

基于时序大数据的飞行安全状态评估方法综述

杨洁¹ 唐荻音² 马泽珊³ 刘宝鼎² 贡欣宇² 文正旭³ 于劲松²
卢劲鹏³ 康锐¹ 韩丹阳¹ 陶来发¹ 冯灿⁴ 刘涛⁴

摘 要 随着全球航班规模与运行密度提升,传统人工监控方法在应对复杂动态飞行环境方面逐渐显现出局限性.近年来,数据驱动的智能监控方法成为提升飞行安全与运行效率的研究热点.本文对基于时序大数据的飞行安全状态评估方法进行综述,从飞行数据的时序特性出发,梳理三类面向不同时间维度的关键评估方法:异常检测、征兆挖掘以及趋势跟踪与预测,涵盖飞行异常状态的识别与潜在风险事件的早期预警与预测.首先,对上述三类评估方法进行系统定义,可覆盖“过去-现在-未来”的安全保障.其次,介绍各类方法的代表性研究进展与存在问题;以高风险进近阶段为典型场景,分析评估方法的应用现状与协同机制,并回顾其技术支撑,包括数据通信和软件平台.最后,总结当前挑战和未来方向,包括异常检测的可解释性、征兆事件的动态表征与定位、趋势预测与因果推理的融合,以及大模型应用潜力等.

关键词 航空器监测与检测;飞行状态评估;数据驱动;异常检测;征兆挖掘;实时飞行监控系统

引用格式 杨洁,唐荻音,马泽珊,刘宝鼎,贡欣宇,文正旭,于劲松,卢劲鹏,康锐,韩丹阳,陶来发,冯灿,刘涛.基于时序大数据的飞行安全状态评估方法综述.自动化学报,2026,52(9):1846–1867

DOI 10.16383/j.aas.c250449 **CSTR** 32138.14.j.aas.c250449

Review of Flight Safety State Assessment Methods Based on Large-scale Time-series Data

YANG Jie¹ TANG Di-Yin² MA Ze-Shan³ LIU Bao-Ding² GONG Xin-Yu² WEN Zheng-Xu³
YU Jin-Song² LU Jin-Peng³ KANG Rui¹ HAN Dan-Yang¹ TAO Lai-Fa¹ FENG Can⁴ LIU Tao⁴

Abstract As global flight volume and operational density rise, traditional manual monitoring methods are gradually revealing limitations in coping with complex and dynamic flight environments. Recently, data-driven intelligent monitoring methods have become a research hotspot for improving flight safety and operational efficiency. This paper reviews flight safety state assessment methods based on large-scale time-series data. Based on the temporal characteristics of flight data, three key assessment methods across different temporal dimensions are summarized: Anomaly detection, precursor mining, and trend tracking and prediction, covering flight anomalous state identification, early warning, and prediction of potential risk events. First, these methods are systematically defined, covering “past-present-future” safety assurance. Next, representative research progress and existing limitations of various methods are introduced; Using high-risk approach phases as a representative scene, this study analyzes the application status and coordination mechanisms of assessment methods and reviews supporting technologies, including data communication and software platforms. Finally, current challenges and future directions are summarized, including interpretability in anomaly detection, dynamic representation and localization of precursor events, integration of trend prediction with causal inference, and potential applications of large language models.

Keywords aircraft monitoring and detection; flight state assessment; data-driven; anomaly detection; precursor mining; real-time flight monitoring system

Citation Yang Jie, Tang Di-Yin, Ma Ze-Shan, Liu Bao-Ding, Gong Xin-Yu, Wen Zheng-Xu, Yu Jin-Song, Lu Jin-Peng, Kang Rui, Han Dan-Yang, Tao Lai-Fa, Feng Can, Liu Tao. Review of flight safety state assessment methods based on large-scale time-series data. *Acta Automatica Sinica*, 2026, 52(9): 1846–1867

收稿日期 2025-09-03 录用日期 2026-01-29

Manuscript received September 3, 2025; accepted January 29, 2026

杭州市北航国际创新研究院博士后科研专项经费(2025BKZ059),国家自然科学基金(52375074)资助

Supported by Postdoctoral Research Funding of Hangzhou International Innovation Institute of Beihang University (2025 BKZ059) and National Natural Science Foundation of China (52375074)

本文责任编辑 倪茂林

Recommended by Associate Editor NI Mao-Lin

1. 杭州市北京航空航天大学国际创新研究院(北京航空航天大学国际创新学院)杭州 311115 2. 北京航空航天大学自动化科学与电气工程学院北京 100191 3. 北京航空航天大学中法工程师学院北京 100191 4. 中国商飞上海飞机试飞工程有限公司上海 201323

1. Hangzhou International Innovation Institute, Beihang University, Hangzhou 311115 2. School of Automation Science and Electrical Engineering, Beihang University, Beijing 100191 3. Sino-French Engineer School, Beihang University, Beijing 100191 4. COMAC Shanghai Aircraft Flight Test Co., Ltd., Shanghai 201323

近年来,随着航空运输信息化发展和全球航空需求增长,我国民航旅客运输量预计将在 2025 年达到 7.8 亿人次^[1],全球航空旅客数量将突破 50 亿人次^[2]。在飞行环境复杂化和运营压力加剧的背景下,传统依赖事后分析与人工评估的安全保障方式,已难以满足实时监控和风险预警需求^[3]。国家政策持续强调航空安全,提出提升安全管理智能化与实时化水平,构建高水平安全管理体系,将数据视为新型生产要素,以数字化和智能化技术推动飞行安全保障升级^[4-6]。

随着先进传感器技术的发展与多源飞行数据的持续积累,飞行过程中的多维动态信息得以实时记录,为飞行安全研究提供坚实的数据基础^[7]。基于这些数据的研究,不仅能够从宏观上揭示系统运行特征,还可通过挖掘深层次的关联关系与潜在因果链,推动航空安全研究从经验依赖向数据驱动范式的转变。基于大数据的主动分析,可为飞行员、空管人员及维护人员提供科学决策支持,从而有效降低高风险事件发生概率,避免灾难性事故的发生^[8]。在复杂空域环境下,尤其在紧急或高风险情境中,实时数据分析对提升动态监测、风险识别和主动化安全管理能力具有关键作用^[9]。因此,亟须充分发挥大数据在飞行安全保障中的核心作用,推动主动化、实时化与智能化的飞行安全状态评估与预警技术的发展。

为解决上述传统航空安全保障方式在实时性与智能化方面的不足,即时航空安全管理系统(in-time aviation safety management system, IASMS)概念应运而生^[10-13]。IASMS 旨在依托飞行数据的实时监控与自动评估,实现航空安全的智能化与实时可视化管理。然而,随着航空运行数据规模持续扩张,尤其是多模态数据(如文本、语音与视频)的不断积累(全球机队预计 2026 年可达 9 800 万 TB)^[14],IASMS 的高效运行面临航空大数据体量大、种类多、流速快等多重挑战^[15],这对安全评估方法的实时性提出更高要求。

基于此,针对飞行全过程不同时间维度的安全管理需求,本文梳理三类核心状态评估技术:异常检测、征兆挖掘和趋势跟踪与预测,以满足从及时监测到早期预警再到未来预测的多层次保障需求。其中,异常检测用于快速识别当前偏离正常的飞行行为;征兆挖掘侧重从历史时序数据中发现潜在高风险征兆,支持早期预警与主动干预;趋势跟踪与预测则通过飞行状态演化建模,预判风险未来发展,实现提前预测与规避。

三者从“过去 → 现在 → 未来”三个时间维度协同发力,融合人工智能、大数据分析 with 先进通信

技术,形成从异常识别、早期预警到风险预测的递进关系,共同支撑基于时序大数据的全过程、多层次的飞行安全保障体系。

此外,本文介绍三类方法在实际航空场景中的协同应用,探讨其在 IASMS 架构下的集成潜力,分析其高效部署所依赖的关键通信技术与软件平台,并总结当前研究挑战与未来发展方向。

与其他文献相比,本文的主要贡献包括以下三个方面:

1) 系统综述飞行安全状态评估方法。围绕异常检测、征兆挖掘和趋势跟踪与预测三类核心方法,全面梳理技术原理、研究现状及典型方法,明确各方法适用场景与局限性。

2) 引入“过去 → 现在 → 未来”多层次评估框架。以时序大数据分析为主,将三类方法整合于飞行全过程时间维度,明确其在智能安全评估中的定位与功能边界,结合典型运行场景阐述三类方法在 IASMS 架构下的协同路径,且分析通信技术与软件平台的支撑作用。

3) 凝练研究挑战与未来发展方向。总结当前研究在可解释性、动态表征及预测准确性等方面存在的关键问题,提出针对性研究方向与技术展望,为提升飞行安全事件识别效率及响应能力、增强状态评估可解释性与预测能力提供理论和方法支持。

1 飞行安全状态评估方法分类

1.1 即时航空安全管理系统简介

随着飞行运行复杂性的不断提升,传统静态航空安全保障方式在实时性、覆盖性与智能化方面的局限日益凸显。图 1 总结了近几十年来航空安全保障系统项目的发展脉络,包括从早期的航空安全报告系统(aviation safety reporting system, ASRS)^[16]、航空安全专项(aviation safety program, AvSP)^[17]、飞机综合健康管理(integrated vehicle health management, IVHM)^[18]到实时安全保障(real-time system-wide safety assurance, RSSA)等项目^[19-21]。其中,美国国家航空航天局(National Aeronautics and Space Administration, NASA)于 2018 年提出了即时航空安全管理系统(IASMS)的构想,并在 2023 年纳入其长期安全战略。

IASMS 的核心理念在于:通过融合飞行运行过程中产生的多源异构数据^[22],结合人工智能与数据挖掘技术,构建具备在线监测、智能评估与主动缓解能力的飞行安全状态管理系统^[23],从而实现从被动响应向主动预防的安全管理模式转型^[24]。图 2 展示了 IASMS 的整体架构,其运行流程包含以下三




图 1 航空安全保障系统项目发展脉络

Fig.1 Development trajectory of aviation safety assurance system projects




图 2 即时航空安全管理系统架构

Fig.2 Structure of the in-time aviation safety management system

个阶段^[11, 25]:

1) 监测阶段: 采集在线数据与离线数据, 进行

数据检查与融合, 构建标准化、高价值数据流, 为后续建模提供多源数据输入;

2) 状态评估阶段^[13]: 基于数据挖掘与人工智能方法开展三类核心任务: 异常检测识别飞行状态异常、征兆挖掘定位潜在风险、趋势跟踪与预测推演未来异常事件;

3) 缓解阶段: 基于评估结果生成风险缓解策略建议并自动报警, 飞行员、自动执行程序及地面监控系统协同采取改出动作与应急措施以控制风险。

IASMS 架构通过数据、方法与决策的紧耦合, 实现在线监测、智能评估与主动缓解, 支撑智能化、实时化的航空安全保障体系。在此框架下, 本文将聚焦于 IASMS 状态评估阶段, 从飞行数据的时序特性出发, 对异常检测、征兆挖掘以及趋势跟踪与预测三类关键技术进行系统梳理。该划分呼应相关研究中对异常、征兆与趋势三类状态指征的界定^[11], 并与飞行状态在过去、现在与未来时间维度上的演化特征相一致, 有助于厘清数据驱动飞行安全评估的整体技术路径及其内在关联。

1.2 状态评估方法的内涵界定与技术特征

本节进一步围绕 IASMS 状态评估阶段, 明确异常检测、征兆挖掘和趋势跟踪与预测三类方法在时间定位、建模目标及技术特征上的差异与联系。尽管已有研究涉及相关任务, 但在方法体系层面仍缺乏系统化的统一界定。为此, 本文在现有研究基

础上对三类方法进行归纳与界定, 为后续研究现状与发展趋势的分析奠定基础。表 1 简要总结了三类方法的基本任务目标与典型特征, 作为后文展开讨论的分析基础。

下面将介绍每个关键方法的定义、基本实现方法与现有研究方法概况, 如图 3 所示。

1) 异常检测: 通过分析当前可观测的飞行参数, 识别出偏离正常运行状态的异常行为。通常通过学习正常/异常状态的范式, 建立相应模型, 实现对新样本的异常状态评估。异常检测主要面向偏离程度显著的显性异常识别, 其检测结果可作为后续征兆挖掘的事件级标签的基础。

在航空领域中, 异常可分为统计学上异常与操作上异常。异常检测侧重于统计学上异常, 仅反映数据的统计偏离, 可能导致虚警, 且不一定威胁飞行安全。而航空安全更关注实际影响安全的异常。因此, 异常检测更多强调“异常”状态, 而非完全等同于“不安全”。

当前绝大多数文献聚焦于异常检测, 后续会从基于传统统计学、基于经典机器学习和基于深度学习的异常检测方法展开综述。

2) 征兆挖掘: 基于对历史飞行数据的深度分析, 聚焦可能引发未来高风险异常事件的潜在征兆。在特定异常事件场景下, 异常检测与征兆挖掘存在因

表 1 三类飞行安全状态评估方法的功能与技术特征对比

Table 1 Functional and technical characteristic comparison of three flight safety state assessment methods

属性维度	异常检测方法	征兆挖掘方法	趋势跟踪与预测方法
评估目标	当前异常飞行状态识别	历史数据高风险征兆定位	未来飞行状态演化推演
数据依赖	当前/近期数据	历史数据、先验知识	当前/近期数据、异常/征兆状态
典型输出	异常区间、异常分数	征兆表征、因果关联特征	趋势曲线、未来状态预测
关键特征	显性异常	隐性异常、风险关联	状态趋势
典型应用环节	在线监测、快速告警	历史事故原因分析、提前预警与干预	状态趋势监控、风险评估、辅助决策




图 3 飞行安全状态评估方法关系

Fig.3 Relationship among flight safety state assessment methods

果关系: 征兆作为“因”, 可推断“果”即为异常事件. 征兆表现为隐式异常, 偏离程度较小, 不易直接观察, 且与高风险异常事件相关.

具体而言, 征兆具有两类核心属性: 隐式异常属性与风险关联属性. 隐式异常属性指特征参数仅表现轻微偏离, 偏离幅度通常低于传统异常检测阈值, 难以被常规检测模型识别. 风险关联属性刻画偏离特征与未来高风险事件的潜在因果或统计依赖关系, 可通过风险事件关联概率等指标度量. 因此, 征兆可视为异常空间中的关系型子集, 只有同时具备隐式异常和风险关联属性的偏离特征, 才被界定为征兆. 相比之下, 弱异常、早期异常等概念主要强调偏离幅度或时间提前性, 如未体现与特定风险事件的关联增强, 仍属于传统异常检测范畴, 而非征兆.

基于上述定义, 征兆挖掘通过定位与异常事件相关的征兆, 具备提前预警与主动缓解潜力. 后续通过及时改出或其他操作, 可切断异常事件与其相关征兆的联系, 从而主动缓解风险, 避免未来事件发生.

当前基于数据驱动的征兆挖掘研究尚处于起步阶段, 系统架构尚未成熟, 后续内容将重点从学习机制角度进行综述.

3) 趋势跟踪与预测: 根据当前的飞行数据与已发现的异常模式 (如异常检测与征兆挖掘状态估计), 对未来的飞行状态进行趋势递推与预测. 与异常检测和征兆挖掘相比, 趋势跟踪与预测的核心在于推演未来状态的演化趋势.

现有研究主要分为两类方向: 一类基于定量建模, 侧重于飞行轨迹的建模与偏离检测; 另一类基于定性因果推断, 强调征兆与异常事件之间的因果链分析与解释. 本文将从上述两个角度出发, 系统回顾趋势跟踪与预测方法在航空安全中的研究现状与挑战.

总体来看, 三类飞行安全状态评估方法在目标、数据依赖及典型输出上各具特点, 但在实际应用中相互补充、协同增效. 异常检测关注当前状态的快速识别, 用于发现显著偏离正常模式的行为, 实现即时风险响应; 征兆挖掘侧重从历史数据中识别出潜在因果链和风险征兆, 揭示未来高风险事件的触发机制; 趋势跟踪与预测面向未来状态演化与风险研判, 用于评估风险发展趋势及潜在后果. 三者按时序上分别对应当前识别、历史溯源和未来预测, 共同构成飞行全过程状态评估的关键支撑路径.

2 航空时序大数据来源与其对状态评估方法的支撑作用

本文以时序大数据为研究对象开展飞行安全评估方法调研. 在航空安全领域, 时序大数据来源广

泛, 包括飞行记录仪、自动相关监视广播 (automatic dependent surveillance-broadcast, ADS-B) 与雷达数据、机场与空管运行数据, 以及气象监测数据等^[26]. 这些数据在时间维度上连续生成, 涵盖飞行状态、位置以及环境等信息, 为飞行安全状态评估提供了丰富的信息基础.

飞行记录仪数据是现有的典型时序大数据分析的主要来源, 其包含飞机状态、异常信号、性能退化及人为操控等关键信息, 构成安全评估的数据基础^[27-28]. 针对时间序列数据, 飞行数据可从数据值域这一特性出发, 分为连续变量与离散变量^[29]. 具体常见的多变量时间序列飞行数据如表 2 所示. 这类数据基

表 2 飞行数据常见变量汇总
Table 2 Summary of general variables of flight data

类型	变量名	
连续变量	速度/加速度	空速
		马赫数
		三轴加速度
		低引擎速度
	姿态角	高引擎速度
		俯仰角
		滚转角
		偏航角
	操纵面变量	副翼位置
		升降舵位置
		方向舵位置
	高度	气压高度
		无线电高度
	气流角	迎角
		侧滑角
	环境变量	风速矢量
		温度
		气压
离散变量	飞行其他状态量	
	部件/飞行状态	襟翼状态
		减速板状态
		起落架状态
		刹车状态
		反推状态
	飞行控制模式	飞行阶段 (起飞、爬升、巡航、下降、进近、着陆)
		自动驾驶模式
		飞机指引模式
		进近模式
		自动油门模式
	飞机告警状态	状态超限
		故障/失效状态

本包含影响飞行安全的主要因素(如飞机自身状态、人为操控因素、环境因素等),能够捕捉关键风险因素,基本反映飞行安全情况,可支撑后续的子系统层次与参数级别的异常定位、征兆挖掘、趋势跟踪与预测等技术需求。

然而,航空时序数据具有典型的大数据属性:体量大、种类多以及流速快^[30]。从体量角度看,每架飞机装备数千个传感器,每天可产生 TB 级监测数据,长期飞行的积累已形成高维海量的时序数据集;从种类角度看,数据来源多样,呈现出显著的多源异构特征;从速度角度看,飞行过程数据实时生成且连续更新。这些特性在提供丰富信息基础的同时,也带来特征冗余、噪声干扰、多因素交互导致的异常可辨识性下降,以及对模型实时更新效率的挑战。

由上述特性可见,数据的内在结构与飞行安全状态评估方法的能力需求高度关联。首先,高维度与多变量耦合要求异常检测方法具备强鲁棒性与高效特征提取能力,以识别当前偏离模式;接着,多源时序及跨架次演化信息为征兆挖掘提供了隐式异常的识别基础,需要方法能够从长期积累中发现征兆关联;最后,数据实时生成与时序依赖性决定趋势预测需要兼顾长时序建模能力与快速响应能力,以支持动态决策。

因此,航空时序大数据既是飞行安全状态评估方法的基础,又深刻影响着评估方法的设计路径。基于数据特性与方法需求之间的对应关系,第 3 ~ 5 节将分别针对三类评估方法展开系统综述。

3 基于时序大数据的异常检测方法综述

异常检测是飞行安全状态评估的核心方法,通过分析当前飞行数据判断状态是否正常,并为风险处置提供依据^[31]。现有异常检测方法可根据异常类型、数据类型及学习机制等多种方式进行划分^[32-35]。借鉴文献^[36-37]的研究思路,本文从目标驱动的角度,将基于时序大数据的异常检测方法划分为三类:基于传统统计学、基于经典机器学习和基于深度学习的异常检测方法,具体分类如图 4 所示。

基于传统统计学的方法假设数据来源于特定统计分布,而基于机器学习的方法将数据生成过程视为黑箱,从数据中直接学习规律。本文进一步将机器学习方法细分为两类:一类为浅层结构的经典机器学习方法,适合处理低维或单变量数据;一类是深层结构的深度学习方法,具备更强的特征抽取与时序建模能力,可处理高维多变量数据。

3.1 基于传统统计学的异常检测方法

基于传统统计学的异常检测方法通常假设正常




图 4 异常检测方法分类

Fig.4 Classification of anomaly detection methods

实例发生在随机模型的高概率区域,而异常实例发生在低概率区域^[34]。这类方法可以细分为基于数据分布的方法与基于时间序列回归的方法。

1) 基于数据分布的方法

基于数据分布的方法认为偏离正常样本分布的数据点为异常,包括 $N-\sigma$ 准则、四分位 (quantile)、最大标准残差测试 (grubbs) 以及其他分布方法。Liu 等^[38] 使用 3σ 准则来检测飞机发动机数据中的异常。Singh 等^[39] 使用 grubbs 方法检测商用飞机电梯伺服系统中的振荡故障。Keipour 等^[40] 通过对关键飞行变量(如侧滚和俯仰角)的控制偏差进行 Z 分数标准化,以协助异常检测任务。Su 等^[41] 采用符号矢量化方法获取符号特征序列,进一步提取特征序列统计分布(如频率)来检测飞机电池数据中的异常。上述方法通常需根据数据类型选择相应的分布假设以实现异常判别。

2) 基于时间序列回归的方法

基于时间序列回归的方法通过对序列进行建模,并以模型预测值与真实观测值之间的残差作为异常判据。典型代表为自回归综合移动平均 (autoregressive integrated moving average, ARIMA) 及其简化形式等常用模型。Xiong 等^[42] 提出基于数据采集与监视控制系统的传感器参数建立关键参数的 ARIMA 模型,并通过预测残差识别异常状态。

进一步地, 针对固定阈值机制易引发误报的问题, 相关研究通过引入自适应残差建模策略对传统回归方法进行改进: 一方面, 文献 [43] 通过对预测残差进行自适应聚类分析实现异常识别; 另一方面, 文献 [44] 通过基于动态方差的自适应阈值机制降低正常波动引起的误报。另外, Kozitsin 等^[45] 在 AR-IMA 框架下提出了一种计算复杂度较低的异常检测方法, 并验证了其在复杂工程系统实时诊断中的有效性。

上述基于数据分布与时间序列回归的方法结构简单、实现成本低、可解释性强, 在低维或弱相关时序场景中适用, 因此在工程实践中仍被广泛采用。然而, 在复杂高维飞行时序数据中存在局限: 基于数据分布的方法依赖特定假设, 难以完全满足真实飞行数据, 影响检测精度; 基于时间序列回归的方法依赖单变量建模, 难以刻画多变量间动态关联与非线性耦合, 在处理高维、强相关航空数据时性能受限^[46-47]。

3.2 基于经典机器学习的异常检测方法

与依赖统计假设的传统方法相比, 基于经典机器学习的异常检测方法通常通过学习数据在正常运行状态下的特征, 以识别与其偏离的异常表现。考虑到飞行数据以正常样本为主且异常标注有限, 本节将常用且具代表性的方法归纳为三类: 基于距离的方法、基于密度的方法、基于聚类的方法^[48]。此类方法主要基于浅层模型结构的方法学习正常样本特征, 并依据其建立判别机制的基本假设来实现异常检测, 适用于基于飞行数据的无监督异常检测应用场景。

1) 基于距离的方法

基于距离的方法通过待测数据点与其他点的距离来判定异常。其基本假设是异常样本与大多数正常样本在特征空间中的距离较大。典型代表方法是 K-最近邻 (K-nearest neighbors, KNN) 方法^[49], 该方法通过计算数据点与其 K 近邻距离来判断异常程度。其他方法从计算复杂度或者距离定义等方面在 KNN 思想上进行了改进。

为进一步提升 KNN 方法在大规模数据集上的计算效率, Bay 等^[50] 提出基于近邻距离的嵌套循环异常检测算法, 通过剪枝策略可实现接近线性运算复杂度的效果。为了描述时间序列的时序特性, Zhang 等^[51] 采用滑动窗口提取时序特征, 构建基于核密度估计的特征并使用对应的邻近距离判别异常, 具有较好的异常检测效果以及上下文异常检测能力。

2) 基于密度的方法

基于密度的方法通过评估区域中数据点的密度

来检测异常。该方法假设低密度区的数据点有较高异常分数。如果该异常分数超过设定的阈值, 则该点被归类为异常。常用的基于密度的方法是局部离群因子 (local outlier factor, LOF) 和孤立森林 (isolation forest, iForest)。LOF 基于局部密度评估, 能捕获短时和局部异常, 但计算开销较大; iForest 通过随机孤立样本实现异常评分, 在高维或大规模数据上更高效。

为了提升检测的稳定性与高维适应性, 研究者提出了多种 LOF 变体, 如局部离群概率 (local outlier probabilities, LoOP)^[52] 和基于连接的离群因子 (connectivity-based outlier factor, COF) 等^[53]。Jasra 等^[54] 将 LOF 方法应用于飞行时序数据异常检测, 通过离群因子量化异常程度并捕获短时异常行为。进一步, 为了更准确地量化异常, Schlag 等^[55] 提出了基于内在维度生成异常概率分数的方法, 支持邻域和敏感性调节, 在高维和低维数据均具有较低虚警率。

相对于 LOF, iForest 具有较高计算效率, 更適合大规模数据。孙瑞山等^[56] 利用 iForest 建立基于快速存取记录器 (quick access recorder, QAR) 数据的进近阶段航班超限事件预测模型, 有效实现了大规模数据下的异常检测。Khan 等^[57] 提出了基于无监督的孤立森林方法应用于无人机异常事件检测, 并结合后处理计算异常概率以降低误报, 进一步体现 iForest 在实时监控场景中的优势。

3) 基于聚类的方法

基于聚类的方法通过聚类思想将数据划分为簇群, 然后根据簇群之间的距离识别数据中的异常。这类方法无需严格的先验分布假设, 适用于处理高维、非线性耦合的复杂数据。此类方法中常用的有 K 均值 (K-means)、高斯混合模型 (Gaussian mixture model, GMM)、基于密度空间聚类 (density-based spatial clustering of applications with noise, DBSCAN) 和一分类支持向量机 (one-class support vector machine, OC-SVM)。

K-means 方法实现简单, 但对簇形状较为敏感, 且需要事先设定聚类簇的数量; 相比之下, DBSCAN 能够识别任意形状的簇结构, 具备自适应簇扩展能力, 并且无需预先指定簇数量, 因此在多变量时间序列的飞行异常检测场景中表现出较好的适用性^[58-59]。比如, Slimene 和 Ouali^[58] 结合密度聚类算法 DBSCAN 与动态时间规整 (dynamic time warping, DTW) 距离度量, 实现了面向飞行阶段的多变量时间序列异常行为模式检测。该方法以样本邻域内的密度分布为依据生成聚类结果, 处于低密度区域且无法归属到任何高密度簇的样本被自然地

视为异常。

GMM 通过多个高斯分量对正常飞行行为的概率分布进行建模, 且能刻画多类典型行为模式^[60-62]。相关研究^[63]进一步结合期望最大化实现了增量式建模, 提升该方法在持续监测中的适用性。OC-SVM^[64]则通过学习正常样本在特征空间的非线性边界来区分正常与异常点, 适用于缺乏异常样本的飞行场景^[65-70]。为增强模型在噪声下的鲁棒性, Guo 等^[66]提出基于局部密度调节边界的优化策略, 以应对噪声对模型决策边界的影响。Puranik 等^[68]将 DBSCAN 方法和 OC-SVM 方法相结合, 通过先识别簇结构再进行簇内异常判定, 实现了对进近和着陆阶段飞行异常的高效检测。该方法兼顾了 DBSCAN 簇识别灵活性和 OC-SVM 边界判定的精细性, 有效克服了单一方法的局限, 并提升了检测的准确性。

基于经典机器学习的方法通过距离、密度或簇等方式刻画正常样本特征, 以区别异常数据。这类方法计算复杂度适中、可解释性较好, 可适用于多变量数据建模。然而, 这类方法在时序表达方面能力有限, 难以捕捉时序动态演化规律; 同时, 在高维数据中可能出现“维度爆炸”, 现有依赖的假设可能会失效, 导致检测精度下降和计算负担增加, 因此在复杂高维航空时序数据中会性能受限。

3.3 基于深度学习的异常检测方法

基于深度学习的异常检测近年来受到广泛关注, 其可减少人工特征设计并具备高维特征抽取与复杂数据建模能力。现有研究^[71-72]对基于深度学习的通用异常检测进行了系统梳理, 主要包括: 正常类特征学习方法^[73-77]、异常度量依赖的特征学习方法^[78-82]以及端到端异常分数方法等^[83-86]。这些方法在机制层面各具优势, 为不同任务提供灵活建模路径。

然而, 鉴于航空时序大数据存在强时序依赖与变量相关性, 基于长短时记忆 (long short-term memory, LSTM) 及其变体建模的方法是当前主流方法^[87-88]。为进一步增强模型的时序特性学习和变量相关性挖掘能力^[89-90], 研究者尝试将 LSTM 与其他具备不同特性的网络结构方法融合。因此, 结合现有工作, 本文以 LSTM 架构为核心, 从融合策略角度将其划分为四类: 统计学方法、编码器、卷积神经网络 (convolutional neural network, CNN) 以及图模型方法。

1) 融合统计学方法

融合统计学方法是一类在 LSTM 模型基础上引入统计学的异常检测方法, 通过优化特征表示或

者降低噪声影响来提升异常检测性能。为有效降低噪声的干扰, Hundman 等^[91]在 LSTM 时序建模基础上, 引入指数加权移动平均 (exponentially weighted moving average, EWMA) 方法, 对异常偏差进行平滑处理以减少误报。类似地, 为了增强模型在异常检测任务中的稳定性和可靠性, Wang 等^[92]联合了 LSTM 和滤波器方法。另外, 为提高模型在高维空间异常检测的准确性和鲁棒性, Tariq 等^[93]在 LSTM 基础上引入概率主成分分析 (probability principal components analysis, PPCA) 方法, 预先对高维时间序列数据进行降维处理。

2) 融合卷积神经网络方法

融合卷积神经网络方法是一类通过卷积层提取局部空间特征并与 LSTM 结合的异常检测方法, 其目的是增强模型对局部和全局时序特征的学习能力。Song 等^[94]提出了多尺度的 CNN 模块, 通过在不同时间尺度上提取局部特征, 显著提升了 LSTM 对局部和长期时序动态的建模能力。Yang 等^[95]采用 1D-CNN 卷积层从原始无人机时间序列中提取局部时序特征, 为后续 LSTM 建模提供了更具判别性的输入, 从而增强了模型在异常检测任务中的识别能力。

3) 融合编码器方法

融合编码器方法是一类结合深度自编码网络与 LSTM 的异常检测方法, 其目标是通过提取数据的深层特征, 增强时序异常识别能力和特征表示的鲁棒性。为了提升模型对正常类特征的学习能力, Xie 等^[46]采用了基于 LSTM 的卷积变分自编码器 (convolutional variational autoencoder, CVAE) 方法, 学习不同尺度下的高维正常类特征, 提升特征学习的鲁棒性和模型对异常的敏感性。类似地, 王茵茹^[96]提出了基于 VAE (variational autoencoder) 的深度支持向量数据描述方法以提升时序数据在特征空间的表达能力, 能有效应用于发动机各项异常检测任务。进一步, 为了提升模型在不同域的泛化学习能力, 毛文涛等^[97]提出一种面向多域迁移的深度自编码网络, 通过自适应提取不同域的公共特征表征以提升正常状态和异常状态的特征差异性, 从而提升时序异常检测的实时性和可靠性。另外, 为了提升模型在不同飞行场景的检测精度, Chevrot 等^[98]提出了基于 LSTM 的自编码器 (autoencoder, AE) 模型, 通过为不同飞行阶段配备专用解码器, 实现上下文的异常检测, 从而提升了模型在多阶段飞行数据中的异常识别精度。

4) 融合图模型方法

融合图模型方法是一类利用图结构建模多变量

依赖关系并与 LSTM 结合的异常检测方法,其目标是通过捕捉时序变量间的复杂依赖关系,提升模型的特征表达能力及可解释性^[99].为了表达变量间的相关性,Song 等^[94]提出了基于最大信息系数的图卷积网络(graph convolution network, GCN),提取时序变量间的空间相关性,提升模型性能和可解释性.为了提取多元变量复杂的交互特征,张旭等^[100]利用图神经网络融合高阶隐性和显性关系的表征向量,自动提取多元变量复杂的交互特征.进一步,为了共同捕捉时间维度和特征维度的复杂依赖关系,Zhao 等^[101]和 Yan 等^[102]引入了两个并行的图注意力网络(graph attention network, GAN),为后续的异常检测提供优质特征输入.为了充分利用数据与知识的优势,杜航原等^[103]提出了一种融合知识的多视图网络异常检测模型,在多视图学习模式下通过数据与知识的互补融合实现了对异常节点的有效识别.

基于 LSTM 的融合策略在航空时序异常检测中表现出显著优势,可通过不同融合模块的组合,显著提升特征提取能力、噪声抑制能力以及多变量关联建模能力.然而,该方法仍存在局限:训练参数多、计算量大、对大规模高质量数据依赖性强;可解释性不足,难以明确异常原因;超参数敏感且训练复杂,模块融合过多可能导致过拟合或训练不稳定.

针对时序大数据异常检测的在线与离线监控适用性,本文对三类方法进行讨论.传统统计学方法算法简单、计算开销低、延迟小,适合在线监控,是实时飞行安全监控的主流手段;经典机器学习方法可通过增量学习实现在线更新和实时检测;深度学习通常用于离线分析,尤其适合复杂时序特征建模.随着计算能力提升,可通过知识蒸馏等手段将复杂模型压缩为轻量级版本,实现有限在线部署.异常检测方法的选择需综合考虑计算延迟、数据流处理及建模复杂度.

此外,在高安全性航空领域,仅依赖“异常/正常”二元判定不足,还需提供可解释依据,为飞行员及运控人员提供透明、可操作的决策支持.因此,具备可解释性的深度异常检测模型可为异常溯源、风险评估及未来预测提供可操作的依据支撑,是当前亟待突破的重要方向.

4 基于时序大数据的征兆挖掘方法综述

前文介绍的异常检测方法主要通过分析当前飞行数据识别出显著偏离正常模式的异常状态.然而,单纯依赖当前异常识别难以及时阻断潜在风险.因此,需沿时间维度前移,挖掘历史数据中的早期征

兆,实现更早期的风险预警与干预.在此背景下,征兆挖掘被视为提升航空安全水平的重要手段^[104-106].

征兆挖掘通过定位与异常事件相关的潜在征兆,具备提前预警和主动缓解风险的能力^[107-110].目前,基于时序大数据的航空征兆挖掘研究尚少,系统架构不成熟.一方面,征兆隐式异常特性难以检测,研究难度大;另一方面,同类异常事件在不同航次的深层原因差异较大,征兆组合形式多样.此外,征兆未直接影响飞行安全,且研究难度较高,对航空经济效益提升有限,因此学术界与工业界关注不足.

根据现有文献,本文从学习机制角度,将征兆挖掘方法分为有监督学习、无监督学习与弱监督学习三类.其中,征兆主要通过从时间维度/特征空间维度提取原时序中关键飞行参数对应连续时间片段进行表征.图 5 从概念上展示了三类学习机制在时序大数据下的特点及数据条件.




图 5 基于学习机制的征兆挖掘方法分类

Fig.5 Classification of learning mechanism-based precursor mining methods

4.1 基于有监督/无监督学习的征兆挖掘方法

基于有监督学习的征兆挖掘方法核心思想是在已知异常实例标签的前提下,直接建立征兆事件与异常事件之间的关联模型,从而实现征兆事件的定位.

Ackley 等^[111]基于飞行品质监控(flight operation quality assurance, FOQA)数据,利用随机森林与特征选择方法,在进近阶段多个等间隔高度开展基于判别性能的飞行参数重要性评估,识别与非稳定进近事件相关的关键参数组合作为征兆在特征维度上的表达.在此基础上,为进一步表达征兆的时序特性,Deshmukh 等^[108]从 ADS-B 数据构建时序逻辑驱动的征兆检测模型,利用监督学习筛选判

别能力强的特征, 并通过时序逻辑表达式实现征兆在时间维度的表征. 该方法通过时序逻辑定位, 可解释性强, 但性能依赖特定场景的逻辑约束和阈值设定.

总体而言, 有监督学习方法可直接建立征兆与异常事件映射, 但依赖精确的时间维度标签, 而实际飞行数据中此类细粒度标签通常难以获取, 因此其应用受到限制.

基于无监督学习的征兆挖掘方法通常从异常检测视角出发, 通过对正常样本建模, 识别出异常事件发生前偏离正常模式的高风险行为, 并将其作为潜在征兆. 与有监督方法相比, 无监督方法仅依赖正常样本, 更适用于异常样本稀缺且难以精确标注的实际飞行数据场景, 因此在征兆挖掘研究中受到广泛关注.

Garcia 等^[112]提出了基于飞行参数动态复杂性分析的征兆挖掘方法, 通过多尺度熵分析方法学习稳定进近与非稳定进近中关键飞行参数(如空速和下降率)的分布差异, 识别异常事件发生前的高风险时序异常点. 在此基础上, Garcia 等^[113]进一步考虑参数间多变量关联, 建立基于相似度的有序序列模式模型, 并利用贝叶斯概率模型将非稳定进近事件相关序列模式作为征兆在时间维度上的可解释表征. 该方法通过统计学方法分析关键参数行为模式, 具有计算复杂度低、可解释性强的优势, 但征兆定位精度仍受建模能力限制.

为了更好地表达多元时间序列复杂时空关联关系, Li 等^[114]联合了 Transformer 和图注意力网络, 并引入对抗训练策略扩大正常和异常特征差异, 以更好地协助定位导致异常事件发生的关键监测指标. Min 等^[115]提出了一种去噪变分 Transformer 模型学习输入特征分布, 并设计残差解释器量化各输入特征对异常评分的贡献. 然而, 此类 Transformer 方法计算复杂度高、训练耗时, 并对数据量存在较高要求.

综上, 基于无监督的征兆挖掘方法核心在于通过正常飞行行为建模识别高风险模式, 实现异常标签稀缺情况下的征兆表征. 然而, 此类方法未以征兆定义为出发点挖掘未来异常事件相关模式, 单纯依赖高风险模式可能限制实际飞行场景中的定位精度. 此外, 在复杂动态飞行场景中, 仅依赖正常样本的单一信息源对具有复杂动态特性的征兆定位仍存在局限性.

4.2 基于弱监督学习的征兆挖掘方法

基于弱监督学习的征兆挖掘方法是通过给定的

事件级标签建立模型, 并利用逆向推理实现征兆在时间维度和特征空间上的精细定位, 可充分利用正常和异常样本辅助征兆识别.

在实际航空应用中, 连续时间维度的异常标签通常难以获取, 而事件级非精确标签相对容易获得^[116]. 这类标签可通过国际标准或人工标注获取, 用于标记某一航次或特定时间段的异常事件信息.

针对这类非精确标签下的弱监督学习问题, 多实例学习 (multi-instance learning, MIL)^[117]是当前流行的方法, 其具有实例级推理的天然特性, 并已在计算机视觉和文档分类等各个领域得到广泛应用^[118]. MIL 方法假设一组未给定标签的“实例”(instance) $I = \{e_1, e_2, \dots, e_n\}$ 被分组到一个给定标签的“包”(bag) B 中, 可通过给定粗颗粒度标签的 B 逆向推理出 I 的细颗粒度标签. 这类方法能够有效识别关键实例, 用于解释决策背后的机理, 与征兆的定位具有较高的匹配度.

在 MIL 框架基础上, 为了描述时序特性, Janakiraman 等^[119]提出了深层时序的多实例学习 (deep temporal multi-instance learning, DT-MIL) 方法, 利用深层循环神经网络增加了对时间序列的时间特性的理解, 以更好地实现征兆在时间维度的定位.

为进一步丰富征兆在时间和特征维度的表达, 文献^[120-121]在 DT-MIL 的基础上提出多头卷积神经网络-循环神经网络 (multi-head convolutional neural networks-recurrent neural networks, MHCNN-RNN) 框架, 实现征兆在时间维度与特征空间的表征, 其中特征空间表达主要通过关键传感器参数来描述. 然而, 这类方法计算复杂度高, 需建立多个 MHCNN 子模块解决征兆在特征空间的表达.

为了兼顾计算复杂度和定位准确性, 基于深度注意力学习的多实例学习方法是当前主流方法^[122-123]; 这类方法通过注意力机制可根据数据动态为实例分配权重, 进一步可通过最大化聚合或加权平均聚合方法得出包的整体表示. 相较于 Transformer 模型中的注意力机制, 这类方法具有更低的模型复杂度, 更适合实际航空应用场景.

基于上述注意力权重计算方法, Xu 等^[124]在多实例学习框架中引入时间与特征双重注意机制, 实现了征兆的联合定位. 进一步结合实际飞行应用场景, Yang 等^[125]提出改进的双重注意力机制深度网络 (dual-attention delta-integral multi-instance learning, DA-DI-MIL), 引入了时间和特征注意力机制增强交互, 有效提升了特定故障下的异常模式定位效果.

进一步, 考虑到征兆的隐性异常属性, Yang 等^[126]

在 DA-DI-MIL 方法基础上构建了层次化模型架构, 通过自主学习离散控制变量中的隐含事件序列, 刻画离散控制信号对连续飞行状态演化的潜在影响; 在隐含事件序列的引导下, 可更为精确地定位连续飞行变量中征兆事件在时间维度与特征维度上的表达。

总体来看, 不同学习范式在基于时间序列的征兆挖掘任务中各具优势与局限。有监督方法可直接建立征兆与异常事件映射, 但高度依赖精细时间标签, 在实际飞行应用中受限。无监督方法标签依赖低, 更符合工程需求, 但通常仅基于正常样本建模, 难以充分刻画复杂多样的征兆模式。弱监督方法, 尤其是融合注意力机制的多实例学习类方法, 在事件级标签条件下兼顾计算复杂度与征兆定位能力, 已成为当前主流方法。然而, 在异常类型高度多样且表现复杂的飞行场景中, 其精细化建模与结果可解释性仍面临挑战。

结合航空应用背景, 复杂航空设备故障与飞行操控影响引发的异常模式通常复杂多样。从单一飞行参数或时间窗口组合描述仅能反映异常范围, 难以揭示其背后发生的真正原因。虽然现有研究对征兆在时间维度或特征空间上进行了部分解释, 但从人为理解角度仍不足。因此, 未来研究需进一步完善征兆表征与动态定位方法, 以更有效支撑飞行运行安全评估与决策。

5 基于时序大数据的趋势跟踪与预测方法综述

基于时序大数据的趋势跟踪与预测方法通过当前飞行数据及已识别的异常模式 (如异常检测与征兆挖掘输出), 对飞行状态进行趋势递推并预测高风险事件, 及时规避风险。然而, 航空安全受飞机状态与人为操控共同影响, 异常事件不总符合单纯的趋势递推假设。因此, 本文在传统时间序列趋势跟踪方法基础上, 引入因果关系推断, 从定性与定量角度综述基于时序大数据的航空安全异常事件趋势跟踪与预测方法, 如图 6 所示。

5.1 基于时间序列的轨迹跟踪方法

在航空安全领域, 基于时间序列的轨迹跟踪方法是当前的热点方向之一, 通过对飞行轨迹模式进行建模与预测, 可实现对异常事件的识别与预警, 为空中交通管理和风险预警提供参考^[127]。比如, Zeng 等^[128]将现有的轨迹预测方法分为三大类: 基于动力学模型的轨迹预测方法、基于状态估计的轨迹预测方法以及基于机器学习的轨迹预测方法, 分别从物理约束、状态估计及数据驱动的角度建模。




Fig. 6 Classification of trend tracking and prediction methods

类似地, Xie 等^[129]将现有轨迹预测研究归纳为基于物理建模与基于学习建模两大类。

基于状态估计的轨迹预测方法通常是给定简单的状态空间方程, 通过估计和更新来实现轨迹预测, 仅适用于短时预测。例如 Dalmau 等^[130]使用卡尔曼滤波构建交互式多模型以提高短期预测精准度; Lymeropoulos 等^[131]通过基于蒙特卡洛方法的粒子滤波模型关注风向风速带来的误差。

基于动力学模型的方法综合考虑飞行器动力学与气动约束构建预测模型。例如 Zhang 等^[132]基于质点模型建立在线 4D 轨迹预测的框架。Fukuda 等^[133]提出在总能量守恒假设下, 建立质点模型模拟飞行器运动。然而, 这类方法对数据要求和模型精度要求高, 难以满足实际应用场景。

基于机器学习的轨迹预测方法直接从历史轨迹中学习复杂时空模式, 提取关键特征用于轨迹跟踪与预测, 无需建立复杂动力学模型^[134-136]。Zeh 等^[137]通过贝叶斯推断方法构建概率预测模型, 增加轨迹预测结果的不确定性, 更好地辅助决策支持系统。何昕等^[138]将 LSTM 与人工神经网络相结合, 建立航空器着陆阶段的轨迹预测模型, 具有更好的预测准确性。Ma 等^[139]结合飞机操纵面的运动状态变化, 在 LSTM 基础上通过弱化记忆窗口改进隐藏层结构, 提高模型轨迹预测的精准度。

近年来, 部分研究将新兴深度学习模型引入航空轨迹预测, 以提升复杂空域下的建模与泛化能力^[140-141]。例如, Chu 等^[142]提出飞行模式引导的社会化 LSTM (flight pattern-guided social-LSTM) 模型, 通过融合飞行模式与多机交互信息, 显著提高了高密度空域的联合预测精度。Transformer 架构已被引入飞行轨迹预测中, 以提升多路线、中长期预测以及未知环境泛化的能力^[143-145]。此外, 基于生成对抗网络的轨迹预测方法通过结合深度生成与

聚类机制,有效刻画了中长期轨迹的多模态分布特征,为不确定性建模提供了新思路^[146]。

总体来看,基于动力学模型和状态估计的方法紧密依赖物理约束和飞行器动态方程,更贴近真实物理描述,具有较高可解释性,但建模复杂、计算量大且对参数精度要求高。相比之下,基于机器学习的方法更灵活,可直接从历史飞行数据中学习轨迹特征,适应复杂环境和多变量输入,但缺乏物理约束解释性,在未知环境或长时序预测中可能不稳定。近年来一些新兴方法显示出在复杂高密度空域、长时序预测及泛化能力方面的潜力。值得注意的是,轨迹预测主要关注空间位置演化,对其他飞行状态安全因素未能直接涵盖;考虑飞行任务复杂性与人为操作因素,仅依赖轨迹偏离将难以全面解释异常事件成因。

5.2 基于时间序列的因果推理方法

在航空安全领域,异常事件通常由多种状态变量与外部因素交互作用引起,其演化难以单纯通过趋势递推刻画。征兆挖掘主要识别与未来高风险事件相关的关键表征,即完成“因”的定位;因果推理则进一步揭示这些关键因素间的潜在因果关联,实现从“因”到“果”的推导。因此,因果推理可视为趋势跟踪与预测的深化拓展,通过贝叶斯网络方法推理异常事件的内在机制,提升预测的解释性与可靠性。基于此,本文在传统时间序列趋势跟踪方法基础上,新增对因果关系推断方法的综述,为异常事件精准预测提供新的思路与支撑。

目前,航空领域的因果关系推理主要用于捕捉事件间因果关系,并构建相应的因果模型,以支持飞机各阶段关键参数的分析与预测。该方法可分为基于传统贝叶斯网络的预测模型与基于深度贝叶斯网络的预测模型。Ayra 等^[147]利用传统贝叶斯网络

建立潜在因素与事件关联,实现跑道冲出事件预测;Bauranov 等^[148]在集成安全保障模型(integrated security assurance model, ISAM)基础上,通过贝叶斯网络增强变量耦合表达,提升安全风险分析能力。Kong 等^[149]提出基于深度贝叶斯网络的方法,通过 LSTM 和蒙特卡洛正则化实现飞机硬着陆垂直速度预测及不确定性评估。

基于时间序列的因果推理方法可从特征空间揭示异常事件的潜在因果关系,更准确地定位关键因素,提升预测的解释性与可靠性,并为异常溯源和飞行员决策提供支持^[150]。

总体来看,基于时序大数据的趋势跟踪方法能够刻画飞行状态演化,但对异常原因解释能力有限。引入因果推理可揭示潜在因果关系,增强预测可解释性。然而,飞机异常模式复杂多样,趋势跟踪与因果推理的有效结合仍面临挑战。因此,如何在航空安全背景下充分联合二者优势,以更好地支撑飞行员决策,是未来研究的重要方向。

6 飞行安全状态评估方法应用场景

为直观展示三类飞行安全状态评估方法的实际作用,本文选取高风险进近阶段作为典型应用场景。该阶段涉及飞行高度、速度、姿态及构型等多因素耦合^[151-152],呈多阶段动态演化,易因非稳定状态引发安全事故,是飞行安全的关键监控阶段。

6.1 非稳定进近事件及其状态评估技术应用现状

非稳定进近事件是进近着陆阶段的常见高风险异常事件,主要表现为在特定的高度下飞机未能维持稳定的下滑路径、下降速度等关键飞行状态。图 7 展示了一般进近过程示意图。尽管进近着陆阶段仅占整体飞行时间的约 4%,但该阶段致命事故占比却高达 50% 左右^[153-154]。根据 ICAO 报告,非稳定进




图 7 飞机一般进近程序示意图

Fig. 7 Schematic diagram of the general aircraft approach procedure

近是空中碰撞、受控飞行撞地等高发事件的重要诱因,且其事故风险较稳定飞行高出约 60 倍,因此对其安全状态的评估尤为关键。

目前航空界主流方法为基于规则的飞行品质监控 FOQA 项目,亦称飞行数据监控 (flight data monitoring, FDM) 项目^[29]。这类安全保障项目实质上可视为一种面向典型飞行场景的状态评估方法^[24],通过预设关键参数阈值实现异常识别与风险监测^[155-157]。

然而,该类方法严重依赖预设阈值,难以适应不同飞行场景,无法满足智能化评估需求。因此,基于大数据的智能状态评估方法逐渐成为研究焦点。

6.2 非稳定进近场景下的征兆与异常事件关联

考虑到征兆概念相较异常更为复杂,本节从飞行状态演化和子事件层级两个视角加以理解,说明征兆事件与异常事件之间的因果关联 (见图 8)。




图 8 征兆与异常事件的关系示意图

Fig.8 Schematic diagram of correlation between precursors and anomalous events

假设在飞行状态演化过程中, {A, B, C, D} 分别为征兆状态 A、干预输入 B、征兆状态 C 与异常状态 D。当出现征兆 A 时,由于及时发现并加入了干预 B,则 A 与之对应的异常事件纽带被切断,从而征兆状态 A 未转化为异常状态,而是回归为正常状态。然而,在后续征兆 C 出现后未及时发现,导致最后异常状态 D 出现。在整个过程中,征兆状态 {A, C} 均存在较高的概率触发异常事件,但是干预的引入与否导致了不同的结果。因此,从状态演变过程可以看出,若能及时识别征兆且采取干预,可以帮助避免后续的异常事件的发生。

从子事件级角度来看^[119], {A, B, C, D} 分别对应速度参考值设置错误、速度参考值设置修正、襟翼未正常设置与非稳定进近异常事件。案例显示:在 2 500 ft 时刻出现速度参考值设置错误,并在 2 000 ft 时刻及时改出,避免了非稳定进近事件发生;在 1 500 ft 时刻发生襟翼未正常设置操作,未及时改出,导致速度过高、异常事件触发。

上述对比表明,征兆挖掘能够提前预警异常事件并预测潜在风险。若征兆被及时发现并采取适当干预,可有效切断征兆与异常事件之间的因果链条,从而避免后续高风险异常事件的发生。

6.3 非稳定进近场景下三类方法的协同机制

非稳定进近作为多阶段耦合、快速变化的高风险场景,对飞行安全状态评估提出了更高要求。有效的评估模型需结合不同阶段飞行特征,嵌入针对性算法模块,实现多维风险识别与干预。目前,异常检测、征兆挖掘和趋势跟踪与预测三类方法已初步形成功能互补、协同演进的机制,主要特点如下:

- 1) 异常检测: 关注已出现的显性偏差,如下降率异常,支持实时告警;
- 2) 征兆挖掘: 聚焦异常前隐性变化,挖掘高风险征兆模式,并揭示其与后续异常之间的因果关联;
- 3) 趋势跟踪与预测: 在当前状态基础上进行演化建模,预测异常事件的触发时机与风险水平。

在实际应用中,三类方法已在非稳定进近场景中取得初步成果。在异常检测方面, Silva 与 Murça^[158]应用 GMM 实现飞行轨迹异常的在线检测。Bonifazi 等^[62]从 ADS-B 数据中提取关键能量特征,建立 GMM 模型学习正常飞行模式,并依据偏差定位异常事件。在征兆挖掘方面, Janakiraman 等^[119]提出的 DT-MIL 方法首次将深层时间多实例学习框架引入飞行数据分析中,可自动定位非稳定进近事件的征兆时序分布。Yang 等^[126]提出分层预测结构,通过离散控制变量与连续状态变量的联合建模,有效提高了进近阶段征兆识别的准确性。在趋势跟踪与预测方面, Goh 等^[159]针对 4D 飞行参数,提出基于隧道的高斯过程方法,以概率方式刻画飞机进近着陆阶段的潜在风险。Zhang 等^[160]构建贝叶斯网络实现因果建模,为飞行状态趋势预测与解释提供新思路。

综上,在非稳定进近典型场景中,三类状态评估方法分别承担异常检测 (检测)、征兆挖掘 (预警) 和趋势跟踪与预测 (预测) 的功能,构建了从当前识别到未来预判的系统化风险评估体系。该协同模式不仅体现方法间互补性,也为多样化飞行任务的安全评估提供理论与实践参考。

7 飞行安全状态评估技术支撑平台

在航空飞行安全的实际应用场景中, 异常检测、征兆挖掘和趋势跟踪与预测等飞行安全状态评估方法的工程化应用, 依赖于稳定的数据通信与软件平台支撑. 本节围绕数据通信支撑技术与软件平台支撑技术两个方面, 简要说明其对飞行安全状态评估方法落地运行的关键支撑作用. 图 9 展示了飞行安全状态评估方法在即时航空安全管理系统设想下的总体运行框架, 依托软硬件平台, 实现机载数据的实时采集、安全状态评估及地面智能分析与决策支持.




图 9 飞机机载实时监控系统示意图

Fig. 9 Schematic diagram of aircraft on-board real-time monitoring system

数据通信支撑技术是实现飞行安全状态评估在线运行的重要前提, 其核心作用在于保障关键飞行参数和状态信息的及时可靠传输. 然而, 随着飞行数据规模和评估能力需求的提升, 通信系统需在数据传输容量、时效性及双向交互稳定性等方面持续优化^[161-166], 以支撑异常检测的实时响应、征兆挖掘的关联分析以及趋势跟踪与预测的持续更新.

软件平台支撑技术则为飞行安全状态评估方法提供统一的数据管理与分析环境, 负责机载与地面多源数据的采集、融合与状态评估结果的组织与呈现. 在即时航空安全管理系统框架下, 平台将以飞行过程安全为核心, 支持对飞行异常、风险征兆及状态演化趋势的在线感知与预警. 当前国内外多个

机载健康监控系统^[167-169]已初步具备数据融合处理、异常识别和信息传输能力, 为飞行安全状态评估方法的集成提供了可靠的平台基础.

综上所述, 飞行安全状态评估方法在现有软硬件环境中具备较强的工程适配基础, 未来可围绕评估需求对平台进行针对性优化与扩展, 从而支撑航空安全的实时化与智能化管理.

8 面临的挑战与未来发展方向

本文围绕异常检测、征兆挖掘和趋势跟踪与预测三类关键方法, 梳理并总结了当前面临的挑战与未来发展方向:

首先, 异常检测模型可解释性不足. 当前方法多基于飞行参数偏离进行检测, 强调“是否异常”的快速判断, 但缺乏对异常根因的深入分析. 在操作性异常与复杂混合异常场景下, 二元判定已难以支撑飞行员决策. 在高安全性航空场景下, 异常检测需提供逻辑清晰、因果可追溯的解释. 未来可引入异常事件因果链建模与置信度评估, 从异常产生、传播到影响范围等多维度提供可追溯解释, 提升模型可信度.

其次, 征兆的动态表征与精准定位仍具挑战性. 高风险征非常表现为隐性异常、非线性及多变量强耦合等复杂特性. 现有方法多基于静态特征, 难以刻画其演化与动态特性. 同时, 征兆是一类不确定性高且标签匮乏的隐性异常风险信号, 进一步增加了建模与验证难度. 因此, 亟须结合关键操控量与多变量联合建模的动态表征方法, 输出结构化因果征兆链, 为风险干预提供理论依据.

第三, 趋势跟踪与因果推理的融合仍处于初期. 趋势预测虽可刻画飞行安全状态演化, 但依赖历史趋势递推^[170-174], 难以应对突变或非线性风险事件. 因果推理如动态贝叶斯网络在部分任务展现潜力, 但在高维数据中构建稳定准确的因果结构仍面临技术瓶颈. 未来可尝试结合趋势预测的序列建模与因果推理的结构建模优势, 发展面向航空安全的因果趋势混合模型, 实现异常状态从“发生-演化-干预”的全过程建模.

大语言模型 (large language models, LLMs) 作为新一代人工智能技术, 凭借多模态知识融合和强推理泛化能力, 已成为国内外研究热点. 目前 LLMs 在飞行安全文本数据处理和航空事故报告分析中已取得初步成果, 并在语义理解、逻辑推理和知识整合方面表现出一定潜力^[175-179]. 比如, 部分研究基于 LLMs 的检索增强生成方法构建了面向航空安全领域的专业问答系统, 有效提升了跨文档知

识检索与推理能力, 为专业安全问答和知识管理提供支持^[175]; 一些工作结合上下文学习与提示工程, 利用 LLMs 实现了航空安全事故报告主要因素的自动分类^[176]; 另外一些研究通过将领域知识嵌入 LLMs 的提示词设计, 提升了通航事故中人因错误的推断效果, 为事故自动分析和辅助调查提供了潜在应用价值^[179].

然而, 上述应用主要集中于文本与知识密集型任务, 其在基于时序大数据的飞行安全评估领域仍处于探索阶段. LLMs 优势在于语义理解与知识推理, 而飞行安全评估依赖连续时序数据, 关注状态动态演化与异常特征识别. 数据形态、任务目标与知识表达机制的差异, 制约了大模型在飞行时序分析中的直接应用.

因此, LLMs 在飞行安全评估中的探索可从知识增强、语义对齐与智能决策三个层面展开. 首先, 在知识增强层, 大模型可作为知识驱动模块, 通过整合领域知识、历史资料与专家经验, 为时序模型提供先验约束与语义指导, 提升对复杂飞行事件的理解与推理能力. 其次, 在语义对齐层, 可借助多模态编码器或嵌入机制, 将时序特征映射至语义空间, 实现飞行状态与风险语义关联建模, 增强模型可解释性与泛化能力. 最后, 在智能决策层, 大模型可作为在环智能体, 结合人机协同机制, 动态参与异常诊断与策略生成, 为主动安全管理提供实时智能支持.

总体而言, 大模型在飞行安全评估中的潜力在于弥合时序表征与语义推理的鸿沟, 通过知识增强、语义对齐与智能协同, 提升模型在复杂动态环境下的泛化与理解能力. 然而, 其在知识可靠性与安全可靠方面仍需深入研究, 为未来航空安全智能化发展提供可验证的技术路径.

综上, 面向未来飞行安全保障的需求, 亟须从以下几个方向深化研究: 1) 强化异常检测模型的可解释性以增强决策支撑能力; 2) 提升征兆事件的动态建模与多维定位能力, 支撑风险溯源与因果分析; 3) 融合趋势建模与因果推理方法, 提升复杂演化事件的预测能力; 4) 引入大模型提升模型在复杂动态环境下的泛化能力.

9 结束语

本文围绕复杂飞行环境下安全管理实时性的需求, 系统梳理了基于时序大数据的飞行安全状态评估方法, 包括异常检测、征兆挖掘和趋势跟踪与预测, 分别对应飞行状态的当前异常、历史征兆与未来趋势, 构建了覆盖“过去 → 现在 → 未来”的多层次评估体系, 实现从实时监测到风险预警及趋势预

测的全流程安全保障.

本文比较分析了各类方法的技术原理、适用场景及其局限性, 凝练出当前在可解释性不足、动态建模能力有限与预测精度提升方面所面临的挑战. 面向未来飞行安全保障, 需深化异常检测可解释性、征兆动态多维定位、趋势与因果推理融合以及大模型赋能.

通过聚焦上述关键技术的突破与集成, 未来飞行安全状态评估方法将更好地满足动态监测的实际需求, 推动飞行安全保障能力向更高水平发展.

参考文献

- 1 Civil Aviation Administration of China News. Work briefing| Civil aviation expected to complete 780 million passenger trips in 2025 [Online], available: http://www.caacnews.com.cn/special/2025zhuant/8274/2019gzhltd/202501/t20250109_1384076.html, January 31, 2026
(中国民航网. 工作会快递|2025 年民航预计完成旅客运输量 7.8 亿人次 [Online], available: http://www.caacnews.com.cn/special/2025zhuant/8274/2019gzhltd/202501/t20250109_1384076.html, 2026-01-31)
- 2 International Air Transport Association. Global outlook for air transport [Online], available: <https://www.iata.org/en/iata-repository/publications/economic-reports/global-outlook-for-air-transport-june-2025/>, January 31, 2026
- 3 Bolić T, Ravenhill P. SESAR: The past, present, and future of European air traffic management research. *Engineering*, 2021, 7(4): 448–451
- 4 Civil Aviation Administration of China News. 2024 national civil aviation work conference held in Beijing [Online], available: http://www.caacnews.com.cn/tt/202401/t20240104_1373688.html, January 22, 2026
(中国民航网. 2024 年全国民航工作会议在京召开 [Online], available: http://www.caacnews.com.cn/tt/202401/t20240104_1373688.html, 2026-01-22)
- 5 Civil Aviation Administration of China. The 14th five-year plan for the development of general aviation [Online], available: <https://www.planning.org.cn/law/zt/view?id=2681>, March 25, 2026
(中国民用航空局. “十四五”通用航空发展专项规划 [Online], available: <https://www.planning.org.cn/law/zt/view?id=2681>, 2026-03-25)
- 6 Civil Aviation Administration of China. Regulatory, rules, and standards framework for data management in smart civil aviation development (2022–2025)(draft for public consultation) [Online], available: <https://www.secrss.com/articles/47306>, March 25, 2026
(中国民用航空局. 智慧民航建设数据管理法规规章标准体系 (2022–2025 年)(征求意见稿) [Online], available: <https://www.secrss.com/articles/47306>, 2026-03-25)
- 7 Burmester G, Ma H, Steinmetz D, Hartmann S. *Advances in Aeronautical Informatics: Technologies Towards Flight 4.0*. Cham: Springer, 2018. 55–65
- 8 Ma H L, Sun Y G, Chung S H, Chan H K. Tackling uncertainties in aircraft maintenance routing: A review of emerging technologies. *Transportation Research Part E: Logistics and Transportation Review*, 2022, 164: Article No. 102805
- 9 Demir G, Moslem S, Duleba S. Artificial intelligence in aviation safety: Systematic review and biometric analysis. *International Journal of Computational Intelligence Systems*, 2024, 17(1): Article No. 279
- 10 National Academies of Sciences, Engineering, and Medicine. *In-time Aviation Safety Management: Challenges and Research for an Evolving Aviation System*. Washington: The National

- Academies Press, 2018.
- 11 Ellis K K, Krois P, Koelling J, Prinzel L J, Davies M D, Mah R. A concept of operations (ConOps) and design considerations for an in-time aviation safety management system (IASMS) for advanced air mobility (AAM). In: Proceedings of the AIAA Scitech 2021 Forum. Virtual Event: AIAA, 2021.
- 12 Ellis K K, Prinzel L J, Koelling J, Davies M D, Mah R, Krois P, et al. An ontological approach to integrate commercial space operations with an in-time aviation safety management system (IASMS). In: Proceedings of ASCEND 2021. Las Vegas, USA: AIAA, 2021.
- 13 Oza N C, Stephens C, Fox K D. Enabling Safety from Data: Machine Learning/Artificial Intelligence for In-time Aviation Safety, NASA, USA, 2021.
- 14 Daily J, Peterson J. *Supply Chain Integration Challenges in Commercial Aerospace: A Comprehensive Perspective on the Aviation Value Chain*. Cham: Springer, 2016. 267–278
- 15 Sun An-Liang. Research on Knowledge Graph Construction Based on Aviation Safety Incident Report ASRS [Master thesis], Sichuan University, China, 2022.
(孙安亮. 基于航空安全事故报告 ASRS 知识图谱构建的研究 [硕士学位论文], 四川大学, 中国, 2022.)
- 16 Billings C E, Lauber J K, Funkhouser H, Lyman E G, Huff E M. NASA Aviation Safety Reporting System, NASA-TM-X-3445, NASA, USA, 1976.
- 17 Shin J. The NASA aviation safety program: Overview. In: Proceedings of the ASME Turbo Expo 2000: Power for Land, Sea, and Air. Munich, Germany: ASME, 2000.
- 18 Ezhilarasu C M, Skaf Z, Jennions I K. The application of reasoning to aerospace integrated vehicle health management (IVHM): Challenges and opportunities. *Progress in Aerospace Sciences*, 2019, **105**: 60–73
- 19 Ellis K K, Prinzel L J, Krois P, Davies M D, Oza N, Stephens C, et al. A future in-time aviation safety management system (IASMS) perspective for commercial air carriers. In: Proceedings of the AIAA AVIATION 2022 Forum. Chicago, USA: AIAA, 2022.
- 20 National Aeronautics and Space Administration. Strategic implementation plan 2023 [Online], available: <https://www.nasa.gov/wp-content/uploads/2021/04/sip-2023-final-508.pdf>, January 19, 2026
- 21 Ellis K K, Krois P, Davirs M D, Koelling J. In-time System-Wide Safety Assurance (ISSA) Concept of Operations, NASA-TM-X-3445NASA, USA, 2019.
- 22 Raza W, Renkhoff J, Ogirimah O, Stansbury R S, Song H B. Flight data recorders: Past, present, and future. *IEEE Aerospace and Electronic Systems Magazine*, 2024, **39**(9): 120–145
- 23 Ellis K K, Prinzel L J, Vincent M, Krois P, Ackerson J, Infeld S, et al. An in-time aviation safety management system concept of operations and modernization of the national airspace system. In: Proceedings of the AIAA SCITECH 2025 Forum. Orlando, FL, USA: AIAA, 2025.
- 24 Coelho e Silva L, Murça M C R. A data analytics framework for anomaly detection in flight operations. *Journal of Air Transport Management*, 2023, **110**: Article No. 102409
- 25 Ellis K K, Prinzel L J, Krois P, Davies M D, Oza N, Mah R, et al. Concept of operations for an in-time aviation safety management system (IASMS) for upper E airspace. In: Proceedings of the AIAA SCITECH 2023 Forum. National Harbor, MD, USA: AIAA, 2023.
- 26 Li S J, Yang Y, Yang L, Su H X, Zhang G G, Wang J. Civil aircraft big data platform. In: Proceedings of the IEEE 11th International Conference on Semantic Computing (ICSC). San Diego, USA: IEEE, 2017. 328–333
- 27 Campbell N A H. The evolution of flight data analysis. In: Proceedings of the Australian Society of Air Safety Investigators (ASASI). Civic Square, Australia: ASASI, 2007.
- 28 Moir I, Seabridge A, Jukes M. *Civil Avionics Systems*. Chichester: John Wiley & Sons, 2013.
- 29 European Union Aviation Safety Agency. Guidance for the Implementation of Flight Data Monitoring Precursors, European Union Aviation Safety Agency, Germany, 2020.
- 30 Yin S, Kaynak O. Big data for modern industry: Challenges and trends [point of view]. *Proceedings of the IEEE*, 2015, **103**(2): 143–146
- 31 Hawkins D M. *Identification of Outliers*. Dordrecht: Springer, 1980.
- 32 Blazquez-Garcia A, Conde A, Mori U, Lozano J A. A review on outlier/anomaly detection in time series data. *ACM Computing Surveys (CSUR)*, 2022, **54**(3): Article No. 56
- 33 Boniol P, Liu Q, Huang M, Palpanas T, Paparrizos J. Dive into time-series anomaly detection: A decade review. arXiv preprint arXiv: 2412.20512, 2024.
- 34 Chandola V, Banerjee A, Kumar V. Anomaly detection: A survey. *ACM Computing Surveys (CSUR)*, 2009, **41**(3): Article No. 15
- 35 Shu Li-Chen, Xu Jian-Guang, Zhu Yu-Long. A review of anomaly detection based on time series data. *Industrial Information Security*, 2025(5): 37–49
(舒历晨, 徐建光, 朱雨龙. 基于时序数据的异常检测综述. 工业信息安全, 2025(5): 37–49)
- 36 Braei M, Wagner S. Anomaly detection in univariate time-series: A survey on the state-of-the-art. arXiv preprint arXiv: 2004.00433, 2020.
- 37 Lou Si-Wei, Zhang Xu-Jie, Yang Yue-Lin, Li Yi, Zhao Yu-Chen, Yang Chun-Jie. Review of fault detection and diagnosis research in blast furnace ironmaking process: Retrospective, status, and prospects. *Acta Automatica Sinica*, 2025, **51**(8): 1739–1759
(楼嗣威, 张徐杰, 杨越麟, 李逸, 赵雨辰, 杨春节. 高炉炼铁过程故障检测与诊断综述: 回顾, 现状与展望. 自动化学报, 2025, **51**(8): 1739–1759)
- 38 Liu J H, Bai J, Liu S. Real-time monitoring of aircraft engines using a feed-forward deep neural network. *Proceedings of the China Aeronautical Science and Technology Conference (CASTC)*. Singapore: Springer, 2023. 390–400
- 39 Singh Y, Bagri K, Jayakumar A, Rizzoni G. Fault diagnostics for oscillatory failure case in aircraft elevator servos. *IFAC-PapersOnline*, 2023, **56**(2): Article No. 408415
- 40 Keipour A, Mousaei M, Scherer S. Automatic real-time anomaly detection for autonomous aerial vehicles. In: Proceedings of the International Conference on Robotics and Automation (ICRA). Montreal, Canada: IEEE, 2019. 5679–5685
- 41 Su M T, Zhao W J, Zhu Y, Zha D, Zhang Y S, Xu P. Anomaly detection of vectorized time series on aircraft battery data. *Expert Systems With Applications*, 2023, **227**: Article No. 120219
- 42 Xiong B W, Xu J W, Kong L R, Fan J G, Chen X H, Hu D T. Gas data anomaly detection based on time-series ARIMA model. In: Proceedings of SPIE 12919, International Conference on Electronic Materials and Information Engineering (EMIE 2023). Guangzhou, China: SPIE, 2023. Article No. 129190W
- 43 Xiao Yong, Zheng Kai-Hong, Yu Zhong-Zhong, Zhou Mi, Li Sen, Ma Qian-Li. Power data anomaly detection based on holt-winters model and DBSCAN clustering. *Power System Technology*, 2020, **44**(3): 1099–1104
(肖勇, 郑楷洪, 余忠忠, 周密, 李森, 马千里. 基于三次指数平滑模型与 DBSCAN 聚类的电量数据异常检测. 电网技术, 2020, **44**(3): 1099–1104)
- 44 Zeng J, Zhang L, Shi G T, Liu T G, Lin K. An ARIMA based real-time monitoring and warning algorithm for the anomaly detection. In: Proceedings of the 23rd IEEE International Conference on Parallel and Distributed Systems (ICPADS). Shenzhen, China: IEEE, 2017. 469–476

- 45 Kozitsin V, Katser I, Lakontsev D. Online forecasting and anomaly detection based on the ARIMA model. *Applied Sciences*, 2021, **11**(7): Article No. 3194
- 46 Xie T M, Xu Q F, Jiang C X. Anomaly detection for multivariate times series through the multi-scale convolutional recurrent variational autoencoder. *Expert Systems With Applications*, 2023, **231**: Article No. 120725
- 47 Zhang C X, Song D J, Chen Y C, Feng X Y, Lumezanu C, Cheng W, et al. A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series data. In: Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu, USA: AAAI Press, 2019. 1409–1416
- 48 Jasra S K, Valentino G, Muscat A, Camilleri R. A comparative study of unsupervised machine learning methods for anomaly detection in flight data: Case studies from real-world flight operations. *Aerospace*, 2025, **12**(2): Article No. 151
- 49 Ying S, Wang B M, Wang L, Li Q S, Zhao Y S, Shang J G, et al. An improved KNN-based efficient log anomaly detection method with automatically labeled samples. *ACM Transactions on Knowledge Discovery From Data (TKDD)*, 2021, **15**(3): Article No. 34
- 50 Bay S D, Schwabacher M. Mining distance-based outliers in near linear time with randomization and a simple pruning rule. In: Proceedings of the 9th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Washington, USA: ACM, 2003. 29–38
- 51 Zhang L Y, Zhao J B, Li W. Online and unsupervised anomaly detection for streaming data using an array of sliding windows and PDDs. *IEEE Transactions on Cybernetics*, 2021, **51**(4): 2284–2289
- 52 Verzola I, Donati A, Martinez J, Schubert M, Somodi L. Project Sibyl: A novelty detection system for human space-flight operations. In: Proceedings of the SpaceOps 2016 Conference. Daejeon, Republic of Korea: AIAA, 2016. Article No. 2405
- 53 Zhang L, Chen Y, Liao S W. Algorithm optimization of anomaly detection based on data mining. In: Proceedings of the 10th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA). Changsha, China: IEEE, 2018. 402–404
- 54 Jasra S K, Valentino G, Muscat A, Camilleri R. Hybrid machine learning-statistical method for anomaly detection in flight data. *Applied Sciences*, 2022, **12**(20): Article No. 10261
- 55 Schlag L, O'Meara C, Wickler M. Numerical analysis of automated anomaly detection algorithms for satellite telemetry. In: Proceedings of the SpaceOps Conference. Marseille, France: AIAA, 2018. Article No. 2534
- 56 Sun Rui-Shan, Han Shao-Hua. Ultra limit incident prediction of flight approach based on isolation forest. *Journal of Safety and Environment*, 2022, **22**(4): 2010–2016
(孙瑞山, 韩韶华. 基于孤立森林的航班进近超限事件预测. 安全与环境学报, 2022, **22**(4): 2010–2016)
- 57 Khan S, Liew C F, Yairi T, McWilliam R. Unsupervised anomaly detection in unmanned aerial vehicles. *Applied Soft Computing*, 2019, **83**: Article No. 105650
- 58 Slimene M B, Ouali M S. Anomaly detection method of aircraft system using multivariate time series clustering and classification techniques. *IFAC-PapersOnLine*, 2022, **55**(10): 1582–1587
- 59 Sheridan K, Puranik T G, Mangortey E, Pinon-Fischer O J, Kirby M, Mavris D N. An application of DBSCAN clustering for flight anomaly detection during the approach phase. In: Proceedings of the AIAA Scitech Forum. Orlando, USA: AIAA, 2020. Article No. 1851
- 60 Sun Rui-Shan, Chen Xiong, Liang Yan. Abnormal operation detection for approach and landing phase based on Gaussian mixture model. *Journal of Safety and Environment*, 2022, **22**(3): 1371–1376
(孙瑞山, 陈雄, 梁妍. 基于高斯混合模型的飞机进近着陆阶段运行异常检测. 安全与环境学报, 2022, **22**(3): 1371–1376)
- 61 Li L S, Hansman R J, Palacios R, Welsch R. Anomaly detection via a Gaussian mixture model for flight operation and safety monitoring. *Transportation Research Part C: Emerging Technologies*, 2016, **64**: 45–57
- 62 Bonifazi A, Sun J, van Baren G, Hoekstra J M. Modeling and detecting anomalous safety events in approach flights using ADS-B data. In: Proceedings of the 14th USA/Europe Air Traffic Management Seminar. Virtual Event: 2021. 20–23
- 63 Zhao W Z, Li L S, Alam S, Wang Y J. An incremental clustering method for anomaly detection in flight data. *Transportation Research Part C: Emerging Technologies*, 2021, **132**: Article No. 103406
- 64 Choi K, Yi J H, Park C, Yoon S. Deep learning for anomaly detection in time-series data: Review, analysis, and guidelines. *IEEE Access*, 2021, **9**: 120043–120065
- 65 Xia T, Zhou L J, Ahmad K. Machine learning-based anomaly detection and prediction in commercial aircraft using autonomous surveillance data. *PLoS One*, 2025, **20**(2): Article No. e0317914
- 66 Guo K, Liu L S, Shi S H, Liu D T, Peng X Y. UAV sensor fault detection using a classifier without negative samples: A local density regulated optimization algorithm. *Sensors*, 2019, **19**(4): Article No. 771
- 67 Ji Y, Lee H. Event-based anomaly detection using a one-class SVM for a hybrid electric vehicle. *IEEE Transactions on Vehicular Technology*, 2022, **71**(6): 6032–6043
- 68 Puranik T G, Mavris D N. Anomaly detection in general-aviation operations using energy metrics and flight-data records. *Journal of Aerospace Information Systems*, 2018, **15**(1): 22–36
- 69 Fuertes S, Pilastre B, D'Escrivan S. Performance assessment of NOSTRADAMUS & other machine learning-based telemetry monitoring systems on a spacecraft anomalies database. In: Proceedings of the SpaceOps Conference. Marseille, France: AIAA, 2018. Article No. 2559
- 70 Wei Bai-Lin, Zhou Ying. Research on abnormal detection of aircraft components based on support vector regression machine. *Scientific and Technological Innovation*, 2024(22): 197–200
(魏柏林, 周莹. 基于支持向量回归机的航空飞机零部件异常检测研究. 科学技术创新, 2024(22): 197–200)
- 71 Darban Z Z, Webb G I, Pan S R, Aggarwal C, Salehi M. Deep learning for time series anomaly detection: A survey. *ACM Computing Surveys*, 2025, **57**(1): Article No. 15
- 72 Pang G S, Shen C H, Cao L B, van den Hengel A. Deep learning for anomaly detection: A review. *ACM Computing Surveys (CSUR)*, 2022, **54**(2): Article No. 38
- 73 Ayhan B, Vargo E P, Tang H. On the exploration of temporal fusion Transformers for anomaly detection with multivariate aviation time-series data. *Aerospace*, 2024, **11**(8): Article No. 646
- 74 Malhotra P, Ramakrishnan A, Anand G, Vig L, Agarwal P, Shroff G. LSTM-based encoder-decoder for multi-sensor anomaly detection. arXiv preprint arXiv: 1607.00148, 2016.
- 75 Luo W X, Liu W, Gao S H. Remembering history with convolutional LSTM for anomaly detection. In: Proceedings of the IEEE International Conference on Multimedia and Expo (ICME). Hong Kong, China: IEEE, 2017. 439–444
- 76 Ding K Z, Li J D, Bhanushali R, Liu H. Deep anomaly detection on attributed networks. In: Proceedings of the SIAM International Conference on Data Mining. Calgary, Canada: SIAM, 2019. 594–602
- 77 Wang S Q, Zeng Y J, Liu X W, Zhu E, Yin J P, Xu C F, et al. Effective end-to-end unsupervised outlier detection via inlier priority of discriminative network. In: Proceedings of the 33rd International Conference on Neural Information Processing Sys-

- tems. Vancouver, Canada: Curran Associates Inc., 2019. Article No. 536
- 78 Zhong J, Zhang H, Miao Q. Flight anomaly detection and localization based on flight data fusion and random channel masking. *Applied Soft Computing*, 2025, **174**: Article No. 113023
- 79 Knorr E M, Ng R T, Tucakov V. Distance-based outliers: Algorithms and applications. *The VLDB Journal*, 2000, **8**(3-4): 237-253
- 80 Chalapathy R, Menon A K, Chawla S. Anomaly detection using one-class neural networks. arXiv preprint arXiv: 1802.06360, 2018.
- 81 Wu P, Liu J, Shen F. A deep one-class neural network for anomalous event detection in complex scenes. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, **31**(7): 2609-2622
- 82 Yang X, Deng C, Zheng F, Yan J C, Liu W. Deep spectral clustering using dual autoencoder network. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, USA: IEEE, 2019. 4061-4070
- 83 Pang G S, Shen C H, Jin H D, van den Hengel A. Deep weakly-supervised anomaly detection. In: Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Long Beach, USA: ACM, 2023. 1795-1807
- 84 Oh M H, Iyengar G. Sequential anomaly detection using inverse reinforcement learning. In: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA: ACM, 2019. 1480-1490
- 85 Fan S H, Shi C, Wang X. Abnormal event detection via heterogeneous information network embedding. In: Proceedings of the 27th ACM International Conference on Information and Knowledge Management. Torino, Italy: ACM, 2018. 1483-1486
- 86 Sabokrou M, Khalooei M, Fathy M, Adeli E. Adversarially learned one-class classifier for novelty detection. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018. 3379-3388
- 87 Campbell N H, Grauer J A, Gregory I M. Loss of control detection for commercial transport aircraft using conditional variational autoencoders. In: Proceedings of the AIAA Scitech 2021 Forum. Virtual Event: AIAA, 2021.
- 88 Gopali S, Abri F, Siami-Namini S, Namin A S. A comparative study of detecting anomalies in time series data using LSTM and TCN models. arXiv preprint arXiv: 2112.09293, 2021.
- 89 Chen Jun-Ying, Xi Yue-Yun, Li Zhao-Yang. Prediction of aero-engine remaining life by combining multi-scale local features and Transformer global learning. *Acta Automatica Sinica*, 2024, **50**(9): 1818-1830
(陈俊英, 席月芸, 李朝阳. 多尺度局部特征和 Transformer 全局学习融合的发动机剩余寿命预测. 自动化学报, 2024, **50**(9): 1818-1830)
- 90 Zhong J, Zhang Y J, Wang J Y, Luo C, Miao Q. Unmanned aerial vehicle flight data anomaly detection and recovery prediction based on spatio-temporal correlation. *IEEE Transactions on Reliability*, 2022, **71**(1): 457-468
- 91 Hundman K, Constantinou V, Laporte C, Colwell I, Soderstrom T. Detecting spacecraft anomalies using LSTMs and nonparametric dynamic thresholding. In: Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK: ACM, 2018. 387-395
- 92 Wang B K, Liu D T, Peng Y, Peng X Y. Multivariate regression-based fault detection and recovery of UAV flight data. *IEEE Transactions on Instrumentation and Measurement*, 2020, **69**(6): 3527-3537
- 93 Tariq S, Lee S, Shin Y, Lee M S, Jung O, Chung D, et al. Detecting anomalies in space using multivariate convolutional LSTM with mixtures of probabilistic PCA. In: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA: ACM, 2019. 2123-2133
- 94 Song Y, Tang D Y, Yu J S, Yu Z T, Li X. Short-term forecasting based on graph convolution networks and multiresolution convolution neural networks for wind power. *IEEE Transactions on Industrial Informatics*, 2023, **19**(2): 1691-1702
- 95 Yang L, Li S B, Zhu C C, Zhang A S, Liao Z H. Spatio-temporal correlation-based multiple regression for anomaly detection and recovery of unmanned aerial vehicle flight data. *Advanced Engineering Informatics*, 2024, **60**: Article No. 102440
- 96 Wang Yin-Ru. Aero-engine fault diagnosis based on time series anomaly detection. *Advances in Aeronautical Science and Engineering*, 2025, **16**(2): 121-133
(王茵茹. 基于时间序列异常检测的航空发动机故障诊断. 航空工程进展, 2025, **16**(2): 121-133)
- 97 Mao Wen-Tao, Tian Si-Yu, Dou Zhi, Zhang Di, Ding Ling. A new deep transfer learning-based online detection method of rolling bearing early fault. *Acta Automatica Sinica*, 2022, **48**(1): 302-314
(毛文涛, 田思雨, 窦智, 张迪, 丁玲. 一种基于深度迁移学习的滚动轴承早期故障在线检测方法. 自动化学报, 2022, **48**(1): 302-314)
- 98 Chevrot A, Vernotte A, Legeard B. CAE: Contextual auto-encoder for multivariate time-series anomaly detection in air transportation. *Computers & Security*, 2022, **116**: Article No. 102652
- 99 Xiao Gang, Lu Da-Peng, Zheng Wen-Bo, Cheng Zhen-Bo, Zhang Yuan-Ming. Multivariable time series data anomaly detection method based on spatiotemporal graph attention network. *Journal of Zhejiang University (Engineering Science)*, 2025, **59**(10): 2134-2143
(肖刚, 卢大鹏, 郑文博, 程振波, 张元鸣. 基于时空图注意力网络的多变量时序数据异常检测方法. 浙江大学学报(工学版), 2025, **59**(10): 2134-2143)
- 100 Zhang Xu, Zhang Liang, Jin Bo, Zhang Hong-Zhe. Uncertainty-based multivariate time series classification. *Acta Automatica Sinica*, 2023, **49**(4): 790-804
(张旭, 张亮, 金博, 张红哲. 基于不确定性的多元时间序列分类算法研究. 自动化学报, 2023, **49**(4): 790-804)
- 101 Zhao H, Wang Y J, Duan J Y, Huang C R, Cao D F, Tong Y H, et al. Multivariate time-series anomaly detection via graph attention network. In: Proceedings of the IEEE International Conference on Data Mining (ICDM). Sorrento, Italy: IEEE, 2020. 841-850
- 102 Yan W L, Li X, Zheng L J, Shang J X, Wu L, Liu H T, et al. DGAN: Flight data anomaly detection based on dual-view graph attention network. *IEEE Sensors Journal*, 2025, **25**(11): 20956-20969
- 103 Du Hang-Yuan, Cao Zhen-Wu, Wang Wen-Jian, Bai Liang. Multi-view outlier detection for attributed network based on knowledge fusion. *Acta Automatica Sinica*, 2023, **49**(8): 1732-1744
(杜航原, 曹振武, 王文剑, 白亮. 融合知识的多视图属性网络异常检测模型. 自动化学报, 2023, **49**(8): 1732-1744)
- 104 Oster C V J, Strong J S, Zorn C K. *Why Airplanes Crash: Aviation Safety in a Changing World*. New York: Oxford University Press, 1992.
- 105 Xue M, Zelinski S J. Dynamic stochastic scheduler for integrated arrivals and departures. In: Proceedings of the 33rd IEEE/AIAA Digital Avionics Systems Conference (DASC). Colorado Springs, USA: IEEE, 2014. 1-21
- 106 Statler I C. The Aviation System Monitoring and Modeling (ASMM) Project: A Documentation of Its History and Accomplishments: 1999-2005, NASA/TP-2007-214556, NASA, USA, 2007.
- 107 Janakiraman V M. Explaining aviation safety incidents using deep temporal multiple instance learning. In: Proceedings of

- the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK: ACM, 2018. 406–415
- 108 Deshmukh R, Sun D W, Kim K, Hwang I. Reactive temporal logic-based precursor detection algorithm for terminal airspace operations. *Journal of Air Transportation*, 2020, **28**(4): 155–163
 - 109 Bleu-Laine M H. A Methodology for the Prediction and Analysis of Precursors to Flight Adverse Events [Master thesis], Georgia Institute of Technology, USA, 2021.
 - 110 Dang X, Hua C C, Rong C T. Automated anomaly detection and causal analysis for civil aviation using QAR data. *Applied Sciences*, 2025, **15**(5): Article No. 2250
 - 111 Ackley J L, Puranik T G, Mavris D. A supervised learning approach for safety event precursor identification in commercial aviation. In: Proceedings of the AIAA AVIATION Forum. Virtual Event: AIAA, 2020. Article No. 2880
 - 112 Garcia E J, Stephens C, Napoli N J. Detecting high-risk anomalies in aircraft dynamics through entropic analysis of time series data. In: Proceedings of the AIAA AVIATION Forum. Chicago, USA: AIAA, 2022. Article No. 3257
 - 113 Garcia E J, Mulvihill M L, Kharab M S, Stephens C L, Napoli N J. Capturing multivariate time series interactions to detect high-risk instability during approach. In: Proceedings of the AIAA AVIATION Forum. San Diego, USA: AIAA, 2023. Article No. 3548
 - 114 Li J, Liu C, Ding J L. Graph Transformer: Anomaly prediction and interpretation in multivariate time series. In: Proceedings of the International Joint Conference on Neural Networks (IJCNN). Yokohama, Japan: IEEE, 2024. 1–8
 - 115 Min H G, Lei X P, Wu X, Fang Y K, Chen S X, Wang W Q, et al. Toward interpretable anomaly detection for autonomous vehicles with denoising variational Transformer. *Engineering Applications of Artificial Intelligence*, 2024, **129**: Article No. 107601
 - 116 Jiang M Q, Hou C C, Zheng A, Hu X Y, Han S Q, Huang H L, et al. Weakly supervised anomaly detection: A survey. arXiv preprint arXiv: 2302.04549, 2023.
 - 117 Dietterich T G, Lathrop R H, Lozano-Pérez T. Solving the multiple instance problem with axis-parallel rectangles. *Artificial Intelligence*, 1997, **89**(1–2): 31–71
 - 118 Carbonneau M A, Cheplygina V, Granger E, Gagnon G. Multiple instance learning: A survey of problem characteristics and applications. *Pattern Recognition*, 2018, **77**: 329–353
 - 119 Janakiraman V M, Matthews B, Oza N. Using ADOPT algorithm and operational data to discover precursors to aviation adverse events. In: Proceedings of the AIAA Information Systems-AIAA Infotech @ Aerospace. Kissimmee, USA: AIAA, 2018. Article No. 1638
 - 120 Bleu-Laine M H, Puranik T G, Mavris D N, Matthews B. Predicting adverse events and their precursors in aviation using multi-class multiple-instance learning. In: Proceedings of the AIAA Scitech 2021 Forum. Virtual Event: AIAA, 2021. Article No. 0776
 - 121 Memarzadeh M, Matthews B, Templin T. Multiclass anomaly detection in flight data using semi-supervised explainable deep learning model. *Journal of Aerospace Information Systems*, 2022, **19**(2): 83–97
 - 122 Ilse M, Tomczak J, Welling M. Attention-based deep multiple instance learning. In: Proceedings of the 35th International Conference on Machine Learning. Stockholm, Sweden: PMLR, 2018. 2127–2136
 - 123 Liu H Y, Liu C, He S B, Chen J M. Short-term strong wind risk prediction for high-speed railway. *IEEE Transactions on Intelligent Transportation Systems*, 2021, **22**(7): 4243–4255
 - 124 Xu D K, Cheng W, Ni J C, Luo D S, Natsumeda M, Song D J, et al. Deep multi-instance contrastive learning with dual attention for anomaly precursor detection. In: Proceedings of the SIAM International Conference on Data Mining (SDM). Virtual Event: SIAM, 2021. 91–99
 - 125 Yang J, Tang D Y, Yu J S, Zhang J, Liu H G. Explaining anomalous events in flight data of UAV with deep attention-based multi-instance learning. *IEEE Transactions on Vehicular Technology*, 2024, **73**(1): 107–119
 - 126 Yang J, Yu J S, Tang D Y, Gao Z B, Feng C, Liu T. An interpretable precursor-driven hierarchical model for predictive aircraft safety. *Engineering Applications of Artificial Intelligence*, 2024, **138**: Article No. 109322
 - 127 European Organisation for the Safety of Air Navigation. EUROCONTROL Specification for Trajectory Prediction, EUROCONTROL-SPECTP-2017, EUROCONTROL Headquarters, Belgium, 2017.
 - 128 Zeng W L, Chu X, Xu Z F, Liu Y, Quan Z B. Aircraft 4D trajectory prediction in civil aviation: A review. *Aerospace*, 2022, **9**(2): Article No. 91
 - 129 Xie X X, Tian Y, Li J C, Wan L L. Shifting from physical models to learning methods for trajectory prediction: A review. *Expert Systems With Applications*, 2026, **297**: Article No. 129303
 - 130 Dalmau R, Pérez-Batlle M, Prats X. Real-time identification of guidance modes in aircraft descents using surveillance data. In: Proceedings of the 37th IEEE/AIAA Digital Avionics Systems Conference (DASC). London, UK: IEEE, 2018. 1–10
 - 131 Lymperopoulos I, Lygeros J. Sequential Monte Carlo methods for multi-aircraft trajectory prediction in air traffic management. *International Journal of Adaptive Control and Signal Processing*, 2010, **24**(10): 830–849
 - 132 Zhang J F, Liu J, Hu R, Zhu H B. Online four dimensional trajectory prediction method based on aircraft intent updating. *Aerospace Science and Technology*, 2018, **77**: 774–787
 - 133 Fukuda Y, Shirakawa M, Senoguchi A. Development and evaluation of trajectory prediction model. In: Proceedings of the 27th International Congress of the Aeronautical Sciences. Nice, France: 2010. 1–8
 - 134 Zhang Z, Guo D Y, Zhou S Z, Zhang J W, Lin Y. Flight trajectory prediction enabled by time-frequency wavelet transform. *Nature Communications*, 2023, **14**(1): Article No. 5258
 - 135 Jia P Y, Chen H P, Zhang L, Han D J. Attention-LSTM based prediction model for aircraft 4D trajectory. *Scientific Reports*, 2022, **12**(1): Article No. 15533
 - 136 Ma L, Tian S. A hybrid CNN-LSTM model for aircraft 4D trajectory prediction. *IEEE Access*, 2020, **8**: 134668–134680
 - 137 Zeh T, Rosenow J, Fricke H. Bayesian inference of aircraft operating speeds for stochastic medium-term trajectory prediction. In: Proceedings of the 42nd IEEE/AIAA Digital Avionics Systems Conference (DASC). Barcelona, Spain: IEEE, 2023. 1–10
 - 138 He Xin, Wang Jing-Yi, Li Ying-Zhe, Zhao Rui. Prediction of aircraft landing stage trajectory based on ANN-LSTM model. *Ship Electronic Engineering*, 2024, **44**(12): 61–64
(何昕, 王经义, 李颖哲, 赵瑞. 基于 ANN-LSTM 模型的航空器着陆阶段运行轨迹预测. 舰船电子工程, 2024, **44**(12): 61–64)
 - 139 Ma Z M, Yao M F, Hong T, Li B. Aircraft surface trajectory prediction method based on LSTM with attenuated memory window. *Journal of Physics: Conference Series*, 2019, **1215**: Article No. 012003
 - 140 Zhou Tong-Le, Liu Zi-Yi, Chen Mou. Knowledge-data-model-driven trajectory fusion prediction method for low-altitude moving target. *Acta Automatica Sinica*, 2026, **52**(2): 296–308
(周同乐, 刘子仪, 陈谋. 知识-数据-模型驱动的低空动目标轨迹融合预测方法. 自动化学报, 2026, **52**(2): 296–308)
 - 141 Xi Xi, Xu Wei, Liu Chuan-Bin, Liu Wei-Qian, Su Xin-Jie. A technology forecasting model integrating spatiotemporal features under the “structure-content” framework. *Acta Automatica Sinica*, 2025, **51**(12): 2621–2632

- (袁希, 许伟, 刘传斌, 刘玮倩, 苏析洁. “结构-内容”框架下融合时空特征的技术预测模型. 自动化学报, 2025, **51**(12): 2621–2632)
- 142 Chu X, Zeng W L, Wu L X. Joint prediction of multi-aircraft trajectories in terminal airspace: A flight pattern-guided social long-short term memory network. *Engineering Applications of Artificial Intelligence*, 2025, **147**: Article No. 110325
 - 143 Silvestre J, Mielgo P, Bregon A, Martínez-Prieto M A, Álvarez-Esteban P C. Multi-route aircraft trajectory prediction using temporal fusion Transformers. *IEEE Access*, 2024, **12**: 174094–174106
 - 144 Yin Y F, Zhang S, Zhang Y C, Zhang Y, Xiang S L. Aircraft trajectory prediction in terminal airspace with intentions derived from local history. *Neurocomputing*, 2025, **615**: Article No. 128843
 - 145 Qin Ming-Qi, Yuan Yi-Ge, Meng Xiao-Yue, Yang Yang. Research on flight trajectory prediction based on an improved Transformer approach. *Advances in Aeronautical Science and Engineering*, DOI: 10.16615/j.cnki.1674-8190
(秦明奇, 袁艺哥, 孟啸月, 杨洋. 基于改进 Transformer 方法的飞行轨迹预测研究. 航空工程进展, DOI: 10.16615/j.cnki.1674-8190)
 - 146 Zhang H Y, Liu Z Z. Four-dimensional aircraft trajectory prediction with a generative deep learning and clustering approach. *Journal of Aerospace Information Systems*, 2025, **22**(2): 90–102
 - 147 Ayra E S, Ríos I D, Cano J. Bayesian network for managing runway overruns in aviation safety. *Journal of Aerospace Information Systems*, 2019, **16**(12): 546–558
 - 148 Bauranov A, Rakas J. Bayesian network model of aviation safety: Impact of new communication technologies on mid-air collisions. *Reliability Engineering & System Safety*, 2024, **243**: Article No. 109905
 - 149 Kong Y X, Zhang X G, Mahadevan S. Bayesian deep learning for aircraft hard landing safety assessment. *IEEE Transactions on Intelligent Transportation Systems*, 2022, **23**(10): 17062–17076
 - 150 Wang Jian-Wen, Chu Fei, Peng Chen, Zeng Guo-Qiang, Wang Fu-Li. Industrial process safety control based on spatio-temporal stable causal dynamic Bayesian network. *Acta Automatica Sinica*, 2025, **51**(9): 2058–2071
(王建文, 褚菲, 彭晨, 曾国强, 王福利. 基于跨时空稳定因果动态贝叶斯网络的工业过程安全控制. 自动化学报, 2025, **51**(9): 2058–2071)
 - 151 Raymer D P. *Aircraft Design: A Conceptual Approach (Fifth edition)*. Reston: American Institute of Aeronautics and Astronautics, 2012.
 - 152 Filippone Antonio. *Advance Aircraft Flight Performance*. Beijing: National Defense Industry Press, 2022.
(安东尼奥·菲力普斯. 先进飞机飞行性能. 北京: 国防工业出版社, 2022.)
 - 153 Boeing. Statistical Summary of Commercial Jet Airplane Accidents Worldwide Operations 1959–2022, Boeing, USA, 2023.
 - 154 Boeing. Statistical Summary of Commercial Jet Airplane Accidents Worldwide Operations, 1959–2021, Boeing, USA, 2022.
 - 155 Flight Safety Foundation. FSF ALAR Briefing Note 7.1—Stabilized Approach, Flight Safety Foundation, USA, 2000.
 - 156 Flight Safety Foundation. FSF ALAR Briefing Note 4.1—Descent-and-Approach Profile Management, Flight Safety Foundation, USA, 2000.
 - 157 Yang J, Tang D Y, Yu J S, Song Y, Kong L K. Data preparation for precursor identification in unstable approach events in flight data. In: Proceedings of the 33rd European Safety and Reliability Conference (ESREL 2023). Singapore: Research Publishing, 2023. 1713–1720
 - 158 Silva e L C, Murça M C. Machine learning models for online anomaly detection in flight operations. In: Proceedings of the AIAA AVIATION Forum. San Diego, USA: AIAA, 2023. Article No. 4107
 - 159 Goh S K, Singh N P, Lim Z J, Alam S. Interpretable tracking and detection of unstable approaches using tunnel Gaussian process. *IEEE Transactions on Aerospace and Electronic Systems*, 2023, **59**(3): 2658–2671
 - 160 Zhang X G, Mahadevan S. Bayesian network modeling of accident investigation reports for aviation safety assessment. *Reliability Engineering & System Safety*, 2021, **209**: Article No. 107371
 - 161 Wang Xiao-Han, Wang Qiang, Liu Yu, Chen Wei-Lin. Research on real-time monitoring of engine based on civil and military aviation compatible data communications. In: Proceedings of the 1st Chinese Aerospace Safety Symposium. Yantai, China: Science Press, 2015. 578–582
(王筱涵, 王强, 刘宇, 陈玮琳. 基于军民航兼容数据通信的发动机实时监控研究. 见: 空天资源的可持续发展——第一届中国空天安全会议论文集. 烟台: 中国指挥控制学会空天安全平行系统专业委员会, 2015. 578–582)
 - 162 Duan Bao-Yuan, Mu Yong-Hua, Mu Yong-He. Using Ethernet in the new-lateral-airplane flight test. *Measurement & Control Technology*, 2011, **30**(4): 91–93
(段宝元, 穆永花, 穆永河. 以太网在新支线飞机试飞测试中的应用. 测控技术, 2011, **30**(4): 91–93)
 - 163 Luo Qing-Hua, Peng Yu, Zhou Peng-Tai, Peng Xi-Yuan, Wang Wei, Huang Tao. Analysis of next generation networking telemetry technology in aeronautical flight test. *Chinese Journal of Scientific Instrument*, 2017, **38**(2): 261–270
(罗清华, 彭宇, 周鹏太, 彭喜元, 王伟, 黄涛. 航空飞行试验新一代网络化遥测技术浅析. 仪器仪表学报, 2017, **38**(2): 261–270)
 - 164 Zhu Ye-Bu, Xu Shuang, Ding Rui. Decoding and application of A320 FAM ACARS messages. *Aviation Maintenance & Engineering*, 2024(1): 66–68
(朱也卜, 徐爽, 丁锐. A320 飞机 ACARS 报文解析与应用. 航空维修与工程, 2024(1): 66–68)
 - 165 Nkomo Tony Walter. Enhanced Reception Technique of ADS-B Signal [Master thesis], University of Electronic Science and Technology of China, China, 2020.
(Nkomo Tony Walter. ADS-B 信号的增强接收技术 [硕士学位论文], 电子科技大学, 中国, 2020.)
 - 166 Zhang Yu. Design and implementation of ATG data transmission system based on 5G. In: Proceedings of the Annual Academic Conference of Liaoning Institute of Communications (CSAE). Shenyang, China: Liaoning Science and Technology Publishing House, 2022.
(张宇. 基于 5G 的 ATG 数据传输系统设计与实现. 见: 辽宁省通信学会学术年会. 沈阳, 中国: 辽宁科学技术出版社, 2022.)
 - 167 Zeng Jing. Research on the development of B737 health monitoring. *Aviation Maintenance & Engineering*, 2023(3): 62–64
(曾晶. 波音 737 飞机健康监控开发思路探究. 航空维修与工程, 2023(3): 62–64)
 - 168 Xu Qing-Hong, Ren He, Ma Xiao-Jun. *Real-time Monitoring and Health Management Technology for Civil Aircraft*. Shanghai: Shanghai Jiao Tong University Press, 2018. 226–233
(徐庆宏, 任和, 马小骏. 民用飞机实时监控与健康管理工作. 上海: 上海交通大学出版社, 2018. 226–233)
 - 169 Wu Hai-Dong, Nie Rui. Design of C919 airborne data real-time processing system. *Computer Measurement & Control*, 2019, **27**(4): 159–162
(吴海东, 聂睿. C919 机载数据实时处理系统设计. 计算机测量与控制, 2019, **27**(4): 159–162)
 - 170 Zhao Zhi-Hong, Zhang Ran, Sun Shi-Sheng. Bearing remaining useful life prediction based on relation network. *Acta Automatica Sinica*, 2023, **49**(7): 1549–1557
(赵志宏, 张然, 孙诗胜. 基于关系网络的轴承剩余使用寿命预测方法. 自动化学报, 2023, **49**(7): 1549–1557)
 - 171 Wang D, Miao Q, Pecht M. Prognostics of lithium-ion batteries based on relevance vectors and a conditional three-parameter capacity degradation model. *Journal of Power Sources*, 2013,

239: 253–264

- 172 Yang J, Yu J S, Tang D Y, Dai J. A closed-loop voltage prognosis for lithium-ion batteries under dynamic loads using an improved equivalent circuit model. *Microelectronics Reliability*, 2019, **100–101**: Article No. 113459
- 173 Wang H K, Cheng Y, Song K. Remaining useful life estimation of aircraft engines using a joint deep learning model based on TCNN and Transformer. *Computational Intelligence and Neuroscience*, 2021, **2021**(1): Article No. 5185938
- 174 Liu Yu-Meng, Zheng Xu, Tian Ling, Wang Hong-An. Remaining useful life estimation of facilities based on reasoning over temporal graphs. *Acta Automatica Sinica*, 2024, **50**(1): 76–88 (刘雨蒙, 郑旭, 田玲, 王宏安. 基于时序图推理的设备剩余使用寿命预测. 自动化学报, 2024, **50**(1): 76–88)
- 175 Zhang Z H, Yang X C, Zeng C C. A domain-specific retrieval-augmented generation system for civil aviation safety. In: Proceedings of the 4th International Conference on Big Data, Artificial Intelligence and Risk Management. Chengdu, China: ACM, 2024. 682–687
- 176 Yang Y C, Shi D H, Zurada J, Guan J. Application of large language model and in-context learning for aviation safety prediction. In: Proceedings of the 17th International Conference on Advanced Computer Theory and Engineering (ICACTE). Hefei, China: IEEE, 2024. 361–365
- 177 Nanyonga A, Joiner K, Turhan U, Wild G. Applications of natural language processing in aviation safety: A review and qualitative analysis. arXiv preprint arXiv: 2501.06210, 2025.
- 178 Tikayat R A, Bhat A P, White R T, Nguyen V M, Pinon F O J, Mavris D N. Examining the potential of generative language models for aviation safety analysis: Case study and insights using the aviation safety reporting system (ASRS). *Aerospace*, 2023, **10**(9): Article No. 770
- 179 Liu Q L, Li F, Ng K K H, Han J S, Feng S S. Accident investigation via LLMS reasoning: HFACS-guided chain-of-thoughts enhance general aviation safety. *Expert Systems With Applications*, 2025, **269**: Article No. 126422



杨洁 杭州市北京航空航天大学国际创新研究院(北京航空航天大学国际创新学院)博士后. 主要研究方向为航空器监测与检测, 飞行状态评估, 可解释异常检测与预测.

E-mail: megan_yj@buaa.edu.cn

(YANG Jie Postdoctor at the Hangzhou International Innovation Institute, Beihang University. Her research interests include aircraft monitoring and detection, flight state assessment, interpretable anomaly detection and prediction.)



唐荻音 北京航空航天大学自动化科学与电气工程学院副教授. 主要研究方向为故障诊断, 退化建模以及视情维护.

E-mail: tangdiyin@buaa.edu.cn

(TANG Di-Yin Associate professor at the School of Automation Science and Electrical Engineering, Beihang University. Her research interests include fault diagnosis, degradation-based modeling, and condition-based maintenance.)



马泽珊 北京航空航天大学中法工程师学院硕士研究生. 主要研究方向为航空器监测与检测.

E-mail: 21241024@buaa.edu.cn


(MA Ze-Shan Master student at the Sino-French Engineer School, Beihang University. Her research interests include aircraft monitoring and detection.)



刘宝鼎 北京航空航天大学自动化科学与电气工程学院博士研究生. 主要研究方向为故障诊断, 视情维护.

E-mail: 16241094@buaa.edu.cn

(LIU Bao-Ding Ph.D. candidate at the School of Automation Science and Electrical Engineering, Beihang University. His research interests include fault diagnosis and condition-based maintenance.)



贡欣宇 北京航空航天大学自动化科学与电气工程学院硕士研究生. 主要研究方向为预测与健康管理.

E-mail: gxyfred@buaa.edu.cn

(GONG Xin-Yu Master student at the School of Automation Science and Electrical Engineering, Beihang University. His research interests include prognostics and health management.)



文正旭 北京航空航天大学中法工程师学院硕士研究生. 主要研究方向为飞行状态评估.

E-mail: sy2224137@buaa.edu.cn

(WEN Zheng-Xu Master student at the Sino-French Engineer School, Beihang University. His main research interest is flight state assessment.)



于劲松 北京航空航天大学自动化科学与电气工程学院教授. 主要研究方向为预测与健康管理, 自动化测试. 本文通信作者.

E-mail: yujs@buaa.edu.cn

(YU Jin-Song Professor at the School of Automation Science and Electrical Engineering, Beihang University. His research interests include prognostics and health management, and automatic testing. Corresponding author of this paper.)



卢劲鹏 北京航空航天大学中法工程师学院硕士研究生. 主要研究方向为航空器监测与检测, 预测与健康管理.

E-mail: jinpeng_lu@buaa.edu.cn

(LU Jin-Peng Master student at the Sino-French Engineer School, Beihang University. His research in-

terests include aircraft monitoring and detection, prognostics and health management.)



康 锐 杭州市北京航空航天大学国际创新研究院 (北京航空航天大学国际创新学院) 教授. 主要研究方向为确信可靠性理论.

E-mail: kangrui@buaa.edu.cn

(KANG Rui Professor at the Hangzhou International Innovation

Institute, Beihang University. His main research interest is belief reliability theory.)



韩丹阳 杭州市北京航空航天大学国际创新研究院 (北京航空航天大学国际创新学院) 博士后. 主要研究方向为故障诊断, 退化建模, 视情维护, 预测与健康管理.

E-mail: hd_y_daniel@buaa.edu.cn

(HAN Dan-Yang Postdoctor at

the Hangzhou International Innovation Institute, Beihang University. His research interests include fault diagnosis, degradation-based modeling, condition-based maintenance, prognostics and health management.)



陶来发 杭州市北京航空航天大学国际创新研究院 (北京航空航天大学国际创新学院) 研究员. 主要研究方向为故障诊断与预测, 健康状态评估, 复杂系统健康管理.

E-mail: taolaifa@buaa.edu.cn

(TAO Lai-Fa Researcher at the

Hangzhou International Innovation Institute, Beihang University. His research interests include fault diagnosis and prognostics, health state assessment, and health management for complex systems.)



冯 灿 中国商飞上海飞机试飞工程有限公司试飞测试技术二级专业总师, 测试工程部部长, 技术创新中心主任. 主要研究方向为试飞测试工程.

E-mail: fengcan@comac.cc

(FENG Can Level-2 chief technical specialist for flight test, director

of the test engineering department, and director of the Technology Innovation Center at the COMAC Shanghai Aircraft Flight Test Co., Ltd. His main research interest is flight test engineering.)



刘 涛 中国商飞上海飞机试飞工程有限公司技术创新中心主任部门助理. 主要研究方向为试飞测试数据处理.

E-mail: liutao2@comac.cc

(LIU Tao Assistant to the department director of the Technology Innovation Center at the COMAC

Shanghai Aircraft Flight Test Co., Ltd. His main research interest is flight test data processing.)