.95%, AUPRC 从 0.866

表 3 异常检测对比试验结果

Table 3 Anomaly detection comparison experimental results

模型	精确率	召回率	调和均值	AUPRC	AUROC	TPR@FPR = 1%	TPR@FPR = 0.5%
E2P-AKL	0.903	0.845	0.873	0.902	0.946	0.612	0.492
简化模型	0.881	0.812	0.845	0.878	0.932	0.574	0.456
LSTM-AE	0.836	0.784	0.809	0.852	0.917	0.528	0.402
ConvLSTM	0.842	0.792	0.816	0.858	0.92	0.536	0.408
MSCRED	0.851	0.798	0.824	0.866	0.924	0.542	0.414
Isolation Forest	0.801	0.750	0.775	0.812	0.890	0.480	0.360
One-class SVM	0.792	0.742	0.766	0.804	0.884	0.468	0.348

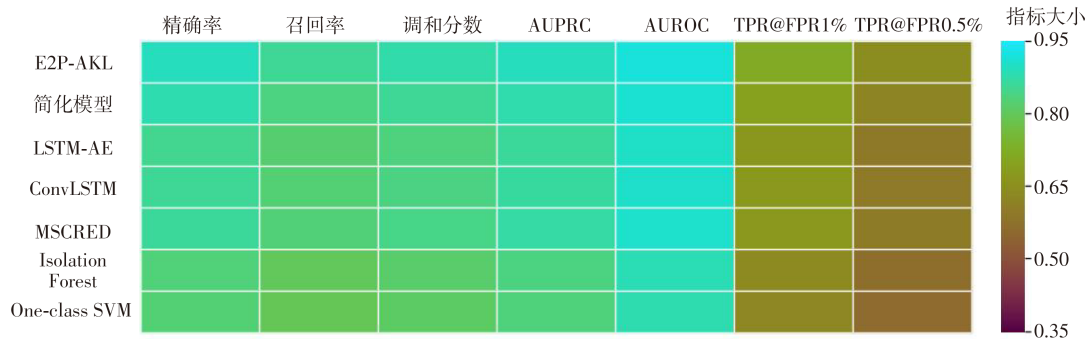


图6 指标热力图

Fig. 6 Indicator heatmap

增加到0.902,提升了约4.16%,AUROC从0.924增加到0.946,增加约2.38%,在低误报约束场景下,TRP@FPR=1%由0.542增加到0.612,提升了约12.9%,TRP@FPR=0.5%由0.414增加至0.492,提升了约18.8%,说明在误报极低时仍能保持更高检出能力。

综上,本节试验验证了E2P-AKL模型模型在异常检测任务中的突出性能。通过与深度基线和传统方法的对比,E2P-AKL模型不仅在综合性能上显著优于现有方法,而且在低误报约束条件下保持较高召回率。结果表明,物理感知与卡尔曼过滤器状态更新的融合是实现高可靠异常检测的关键。

2.5 预测修正消融试验

本节评估所提出的E2P-AKL模型在预测修正任务闭环任务中的有效性。给定观测序列与异常干扰,模型输出位置轨迹与高度的连续预测并对异常段进行在线修正。所有方法在相同的数据划分与预处理流程下训练与评测。

为同时刻画总体误差、前缀稳定性与三维要素,采用如下指标。

(1)逐时刻位置误差

$$e_t = \|\hat{p}_t - p_t\|_2 \quad (33)$$

式中: \hat{p}_t 为预测的平面位置; p_t 为真实的平面位置。

(2)轨迹偏差

$$\lambda = \frac{1}{T} \sum_{t=1}^T \|\hat{p}_t - p_t\|_2 \quad (34)$$

式中: T 为一条航迹的总时间; λ 为轨迹误差。

(3)高度偏差

$$\hat{h} = \frac{1}{T} \sum_{t=1}^T |\hat{h}_t - h_t| \quad (35)$$

式中: \hat{h}_t 为预测高度; h_t 为真实高度; \hat{h} 为高度误差。

为判断在时序当中每一个时间点上的均方根误差,建立前缀误差

$$M = \sqrt{\frac{1}{t} \sum_{i=1}^t e_i^2} \quad (36)$$

式中: M 为均方根误差; e_i 为第*i*个点的位置误差

在该试验节中,仅使用KF模块和不使用KF模块的E2P-AKL预测模型与本研究提出的E2P-AKL模型进行对比。试验结果如表4所示。

表4 预测修正试验结果

Table 4 Experimental results of the prediction correction function

类型	均方误差	均方根误差	轨迹误差	高度误差
预测模块	0.154	0.392	1.284	0.965
KF模块	0.131	0.362	1.102	0.832
E2P-AKL模型	0.094	0.307	0.846	0.654

试验结果显示,E2P-AKL模型在预测与修正任务中相较于两类基线均取得显著优势。使用相对误差指标:相对均方根误差改进率、相对高度改进率、相对轨迹偏移率来评价模型。与仅使用KF模块相比,E2P-AKL模型在相对均方根误差改进率、相对轨迹偏移率与相对高度改进率分别为15.2%、23.3%、21.4%;与仅使用预测模块相比,降幅更为明显,相对均方根误差改进率、相对轨迹偏移率与相对高度偏移率分别为21.7%、34.1%、32.3%。这一结果表明,E2P-AKL模型在整体误差控制、轨迹偏差削减以及高度修正方面均具备显著优势,验证了端到端融合深度表征与物理滤波机制在提高预测精度与稳健性上的有效性。将训练好的模型在三维要素层面上进行预测修正,随滑动窗口,进行逐点式修正,修正结果如图7~9所示。

在异常区间内,仅预测轨迹明显偏离真值,仅KF模块和预测模块仅作部分回拉;E2P-AKL模型的轨迹与真值高度对齐,异常结束后迅速回到稳态。

E2P-AKL模型对高度异常的抑制最为明显,异常后快速逼近真值并保持低偏差,说明所提框架在三维要素上的协同一致性。

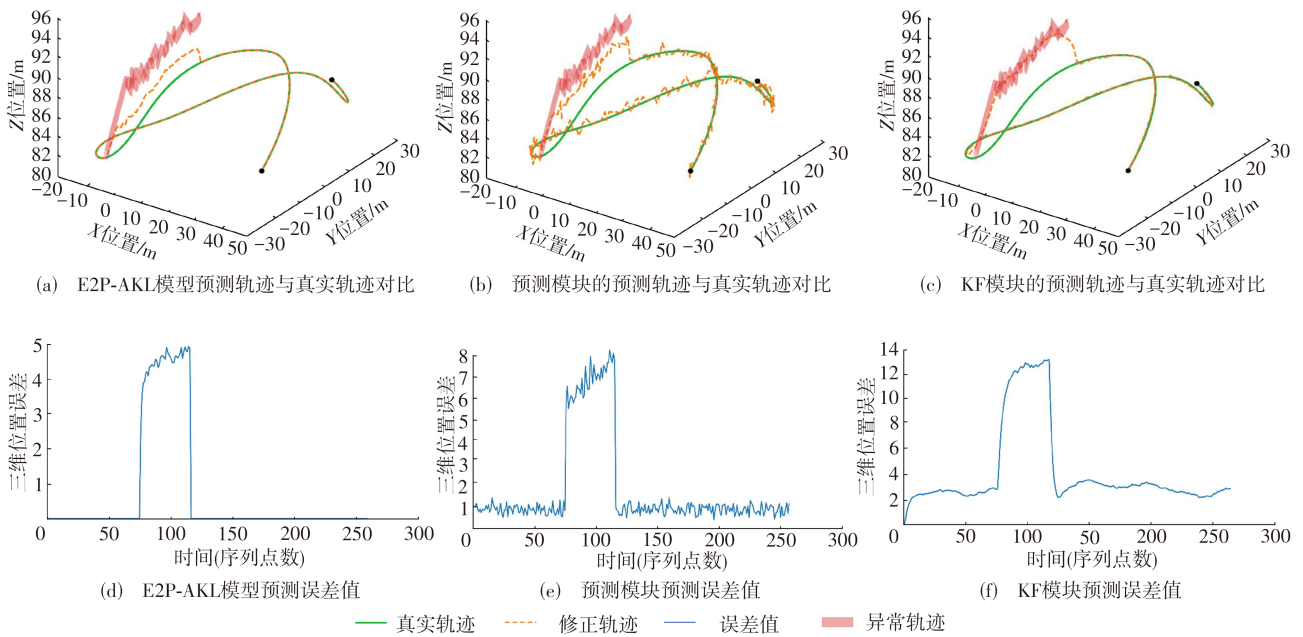


图7 预测修正试验试验结果(轨迹1)

Fig. 7 Predicting and correcting experimental results (track 1)

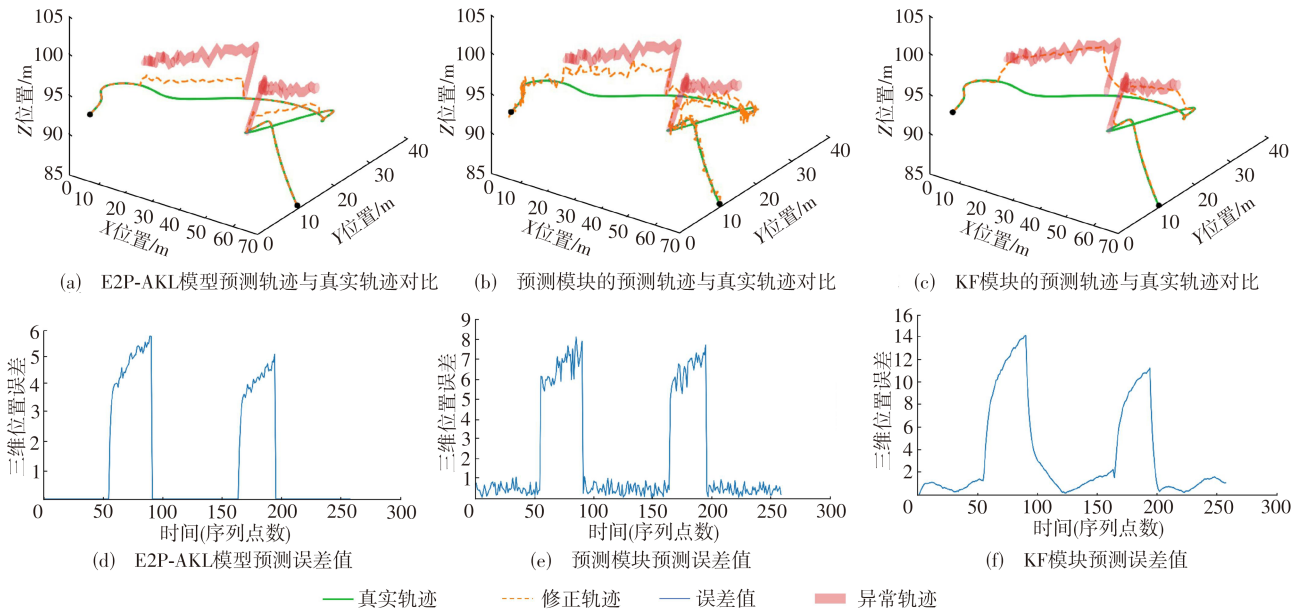


图8 预测修正试验试验结果(轨迹2)

Fig. 8 Predicting and correcting experimental results (track 2)

在端到端训练中,模型能够同时优化表示学习与状态更新,使前向预测的先验与基于观测的后验在统一目标下对齐,从而降低异常带来的先验漂移风险。与此同时,卡尔曼式更新在异常时段对噪声放大大量展现出自适应收缩特性,有效抑制异常传播,并在LSTM的长期依赖建模作用下,实现异常后的快速轨迹回归。相较于单纯依赖重构或平滑的方法,E2P-AKL模型通过物理一致性正则和学习型表示的结合抑制了过拟合与误差放大,在低维高度与高维位置序列上均展现出一致优势,表明该框架对

观测噪声和系统扰动具备较强的分布外稳健性。

2.6 端到端模型嵌入平台可行性分析

无人机网联数据接入平台时,在采样周期为2s的网联数据流下,E2P-AKL模型的异常检测与修正处理流程需在毫秒级范围内,才能满足网联数据及时呈现、呈现正确的需要。本研究使用不同的滑动窗口的大小,使用2024年6月26日一天中的1600余条轨迹构建的测试集,输入端到端模型进行实时异常检测与修正处理来研究模型在完成全流程功能的所需计算开销及模型性能^[22]。采用CPU在32窗口下

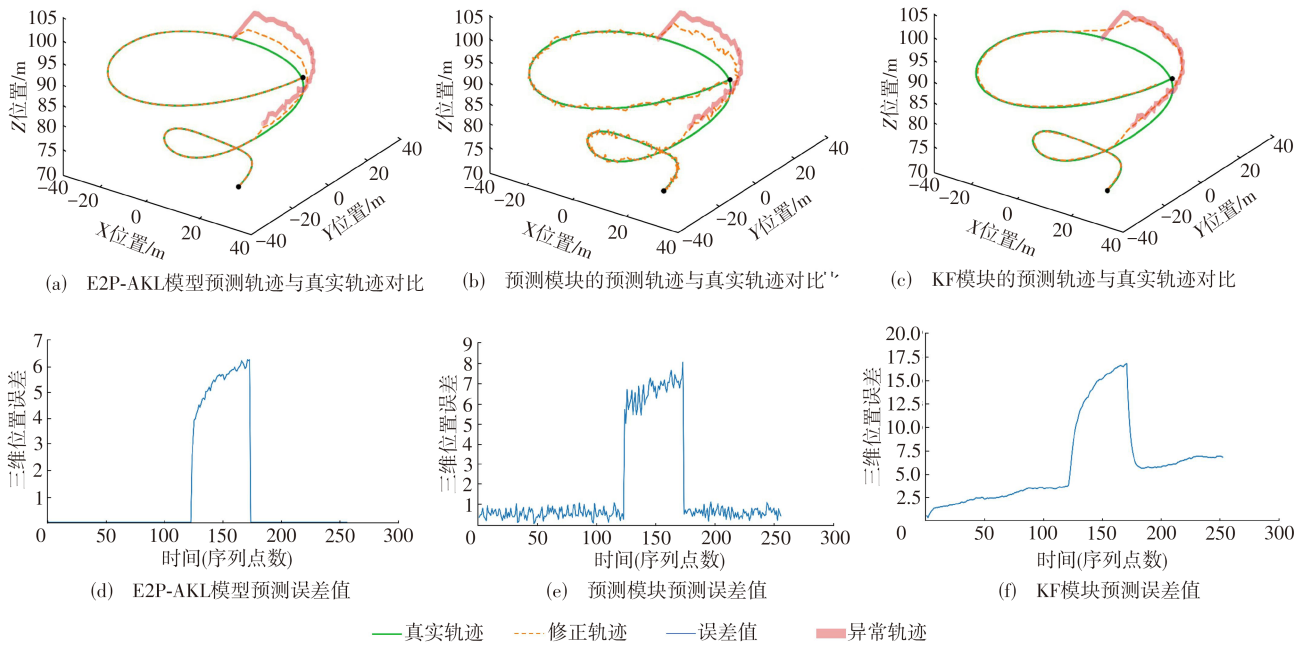


图9 预测修正试验试验结果(轨迹3)

Fig. 9 Predicting and correcting experimental results (track 3)

轨迹1的试验结果如图10和表5所示,对轨迹2的试验结果如图11和表6所示。表5、6中异常类别指航迹诸元中出现异常的类型,组合异常指同时存在2类及以上的航迹异常。对完整测试集进行的异常检测与修正处理的结果如表7所示。

表5 航迹异常点模型处理性能结果(轨迹1)

Table 5 Performance results of model processing for anomaly points (track 1)

异常类别	异常点数	推理延迟/ms	内存占用峰值/MB
高度异常	59	60	128
转向角异常	102	58	104
纬度异常	105	61	109
经度异常	124	59	115
速度异常	22	57	146
组合异常	318	60	211

表7结果表明, E2P-AKL模型的检测修正框架在CPU推理条件下实现了毫秒级响应,推理延迟远低于平台网联采样周期,能够满足及时且正确的在线呈现需求。同时,推理窗口大小对模型的精度及延迟权衡存在影响。端到端单样本处理时,随窗口递增,使用CPU推理时,推理延迟呈现递增趋势,在

表7 不同窗口大小试验试验结果

Table 7 Experimental results of different window sizes

窗口大小	调和均值	精确率	召回率	CPU推理延迟/ms	GPU推理延迟/ms	内存占用峰值/MB
16	0.862	0.900	0.825	25	12	168
32	0.868	0.910	0.830	60	22	223
64	0.873	0.920	0.830	260	45	568
128	0.858	0.925	0.800	520	90	789
256	0.832	0.935	0.750	1 800	180	1 128

表6 航迹异常点模型处理性能结果(轨迹2)

Table 6 Performance results of model processing for anomaly points (track 2)

异常类别	异常点数	推理延迟/ms	内存占用峰值/MB
高度异常	54	60	105
转向角异常	99	62	102
纬度异常	101	59	220
经度异常	127	61	155
速度异常	26	59	141
组合异常	303	60	198

64窗口下F1最佳,为0.873,但CPU平均处理时间达260ms;采用32窗口时F1值相较于64窗口仅下降0.57%,而CPU平均处理时间从260ms降至60ms,下降76.9%,同时内存峰值由568MB降至223MB。32窗口在保证异常召回与低误报的前提下内存开销可控,满足低空管控平台的处理大规模数据时的资源约束,因此推荐作为平台上线的默认配置。依托可微物理积分器与自适应噪声卡尔曼更新,模型在链路抖动与突发噪声场景下保持输出稳定,不确定度可回传用于前端置信展示,加强门控下的数据可信度机制避免不可靠观测放大误判。模型支持流式

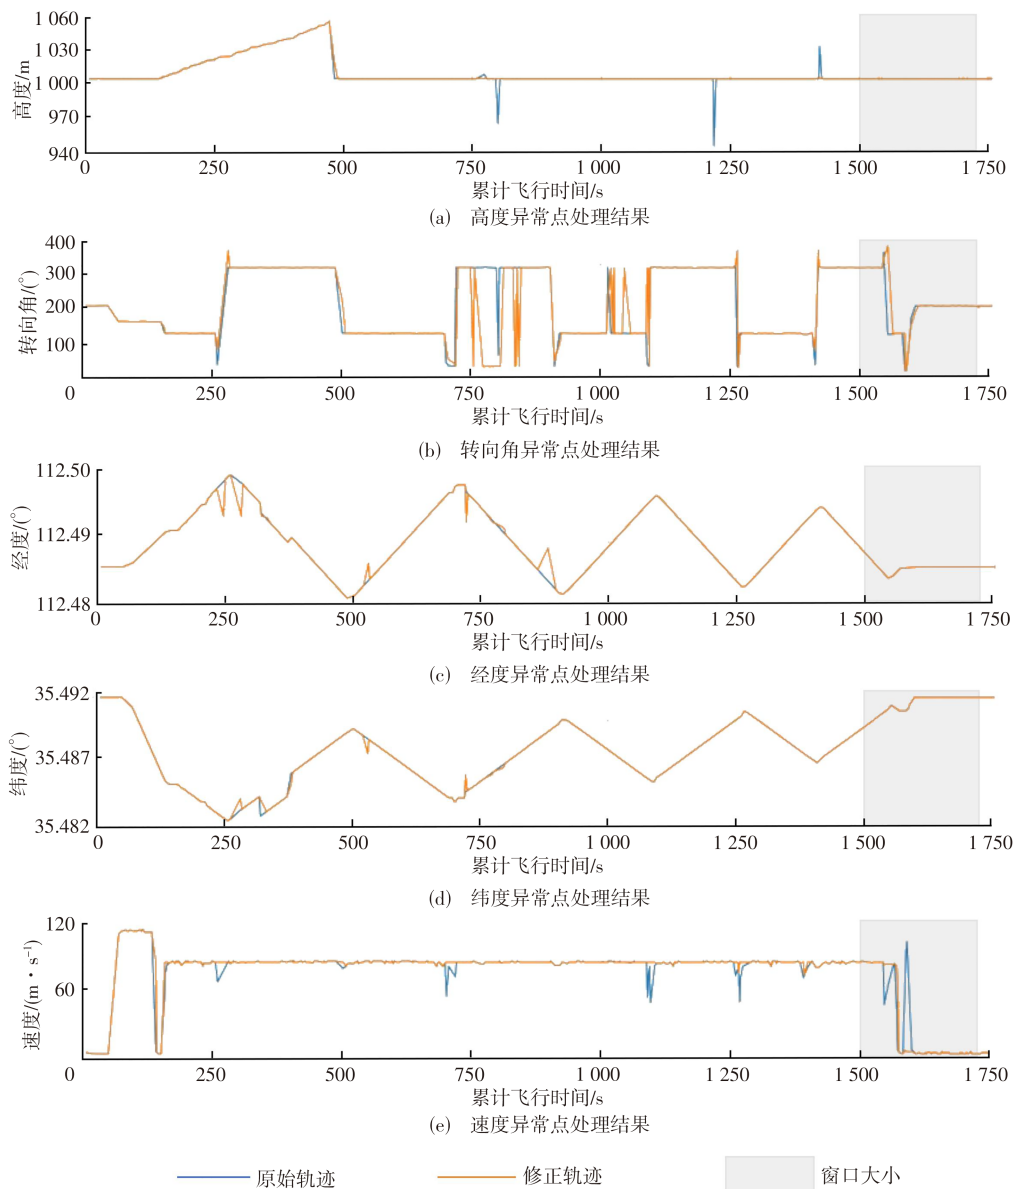


图 10 端到端模型试验试验结果(轨迹 1)

Fig. 10 End-to-end model experimental results (track 1)

滑窗增量更新与远程调用框架(gRPC、REST)接口对接,异常时可降级至仅KF路径以保障连续性。综上,所提出框架在毫秒级闭环、资源可控、稳健与可降级这4个维度均满足平台上线标准,可面向低空交通管控平台网联数据接入平台实施工程化部署。

3 结 语

(1)当前低空交通管控平台正快速发展,呈现出智能化、网联化与体系化建设的加速趋势。现行管制自动化系统在多源监视融合提供了可借鉴的工程经验,但其以飞行计划为基准的航迹异常检测技术体制难以直接运用到低空场景(绝大多数低空飞行活动为娱乐消费类,无飞行计划),低空管制平台仍缺少有

效的航迹异常检测与实时修正方法。现有无人机机载端基于人工智能的航迹异常检测与预测修正方法为平台侧该问题的解决提供了有益思路,但在网联化场景下仍需解决数据异常证据量纲不一,模型组合松耦合、检测与修正功能脱节、无法联合优化,算力与时延开销偏大、不能满足毫秒级约束等问题。本研究面向低空交通管控平台的网联化无人机飞行动态数据创建端到端的物理感知E2P-AKL模型,使得对于开发低空交通管控平台的航迹实时异常检测及预测修正功能具备有效性。

(2)在真实低空交通管控平台数据上的试验表明,本方法相对深度基线MSCRED的F1、AUPRC、AUROC分别提升5.95%、4.16%、2.38%;在FPR小

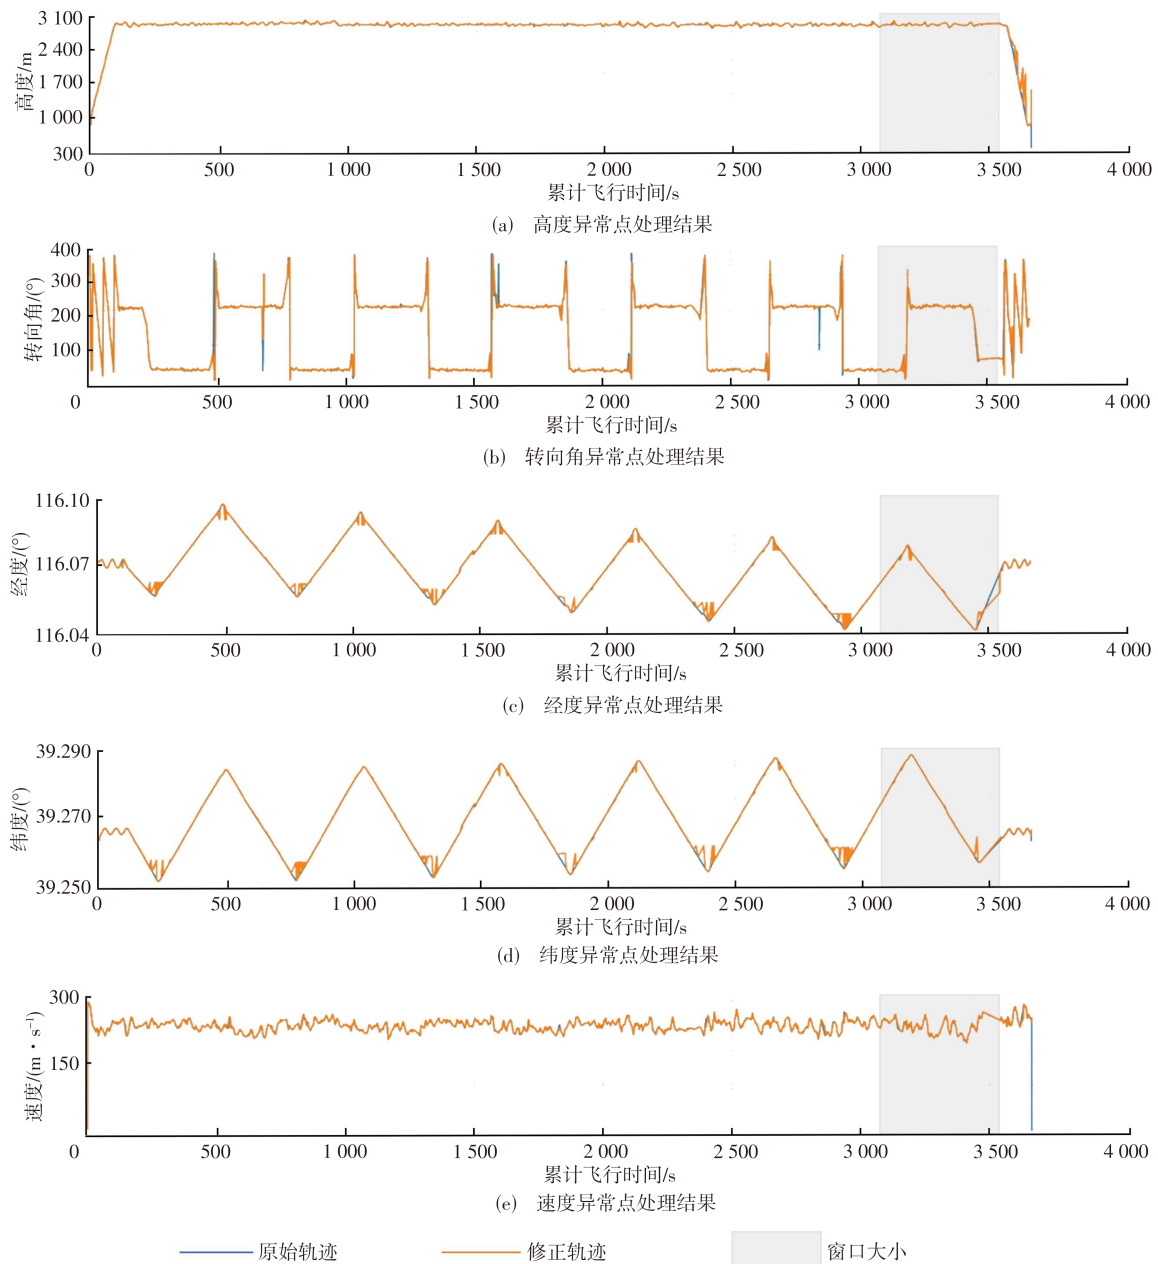


图 11 端到端模型试验试验结果(轨迹 2)

Fig. 11 End-to-end model experimental results (track 2)

于等于1%和0.5%时,TPR分别提升12.9%、18.8%;在预测修正任务上,相对仅使用KF、仅预测模块,均方根误差降低15.2%、21.7%,轨迹偏差降低23.2%、34.1%,高度偏差降低21.4%、32.3%,所提方法在异常检测和预测修正层面获得较高综合指标。实际部署采用32窗口,与F1性能最佳64窗口相比,计算延迟下降76.9%,F1值仅下降0.57%,具备在低空交通管控平台的在线部署可行性。

(3)本研究所提方法的创新在于:针对数据异常判定上统一刻度与规范化缺失、量纲不一、阈值随意的问题,本研究将统计离群、物理包线越界、形态模式变化与序列残差4类证据投影为 $[0,1]$ 统一异常

分数,并引入自适应阈值与权重作为弱监督信号参与端到端反传,使规则知识与表征学习在同一损失下协同,显著降低对精确人工标签的依赖,实现由规则到表示再到决策的一体化训练;针对异常检测和修正方法上深度学习模型和滤波松耦合、检测与修正脱节,难以端到端优化的问题,本研究在预测修正模型中嵌入可微分物理积分器与自适应噪声估计,对滤波关键量进行参数化并参与反传,在可微卡尔曼更新中联合融合观测与先验,以显式物理约束增强对异常扰动的敏感性与修正精度,有效抑制异常传播,同时提升跨场景泛化与分布外稳健性;针对工程化方面传统方法开销大、缺强门控与可回退框

架,难以满足毫秒级边缘约束的问题,本研究以统一异常分数与一致性蒸馏完成多证据尺度对齐与协同优化,以可微物理积分器与自适应噪声将物理先验与滤波更新纳入反传,并配套流式滑窗增量、降级机制以及远程调用对接,由此将检测到修正收敛为单次前向,保证时延与内存可控,在数据退化时仍能连续输出,满足平台侧毫秒级闭环与在线可用。

(4)未来工作将面向跨区域、大规模、多并行数据开展在线更新,扩展多源数据的协同估计与知识迁移,在任务层面引入风险、效能联合目标,将异常风险、路径重规划与合规校核形成闭环联动。

参考文献:

Reference :

- [1] 陶 冶,汤锦辉,闫 震,等.融合表征转换与模式回归的航迹插补方法[J].航空学报,2026,47(1):272-293.
TAO Ye, TANG Jin-hui, YAN Zhen, et al. A trajectory imputation method integrating representation transformation and pattern regression [J]. Acta Aeronautica et Astronautica Sinica, 2026, 47(1): 272-293.
- [2] DONG X, TIAN Y, DAI L, et al. A new accurate aircraft trajectory prediction in terminal airspace based on spatio-temporal attention mechanism[J]. Aerospace, 2024, 11(9): 718.
- [3] 张鼎开,王一喆,王鹏飞,等.基于双重时空掩码与双向Mamba状态空间的高速公路交通异常事件检测模型[J].交通运输工程学报,2025,25(4):311-327.
ZHANG Ding-kai, WANG Yi-zhe, WANG Peng-fei, et al. Expressway traffic anomaly event detection model based on dual spatio-temporal masks and bidirectional Mamba state space modeling [J]. Journal of Traffic and Transportation Engineering, 2025, 25(4): 311-327.
- [4] PANG G S, SHEN C H, JIN H D, et al. Deep weakly-supervised anomaly detection [C]//ACM. Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2023: 1795-1807.
- [5] CHEN B, REN Z, CHENG L. Conformalized time series with semantic features [J]. Advances in Neural Information Processing Systems, 2024, 37: 121449-121474.
- [6] LEE J, XU C, XIE Y. Kernel-based optimally weighted conformal time-series prediction [C]//ICLR. The Thirteenth International Conference on Learning Representations. Singapore: ICLR, 2025: 1-31.
- [7] ZENG G X, CHEN S X, WU H, et al. Continuous-discrete extended Kalman filtering based on the neural ordinary differential equations method [J]. Engineering Applications of Artificial Intelligence, 2024, 133: 108611.
- [8] NI X, REVACH G, SHLEZINGER N. Adaptive KalmanNet: Data-driven Kalman filter with fast adaptation [C]//IEEE. ICASSP 2024-2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). New York: IEEE, 2024: 5970-5974.
- [9] SHEN S Y, CHEN J C, YU G F, et al. KalmanFormer: Using transformer to model the Kalman Gain in Kalman Filters [J]. Frontiers in Neurorobotics, 2025, 18: 1460255.
- [10] CHEN X J, LI Y P. An overview of differentiable particle filters for data-adaptive sequential Bayesian inference [EB/OL]. (2023-12-14). <https://arxiv.org/abs/2302.09639>
- [11] WAN Z Y, ZHAO L. DnD filter: Differentiable state estimation for dynamic systems using diffusion models [C]//IEEE. 2025 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). New York: IEEE, 2025: 13851-13858.
- [12] REIS M J C S, REIS A J D. Edge-based real-time fault detection in UAV systems via B-spline telemetry reconstruction and lightweight hybrid AI[J]. Sensors, 2025, 25(16): 4944.
- [13] AHMAD R, ALKHAMMASH E H. Online adaptive Kalman filtering for real-time anomaly detection in wireless sensor networks[J]. Sensors, 2024, 24(15): 5046.
- [14] POL A A, GOVORKOVA E, GRONROOS S, et al. Knowledge distillation for anomaly detection[EB/OL]. (2023-10-09). <https://arxiv.org/abs/2310.06047>.
- [15] YAO L Y, GAO S B. Dual-student knowledge distillation networks for unsupervised anomaly detection[EB/OL]. (2024-02-01). <https://arxiv.org/abs/2402.00448>.
- [16] KINGMA D P, BA J. Adam: A method for stochastic optimization[EB/OL]. (2014-12-22). <https://arxiv.org/abs/1412.6980>.
- [17] LOSHCHILOV I, HUTTER F. Decoupled weight decay regularization[EB/OL]. (2017-11-14). <https://arxiv.org/abs/1711.05101>.
- [18] 张 森,何仪娟,杨博宇,等.基于LSTM-KF模型的高速列车群组追踪运行轨迹预测方法[J].交通运输工程学报,2024,24(3):296-310.
ZHANG Miao, HE Yi-juan, YANG Bo-yu, et al. Trajectory prediction method for high-speed train group tracking operation based on LSTM-KF model[J]. Journal of Traffic and Transportation Engineering, 2024, 24(3): 296-310.
- [19] SHRESTHA R, MOHAMMADI M, SINAIE S, et al. Anomaly detection based on LSTM and autoencoders using federated learning in smart electric grid [J]. Journal of Parallel and Distributed Computing, 2024, 193: 104951.
- [20] LI J Z, SHI Y, ZHANG T, et al. Radar precipitation nowcasting based on ConvLSTM model in a small watershed in North China[J]. Natural Hazards, 2024, 120(1): 63-85.
- [21] XIE T M, XU Q F, JIANG C X. Anomaly detection for multivariate times series through the multi-scale convolutional recurrent variational autoencoder[J]. Expert Systems with Applications, 2023, 231: 120725.
- [22] OLIVE X, KRUMMER J, FIGUET B, et al. Filtering techniques for ADS-B trajectory preprocessing [J]. Journal of Open Aviation Science, 2024, 2(2): 7882-7899.