

民航飞机预测性维修数据驱动与混合方法综述

李 伟

四川航空股份有限公司工程技术分公司, 四川 成都

收稿日期: 2026年8月1日; 录用日期: 2026年8月31日; 发布日期: 2026年9月8日

摘 要

预测性维修技术在民航业是保障运行安全、降低维修成本与减少非计划停场损失的关键技术手段, 正推动着民航机务维修模式由定时预防性维修向数据驱动、混合模式维修转型。围绕算法研究方法、混合建模方式以及实际工程应用三个方面, 本文对民航飞机预测性维修的相关研究成果和发展现状进行整理与总结。本文从数据、方法及挑战三个层面总结民航预测性维修研究进展, 梳理飞行记录数据、机载健康监测数据、维修日志以及运行环境参数等多源数据, 分析CNN/LSTM、Transformer和图神经网络等剩余寿命预测方法, 并介绍物理信息神经网络与数字孪生在该领域的应用情况, 最后讨论该领域所面临的数据标注不足、跨工况泛化能力有限、模型可解释性欠缺以及工程部署困难。

关键词

预测性维修, 剩余使用寿命, 数据驱动, 数字孪生, 混合模型

A Review of Data-Driven and Hybrid Approaches to Predictive Maintenance for Civil Aircraft

Wei Li

Sichuan Airlines Technics, Chengdu Sichuan

Received: August 1, 2026; accepted: August 31, 2026; published: September 8, 2026

Abstract

Predictive maintenance technology is a key technical means to ensure operational safety, reduce

maintenance costs, and minimize AOG losses in the civil aviation industry. It is driving the transformation of civil aviation aircraft maintenance models from scheduled preventive maintenance to data-driven, hybrid maintenance. This paper organizes and summarizes research findings and current developments in predictive maintenance for civil aircraft, focusing on algorithmic research methods, hybrid modeling approaches, and practical engineering applications. The research progress of predictive maintenance in civil aviation is summarized from three aspects: data, methods, and challenges. First, it sorts out multi-source data such as flight record data, on-board health monitoring data, maintenance logs, and operating environment parameters. Secondly, it analyzes remaining lifetime prediction methods such as CNN/LSTM, Transformer, and graph neural networks. Thirdly, the application of physical information neural networks and digital twins in this field is introduced. Finally, this paper discusses the insufficient data labeling, limited generalization ability across operating conditions, lack of model interpretability, and difficulties in engineering deployment faced in this field.

Keywords

Predictive Maintenance, Remaining Useful Life, Data-Driven, Digital Twin, Hybrid Model

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

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

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



Open Access

1. 引言

飞机维修的效率是民航业保障安全运行与降本增效环节的一个重要手段。根据国际航空运输协会统计, 维修与工程支出约占航空公司直接运营成本的 10%~15%, 而行业估计表明, 由航空器突发故障导致非计划停场(Aircraft On Ground, AOG)会引发航班连锁扰动, 其造成的损失成本可达每小时 10,000 美元到 150,000 美元, 具体费用取决于飞机类型以及航线的影响程度[1]。民航飞机维修策略经历了漫长的技术演进, 即纠正性维修、定时预防性维修、基于状态的视情维修以及以数据驱动为核心的预测性维修(Predictive Maintenance, PdM) [2]。

目前民航业广泛采用的维修策略是按飞行小时/循环周期更换设备的定时预防性维修, 这种方式可以在最大程度上保障航空器的安全性, 但也会存在一定的剩余可用寿命(Remaining Useful Life, RUL)被浪费的“维修过剩”现象。近年来, 随着机载传感设施、空地通信技术、飞机健康状态监测和数智化技术的发展, 使飞机运行数据、维修记录与环境信息的深度利用成为可能, 软件算法与数据科学推动着航空维修模式不断转型。因此, 基于航空器的历史运维数据与实时健康状态数据, 利用深度学习算法对剩余使用寿命进行识别的预测性维修成为民航维修领域内的研究热点[3]。

民航 PdM 或智能维修的研究成果在技术发展与应用方向主要体现在两方面: (1) 围绕单一深度学习模型(如 CNN [4] [5]、LSTM [6]等热门网络模型)对航空器剩余寿命进行预测的机器学习方法, 已经取得了不错的进展, 但现有综述对民航 PdM 中各类数据驱动方法的类型、适用边界尚缺乏系统比较。(2) 数据驱动常常依赖于训练数据的规模和特定领域, 在噪声干扰、变工况及小样本条件下泛化能力明显不足, 物理模型与数据驱动的相结合的方法如何有效弥补纯数据驱动模型的不足仍在探索阶段[7] [8]。(3) 多数学术成果以预测剩余寿命估计精度作为主要评价指标, 但真实民航场景的应用受到数据质量与数据共享、故障标签稀缺、运行工况差异、模型可解释性、维修资源约束以及适航可接受性等多重因素影响, 使得高精度算法并不必然等同于高可用的工程方案[9]。

因此，本文从算法方法、混合方法与工程应用三个方面展开综述，主要贡献为：梳理民航预测性维修中的数据驱动方法及其应用场景；总结混合建模与数字孪生的发展脉络及关键实现路径；讨论现有模型可信性、跨场景迁移与工程落地应用等开放性挑战，以期为民航飞机预测性维修的工程化研究与应用提供参考。

2. 民航预测性维修的多源异构数据

2.1. 多源异构航空数据特征分析

民航 PdM 的数据主要是由机载快速存取记录器(QAR)与飞行数据记录器(FDR)飞行参数、机载健康监测数据、维修文本日志及运行环境数据等多源异构数据组成。QAR/FDR 具有典型的高频、海量、强噪声与多工况特性，记录了飞机的位置、姿态、操作、告警、发动机性能等参数[10]。机载健康监测数据覆盖以飞机状态监控系统(ACMS)、飞机健康管理(AHM)和发动机健康监测系统采集的故障代码、告警信息、趋势参数、发动机性能参数、系统状态参数等数据[11]。维修文本日志主要以故障现象、故障原因和处置措施等非结构化文本形式存在，包含大量专业术语、缩写及非标准化表达，需借助自然语言处理技术进行结构化解析与文本信息提取[12]。运行环境数据涵盖机场气象(温度、湿度、气压)、航路大气环境与机场海拔等外部变量，多为低频、时空离散的异构数据，与机载高频时序数据在采样尺度上难以直接对齐[13]。

由于受到民航真实运行数据的保密性限制，在学术研究领域，最常见的公开基准数据集是由 NASA 发布的 C-MAPSS [14]与 N-CMAPSS [15]航空发动机数据集。C-MAPSS 通过仿真生成不同运行条件和故障模式下的多传感器全寿命退化轨迹，提供了多工况、多故障模式下的全寿命周期仿真数据，是剩余寿命预测研究最常用的基准。N-CMAPSS 是 C-MAPSS 的升级版，通过进一步引入真实飞行剖面与变工况退化轨迹，并提供故障类别标签，使运行条件更接近实际航空场景，为评估模型的变工况泛化能力提供了新的测试基准。民航预测性维修常用的航空数据类型及其特征如表 1 所示。

Table 1. Types of aviation data used in civil aviation predictive maintenance and their characteristics
表 1. 民航预测性维修常用航空数据类型及其特征

数据类型	来源	典型数据内容	主要特征	在预测性维修中的典型应用
QAR 数据	快速存取记录器(QAR)	高度、速度、姿态、发动机转速、温度、压力、油量、操纵参数等	多变量时序、高频、数据量大、强噪声；受飞行阶段和运行工况影响明显	异常检测、状态监测、故障预警、性能退化分析、健康指标构建
FDR 数据	飞行数据记录器(FDR)	飞行状态、操纵输入、发动机及关键系统参数	连续时序、可靠性高、具有明确的飞行阶段属性	飞行状态重构、异常事件分析、系统性能监测、故障关联分析
机载健康监测数据	ACMS、AHM、发动机健康监控系统等	故障代码、告警信息、趋势参数、发动机性能参数、系统状态参数	面向特定系统、故障相关性较强，具有较高实时性	故障诊断、趋势监控、部件性能退化识别、RUL 预测
维修文本日志	技术日志、维修记录、工卡、故障报告、拆换记录等	故障现象、故障原因、排故过程、维修措施、部件拆换信息	非结构化或半结构化文本，专业缩写多、表达不规范、上下文依赖强	故障知识抽取、故障分类、维修案例检索、故障维修措施关联分析
运行环境数据	航班运行系统、气象系统、机场及航线数据	航段、飞行循环、载荷、环境温度、湿度、高度、机场与航线条件等	低频、多源、上下文相关，与设备退化存在间接关联	工况划分、退化模型修正、风险分析、跨航线/跨环境健康评估

续表

C-MAPSS 数据集	NASA C-MAPSS 仿真平台	多台航空发动机从健康状态到失效的多传感器退化序列及运行条件	标准化高、具有完整退化轨迹和 RUL 标签, 包含多运行工况及故障模式	RUL 预测、健康指标构建、CNN/LSTM/Transformer 等算法性能比较
N-CMAPSS 数据集	NASA N-CMAPSS	基于真实商业飞行剖面的发动机多变量时序、退化状态及故障信息	相较 C-MAPSS 具有更复杂的飞行工况、更高时间分辨率和更丰富的退化信息	复杂工况下 RUL 预测、健康状态估计、迁移学习及模型泛化研究

尽管这两个公开数据集极大促进了算法和技术上的发展, 但仍主要依赖仿真退化过程, 难以完全覆盖真实机队中 QAR 数据的噪声水平、缺失模式与维修文本的语义复杂性, 数据治理与多源对齐等问题, 因此, 航空 PdM 实质上面临数值时序与非结构化语义信息的多源异构数据融合问题。

2.2. 多源异构数据预处理与知识提取

民航飞机预测性维修建模工作需要依托各类多源异构数据开展, 但不同数据源在采样频率、记录机制、语义粒度和数据质量等方面存在显著差异, 因此在搭建预测模型之前, 通常需要对原始数据进行数据清洗、时间维度校准、多类数据整合以及故障标签整理等数据预处理工作[11][15]。对于 QAR/FDR 和机载健康监测数据, 常见问题包括缺失值、异常值、重复记录、时间戳偏差及不同飞行工况带来的干扰问题。针对这些问题, 通常可采用基于规则与统计的方法、滤波与插值方法以及面向趋势保持的质量控制方法进行处理。预测性维修工作的核心, 是捕捉设备故障的前期征兆和性能退化的整体变化过程, 因此数据清洗的时候应当避免过度平滑, 以免早期异常信息被削弱[13]-[15]。

不同渠道采集的民航设备数据, 在记录时间范围和数据触发形式上有着较大差别; QAR/FDR 多为高频且连续的时序数据, 机载健康监测数据包含固定周期采样和突发事件触发两种形式, 维修日志数据以零散的文字事件记录为主, 飞行运行环境数据则是低频的时空离散数据。因此, 多源融合前通常需要统一所有数据的时间标准, 划分对应的飞行阶段, 将数据对应到对应航班和飞机机型, 同时完成各类数据的事件窗口匹配工作, 再通过数据整合、特征整合、决策整合的方式, 形成统一的设备健康状态信息[11]。在实际的民航运行场景中, 只完成数据时间同步的基础工作并不足够, 还需要结合设备告警信息、性能退化情况、维修处理流程之间的业务关联, 开展综合性的数据处理工作。

维修文本日志是故障标签与领域知识的重要来源, 但其通常存在专业词汇多、简写用法繁杂、书写格式不统一、语句信息缺失等诸多问题, 大幅提升了数据结构化整理和利用的难度。为此, 研究中通常采用文字标准化处理、信息实体识别、文本内容归类、语义关系提取等基础文本处理手段, 从维修日志中筛选出故障零部件、故障具体表现、故障产生原因、对应的维修处理方案等关键信息, 并与设备故障代码、工卡及零部件拆换记录进行交叉验证, 以构建更加可靠的标签体系和领域知识表示[12]。总体而言, 多源异构数据处理与维修文本知识提取直接决定了样本质量与标签可信度, 是保障预测性维修模型有效性与工程可用性的关键基础。

综上, 多源异构数据的清洗、对齐、融合以及维修文本知识提取, 既会影响模型训练样本和故障标签的可靠程度, 也会对预测性维修模型的适配能力、可解读性以及实际工程应用效果产生直接作用。因此, 这部分数据处理工作, 是民航飞机预测性维修相关研究中不可或缺的基础核心环节。

3. 数据驱动的剩余使用寿命预测算法

民航飞机关键部件的 RUL 预测是从多源传感器监测数据中自动提取退化特征并映射至设备剩余可用时间。近年来, 借助深度学习和数据挖掘技术, 数据驱动 RUL 的预测算法能够直接从飞行参数、发动

机性能参数及部件状态监测数据中自动挖掘退化规律,在处理高维、非线性、多工况的航空发动机及子系统监测数据方面展现出显著优越性[16]。本文从深度神经网络时空特征提取、基于自注意力机制的Transformer 前沿应用以及面向复杂系统的图神经网络三个维度,梳理数据驱动 RUL 预测算法的研究进展。

3.1. 深度神经网络的时空特征提取

正如前文所述,民航 PdM 数据具有高维、多变量、异构、耦合性强等特性,而 RUL 预测的首要目标是提取传感器间的空间关联与时序退化规律,因此,卷积神经网络(Convolutional Neural Network, CNN)与循环神经网络(Recurrent Neural Network, RNN)及其变体长短期记忆网络(Long Short-Term Memory, LSTM),凭借各自在空间特征提取与时序建模方面的独特优势,已成为航空发动机 RUL 预测的基础网络架构[17]。CNN 通过卷积核在多个传感器通道之间滑动,能够提取多传感器数据之间的空间相关性和局部特征,进而判断局部退化模式;RNN 及其改进模型 LSTM、GRU 按照时间顺序更新隐状态,更适于描述部件性能随循环次数逐渐衰退的动态过程。因此,近年来较典型的技术路线并非单独使用 CNN 或 LSTM,而是利用 CNN 完成局部及跨传感器特征压缩,再通过 LSTM、BiLSTM 或 GRU 建立跨时间窗的退化演化映射[18]-[22]。

李杰等将两层 CNN 与两层 LSTM 串联,利用 CNN 挖掘监测数据的空间特征,再由 LSTM 学习退化序列的时间依赖,在 C-MAPSS 上使 Score 和 RMSE 分别下降 32%和 8.3% [23]。为了提高不同退化尺度的表达能力,Chen 等将多尺度深度 CNN 与 LSTM 结合,使不同感受野分别学习局部波动和较长期退化模式,从而缓解单一时间尺度难以兼顾不同故障阶段的问题[24]。另一种做法是以时序卷积网络(Temporal Convolutional Network, TCN)替代部分循环结构以提高大规模机队数据的计算效率,Ren 等首先利用卷积自编码器融合多传感器信息,再利用 TCN 的因果卷积和扩张卷积进行退化序列建模,在保持较大时间感受野的同时提高并行计算能力[25]。

从民航 PdM 应用的角度看,CNN/RNN 与 LSTM 相结合的混合框架仍存在一定的局限性。第一,CNN 论文中的“空间特征”并不总是等同于航空状态监测数据中的空间结构,CNN 更多捕捉的是滑动窗口内的局部通道相关性,而非部件之间可解释的连接关系。第二,LSTM 递归计算在超长序列上效率低下且信息传递存在衰减,当输入窗口延长至多个航段或较长退化周期时,其训练效率和超长依赖表达能力仍会下降。在此基础上,注意力机制被用于弥补传统 CNN-LSTM 对关键通道和关键局部区域响应不足的问题。Li 等将卷积块注意力模块(CBAM)嵌入 CNN-LSTM,在通道与空间两个维度重新加权特征,在 C-MAPSS DS02 数据集上较同类使 RMSE 降低 17.4%、Score 改善 25.9% [26]。Deng 等提出一种基于 CNN-LSTM-Attention 的飞机发动机剩余使用寿命预测模型,利用 CNN 提取局部退化特征,LSTM 学习时间演化关系,注意力层则重新分配不同时间步及特征对寿命预测的贡献[27]。

3.2. 基于自注意力机制的 Transformer 架构

Transformer 架构是利用自注意力机制并行计算序列中任意两个时间步之间的相关性,并利用位置编码保留序列顺序,从而缓解 RNN、LSTM 递归计算在长序列上的梯度衰减和串行计算效率低下的问题[28]。对于民航 PdM 数据而言,海量、多源的数据特征需要该架构利用不同注意力头分别关注不同传感器组合、退化阶段和时间尺度,从而为复杂运行条件下的非平稳退化提供更灵活的表征空间。

近年来,Transformer 及其变体在航空发动机 RUL 预测中得到广泛应用,技术路线主要分为两类。第一类是将 CNN、LSTM、Transformer 进行融合,补足对局部模式和噪声鲁棒性的不足。Hu 等根据航空发动机传感器序列特点修改 Transformer 结构,并分别将 CNN 和 LSTM 嵌入 Transformer 编码器、解码器,

使 CNN 负责局部退化模式提取、LSTM 补充连续时序信息、Transformer 负责全局依赖建模, 结果表明这种方式适合多传感器的航空数据[29]。Wang 等提出时间增强多头自注意力模型, 通过显式强化时间信息来筛选与 RUL 相关的关键时刻和传感器特征[30]。这些研究表明, Transformer 在航空 RUL 预测中的价值并非简单替换 LSTM, 而是将传统局部时序建模扩展为跨时间尺度的全局关联建模。第二类是在多尺度和多头注意力方面的改进, 以适应民航多工况的工程特点。Zhao 等提出一种多尺度深度自注意力网络(MSIDSN), 通过融合多尺度卷积块与自注意力机制实现多传感器退化特征的有选择性提取, 并采用并行 BiGRU 和 BiLSTM 捕捉时间尺度上的长期依赖关系, 同时引入新型损失函数修正延迟预测, 在航空发动机剩余使用寿命预测任务中取得了优越性能[31]。Zhang 等采用交叉注意力多尺度状态空间模型(CM-Mamba), 借助双通道多尺度切片的处理方式, 分别提取出数据中全局的长期退化特征和局部的短期异常变化规律, 模型还结合窗口自注意力和交叉注意力两种机制, 让全局特征与局部特征可以充分融合交互, 该方法在 C-MAPSS 数据集的剩余使用寿命预测测试中, 表现优于当下多种主流的预测方法[32]。第三类是在架构的轻量化和高效性方面进行改进, Zhang 等设计一种剪枝自适应最优轻量级 PAOLTransformer 模型, 依据范数相关信息判断各个参数的作用大小, 再通过结构化剪枝的方式去除模型中多余的参数结构, 同时结合强化学习算法自动匹配最合适的模型压缩比例; 和传统的标准 Transformer 模型相比, 该模型的预测误差降低了 7% 左右, 整体计算复杂程度也下降了 33% [33]。Ren 等构建一种轻量级分组 GT-MRNet 网络, 通过分组线性变换的方式减少模型的冗余参数, 并引入自适应时间序列精简方法, 能够动态筛选出设备关键的退化时间节点; 该网络在预测精度基本不变的情况下把计算成本压缩了 91.8%, 从而为航空发动机等核心部件的在线实时剩余使用寿命预测提供了一种高效的边缘智能解决思路[34]。

Transformer 模型虽然在寿命预测的精准度上有了明显提升, 但目前大部分相关研究的测试数据, 都来源于 C-MAPSS 这类仿真模拟数据集; 这类仿真数据和民航飞机实际运行的 QAR 快速存取记录器数据存在一定区别, 两者在噪声分布、数据缺失形式和设备退化特征的丰富度上均有差异, 所以这类模型在实际工程场景中的适配效果, 还需要开展更多验证工作。

在民航飞机预测性维修的实际应用场景中, 相关研究成果还需要兼顾多工况适配能力、预测结果区间、模型推理速度和模型压缩比例等多项指标, 以此判定这类预测模型是否能够真正应用于机载边缘计算设备, 或是落地到航空公司的实际维修决策工作中。

3.3. 面向复杂系统的图神经网络

民航飞机内部搭载着液压系统、环境控制系统、气路系统等多个复杂子系统, 在系统内容分布着数量众多的传感器节点, 各类节点之间存在着相互关联、相互影响的耦合关系。传统的深度学习方法通常把各个传感器的数据当作彼此独立的通道来分别处理, 忽略了传感器之间客观存在的拓扑关联关系, 因此在面对系统级的级联故障时, 预测效果往往不够理想。图神经网络(Graph Neural Network, GNN)通过将传感器节点以及节点之间的关联关系建模为一种图结构, 为复杂系统的健康状态评估提供了新思路。当 GNN 被应用于航空领域的 RUL 预测任务时, 首先需要解决的一个关键问题是如何构建能够真实反映复杂系统内部传感器节点拓扑关系的图结构。

在图构建层面, 目前可以归纳出三种具有代表性的技术方向。第一类是物理信息引导构建图结构, 即根据系统原理图、部件连接关系和能量/介质传递路径预先确定邻接矩阵。Zhou 等提出一种物理信息驱动的时空混合神经网络(PI-STHNN), 通过将发动机热循环物理模型与灰色关联度分析相结合来构建传感器关联图, 并采用并行时空提取与注意力融合机制, 在 C-MAPSS 和 N-CMAPSS 数据集上实现了优于现有方法的 RUL 预测精度[35]。第二类是数据驱动构建图结构, 通过相似度、相关性或邻域算法从多传感器数据中自动确定边。Huang 等提出一种时空注意力图神经网络(STAGNN), 采用数据驱动的方式基于传

传感器协方差关系自适应构建图结构, 结合 GNN 与 TCN 级联架构分别提取空间特征与时间序列特征, 并引入多头时空注意力机制实现特征的自适应加权融合, 同时在数据预处理阶段提出基于工况聚类的归一化策略[36]。第三类是可学习动态图, 由神经网络根据当前状态实时推断邻接权重, 表征航空发动机从健康到失效全过程中的动态演化特征。丁家宇等提出一种多尺度动态图神经微分方程(MDGDGE)模型, 通过多尺度自相关分解与自适应动态图结构学习联合捕获航空发动机传感器信号的多尺度时空依赖关系, 并将离散图卷积与时序卷积统一于连续 ODE 框架以缓解过平滑问题[37]。Hua 等提出的动态特征感知图卷积网络 DFAGCN, 利用注意力和相似度机制动态识别不同时间点的传感器依赖关系及最优传感器集合, 并结合 GRU 和 GCN 学习时空退化特征[38]。Wen 等进一步指出, 不同类型传感器之间具有显著异质性, 采用时序异构 GNN 通过在每个时间步构建传感器异构图并结合 FiLM 自适应机制刻画传感器类型的多样性, 可以同时描述传感器类型差异、时间变化和节点间关系[39]。因此, GNN 的发展方向正在由固定相关矩阵逐渐转向“动态、异构、具有物理先验约束”的图结构。

总体而言, CNN/RNN 解决了从原始多传感器数据自动提取局部空间特征和时间退化规律的问题; Transformer 进一步提升了长程依赖及全局特征交互能力; GNN 则开始将部件拓扑、传感器关联和故障传播纳入统一表示。三者并非简单的替代关系, 而是在数据结构假设、建模侧重点和工程部署条件上各有适用边界。对于实际民航飞机预测性维修, 更有前景的架构可能是 CNN/TCN 负责局部信号编码、Transformer 负责跨航段长期退化建模、GNN 负责系统拓扑和级联故障传播, 并进一步与物理模型、数字孪生和维修知识结合, 形成具有物理约束、动态拓扑和不确定性输出的混合预测框架。图 1 呈现了三类算法在数据表征空间与建模能力上的演进关系。




Figure 1. Evolution roadmap for data-driven RUL prediction algorithms

图 1. 数据驱动 RUL 预测算法技术演进路线图

3.4. 算法比较与选型建议

为进一步明确三类方法在民航关键部件 RUL 预测中的适用性，本文从数据需求、计算复杂度、可解释性、噪声鲁棒性以及长短程依赖建模能力等维度进行了归纳总结，如表 2 所示。

Table 2. Comparison of CNN/LSTM, Transformer and GNN for RUL prediction of civil aircraft
表 2. CNN/LSTM、Transformer 与 GNN 在民航飞机 RUL 预测中的比较

比较维度	CNN/LSTM 类方法	Transformer 类方法	GNN 类方法
数据需求	对中等规模时序数据具有较好的适应性，可取得较稳定结果，但对退化标签质量较为敏感	通常依赖较大规模、多工况、长时间序列数据，对训练数据覆盖性要求较高	通常需要系统拓扑、部件连接关系或可学习图结构等附加信息，数据组织要求较高
计算复杂度	卷积部分计算效率较高，但 LSTM 存在递归串行计算问题，整体复杂度处于中等水平	自注意力机制在长序列条件下计算与存储开销较大，但并行计算能力较强	复杂度与节点规模、边数量及图更新方式密切相关，静态图模型复杂度适中，动态图和异构图模型复杂度较高
可解释性	通过卷积响应、特征可视化和注意力权重分析局部退化模式，对传感器或部件间物理关联关系解释能力有限	借助注意力权重识别关键时间步和关键传感器，解释结果更多体现相关性而非严格因果性	当图结构由物理先验或系统连接关系支撑时，具有较好的结构可解释性，可用于分析耦合关系和故障传播路径
对噪声的鲁棒性	对局部扰动和短时噪声具有一定鲁棒性，但递归结构易受到异常点累积影响	对全局依赖关系较敏感，若缺少有效正则化和预处理，可能放大噪声干扰	当图结构构建合理时，可借助邻域聚合削弱局部噪声；但若连边错误，则可能导致噪声传播
短程依赖建模能力	优势明显，适合提取局部波动、短时异常及阶段性退化特征	能够建模短程依赖，但对局部纹理和邻近模式的直接提取能力通常不如卷积结构	取决于图模型与时序模块的耦合方式，其优势主要体现在结构关联建模而非局部短时模式提取
长程依赖建模能力	LSTM 较 RNN 有所提升，但在超长序列建模中仍受梯度传播和串行计算限制	优势突出，适合建模跨航段、跨工况和长周期退化过程中的全局依赖关系	若结合时空图建模或时序单元，可较好刻画长期耦合演化，但训练与优化难度较高
拓扑关系表达能力	将多传感器视为并列输入通道，缺乏对系统结构关系的显式表达	通过注意力机制学习隐式关联，但难以直接对应真实物理拓扑	具有显式拓扑建模优势，适合描述部件连接关系、传感器耦合及故障传播机制
对缺失数据与不规则采样的适应性	一般依赖插值、重采样和滑动窗口等预处理方法	结合掩码机制与位置编码进行处理，但效果受模型设计和数据质量影响较大	若与动态图学习、时空插补或异构建模结合，可获得较好适应性，但实现复杂度较高
工程部署可行性	模型结构成熟，实现难度较低，较适合边缘部署与在线应用	需重点考虑模型压缩、参数剪枝和推理延迟，部署门槛相对较高	图构建、结构更新和推理流程较复杂，系统集成与工程部署难度相对较大
典型适用场景	单部件、局部退化明显、数据规模中等的 RUL 预测任务	长序列、多工况、全局退化模式复杂的 RUL 预测任务	多部件耦合、系统级健康管理及级联故障分析任务

4. 混合模型与数字孪生预测方法

在民航飞机预测性维修中，单纯依靠数据搭建的模型，虽然可以很好地拟合各类非线性数据变化规律，但这类模型缺少对应的物理原理支撑，可解释性较差，同时模型训练需要依托大量标注数据；传统的物理模型，比如裂纹扩展计算模型、热力学模型、状态空间计算模型等，虽然有着清晰的运行机理，

却无法适配航空设备复杂多变的实际运行场景[40]。因此,将物理知识与数据训练学习进行融合已成为航空预测性维修的重要发展方向。

4.1. 物理信息神经网络的应用框架

物理信息神经网络(Physics-Informed Neural Network, PINN)是将设备物理退化规律作为学习过程的先验约束,将其嵌入数据学习过程,指导模型收敛,实现了物理机理与数据的优势互补[41]。例如,在飞机结构疲劳预测中,可将 Paris 型裂纹扩展规律、损伤单调累积约束等写入网络训练目标,使预测裂纹长度不仅逼近实测数据,同时满足合理的损伤演化趋势;类似思想已被用于疲劳裂纹实时预测和物理信息辅助的数据生成[42]。对于航空发动机,可将质量守恒、能量守恒、部件特性图以及温压转速之间的热力学关系用于约束网络输出,从而减少纯数据模型产生“数值正确但物理不可行”结果的风险[43]。

从预测性维修角度看,将物理知识与数据驱动相融合的混合模型可归纳为三种融合方式。第一是数据层融合,即利用物理模型生成受控的合成退化轨迹以解决小样本或未见工况下的训练难题。Xiong 等提出受控物理信息生成对抗网络(CPI-GAN),通过在 GAN 生成器中引入五个基本物理约束和基于代理模型健康指标的物理信息损失函数,生成与退化物理规律一致的合成退化轨迹,有效缓解了实际航空发动机故障样本稀缺的问题[43]。李嘉然采用 Simulink/Simscape 多域机理模型与 LSTM 残差补偿相结合的混合驱动孪生建模,结合遗忘因子递推最小二乘自适应更新策略,显著降低了纯数据模型对实测样本的依赖[44]。第二是模型层融合,将神经网络与状态空间模型、退化方程或系统仿真模型串联、并联或进行残差补偿。Li 等构建面向动态工况的物理引导神经网络,将航空发动机控制系统的物理原理嵌入神经网络,借助物理约束的正则化方式,缓解纯数据模型过度依赖训练样本的问题,结果表明该方法在工况切换与噪声环境中诊断准确率较高,能够降低故障漏判、误判的出现概率[45]。He 等将物理方程引入图卷积网络的损失函数中,通过建立预防性维护在经济性和安全性之间的平衡约束,对延迟预测施加更高的惩罚,让模型可以在设备动态运行、多类故障并发的场景下,完成高精度、高安全性的剩余使用寿命预测工作[46];于海威则基于物理和数据混合驱动的框架,利用轴承动力学方程来约束 WGAN 进行数据增强,再配合跨域迁移学习与多尺度注意力特征融合的协同设计,在航空主轴轴承样本量较少的条件下实现了剩余寿命的高精度预测[47]。第三是损失层融合,直接在损失函数中引入物理方程或设备性能退化的约束条件。Wang 等提出一种贝叶斯 Mamba 物理信息神经网络(BMPINN),该模型融合了 Mamba 长序列数据处理能力、自注意力特征交互技术和偏微分方程物理约束条件,同时加入贝叶斯-Dropout 混合不确定性量化策略,在航空发动机剩余寿命预测中实现了较高的预测精度以及可靠的不确定性区间估计[48]。Fu 等提出一种混合预测框架,通过物理模型与 HTBNN 的动态置信度加权融合、残差学习与物理正则化约束的协同设计,在航空系统剩余寿命预测中兼顾了高精度、物理可解释性和实时部署能力[49]。

总体而言,物理模型依赖系统机理但建模成本高、难以适应复杂工况;数据驱动模型拟合能力强却高度依赖数据且容易违背物理规律。两者的互补性自然引出了混合模型的研究范式。

4.2. 面向航空部件的数字孪生系统架构

从软件工程而非概念展示的角度看,面向预测性维修的数字孪生系统应被理解为一个持续运行的闭环:机载端数据采集、天地数据链路传输、地面端模型自适应更新、健康状态评估与寿命预测、维修策略反馈[50]。这里的数字孪生不应等同于三维模型或状态可视化,其核心至少包括物理/机理模型、实时运行数据、状态与参数更新机制以及健康预测服务。飞机结构数字孪生研究已将载荷和损伤数据获取、多尺度力学、高效裂纹仿真、模型降阶以及考虑不确定性的 RUL 评估列为关键技术[51];航空发动机 PHM 研究同样指出,多物理场建模、实时数据交互和模型持续修正是数字孪生真正用于健康管理

的主要瓶颈[52]。

在具体航空部件的应用中，数字孪生技术体现出了较为明显的协同作用。在飞机结构健康监测与管理的相关研究中，黄蕾等提出了“飞参-载荷-寿命”三级数字孪生模型体系，通过 XGBoost 增量学习的方法，将飞行参数高精度地映射为载荷数据，再通过非侵入式降阶技术对应力场加以重构，最终基于 DFR 法完成了航空结构疲劳寿命的预测分析[53]。在航空发动机的相关研究与应用领域，Ren 等提出一种由数字孪生驱动的机队协同运维方案，构建了单机级与系统级这两个层级的孪生模型，其中单机级模型主要将材料的物理属性同性能模型加以融合，以此来刻画每一台发动机的个体健康状态，系统级模型则是在此基础上进一步完成整个机队层面的协同决策工作[54]。在飞机环境控制系统以及各类机电部件的研究领域中，数字孪生同样可以结合热力学基础模型与设备传感器采集的数据，完成设备实时健康状态判断以及剩余使用寿命的预估工作。但相较航空发动机和结构数字孪生，ECS 领域将多物理机理模型、实时状态更新和维修决策真正整合成完整孪生闭环的研究仍相对有限。因而，将已有 ECS 数据驱动 PHM 模型升级为可自更新的混合数字孪生，是值得重点关注的研究方向。

4.3. 混合模型的优势与应用局限

综合来看，混合模型相较于单一方法的核心优势在于：物理机理为数据驱动模型提供先验约束与可解释性，数据驱动方法则为物理模型提供参数自适应与误差补偿能力，数字孪生进一步加入持续数据同化，使同一预测模型能够随具体飞机、具体部件的服役历史持续演化。但混合模型并非天然优于数据驱动模型，其效果取决于物理模型准确性、数据质量以及融合方式。与纯数据方法相比，混合模型需要额外的机理分析、参数辨识和多源耦合设计，构建成本高、开发周期长、跨学科门槛高，且在线计算复杂度可能较高。不同预测方法在在线计算复杂度、模型精度及工程实现难度上存在显著差异，数据驱动、混合模型与数字孪生方法对比如表 3 所示。

Table 3. Comparison of data-driven, hybrid, and digital twin approaches
表 3. 数据驱动、混合模型与数字孪生方法对比

对比维度	纯数据驱动方法	混合/PINN 方法	数字孪生预测方法
数据需求	高	中等，可由物理知识补偿	中等，但要求持续在线数据
机理依赖	低	中/高	高，尤其是高保真孪生
可解释性	较弱	较强	较强，可追溯状态演化
跨工况泛化	易受数据分布漂移影响	物理约束有效时较好	可通过在线更新进一步改善
不确定性处理	通常需额外设计	可结合 KF/PF/贝叶斯模型	应同时考虑模型、参数和数据不确定性
在线计算	较容易	视复杂度而定	较高

对于民航飞机预测性维修而言，民航应用不仅要求平均预测误差低，还要求模型更新过程可验证、结果具有置信度并能够追溯到数据和模型版本。未来关键并不只是继续堆叠更复杂的神经网络或更精细的仿真模型，而是形成可工程落地的统一方法论：何时采用数据层融合，何时采用模型层耦合，何时采用损失层约束；哪些部件适合数字孪生强建模，哪些部件更适合轻量化健康映射。这一问题尚未形成统一答案，也正是当前综述研究需要进一步澄清的核心争议之一。

5. 现有挑战与工程化落地展望

尽管民航预测性维修领域在数据驱动算法与混合建模方向已取得显著进展，但从实验室算法走向实

际机队应用，核心难点不再是单纯提升设备剩余使用寿命的预测准确程度，而是如何在数据获取难度、多场景适配能力、预测结果可靠性和实际工程落地可行性之间找到合适的平衡。尤其是现有研究仍大量依赖 C-MAPSS、N-CMAPSS 等标准数据集开展试验；这类数据集的数据完整度和设备退化变化规律，和真实飞行数据、机载健康监测数据存在一定区别，真实数据中普遍存在数据缺失、数据干扰、人为维修干预以及不同机队的差异化问题。因此，只有将预测精准度的提升效果，转化为可靠、可核验且能够辅助维修工作规划的实际能力，预测性维修技术才能够真正落地应用[55]-[58]。

5.1. 现有核心挑战

(1) 数据质量与标注稀缺，以及跨工况泛化问题

民航领域的真实运行数据因为商业保密方面的限制，难以在不同主体之间实现共享，而现有的公开基准数据集又基本都是以仿真数据为主，这类数据和真实飞行数据相比，在干扰数据分布、数据缺失规律、运行场景丰富度等方面，都存在较大的差异。与此同时，民航设备的故障数据样本数量较少，和海量的正常运行数据形成了严重的数量失衡问题，纯数据驱动模型在这种条件下放到真实场景中就容易出现过拟合的情况，而且多源异构数据(包括高频时序数据、维修文本、环境参数等)在时空对齐和语义融合方面的技术也还不够成熟。除此之外，飞机型号不同、发动机个体不同、航线环境不同以及飞行工况的变化，都会让训练域和实际部署域之间产生比较明显的分布偏移，从 C-MAPSS 数据集之间的迁移进一步扩展到跨机队、跨航司的真实运行数据，仍然是一个关键难题。

(2) 模型可解释性与适航合规性是工程落地的难题

当前主流深度学习模型的黑箱特性，难以满足民航适航认证对决策可追溯、结果可验证的要求，而现有 DO-178C/DO-254 等民航安全规范尚未形成一套针对 AI 预测模型的明确认证框架，模型输出的不确定性量化不够充分，物理一致性方面的约束也存在不足，这就导致维修人员很难去信任算法给出的维修建议，同时也没办法通过适航审查。近年来，学者将 SHAP 分析方法和可解释健康检测模型，应用在航空发动机剩余使用寿命的预测研究中[57]-[59]；但在实际工程应用中，模型的可解释性不能只停留在事后的数据特征分析层面，需要搭建一套完整的验证体系，覆盖原始数据采集、数据清理、模型版本更新到最终预测结果的全流程。当预测功能进入机载安全相关系统时，还需考虑与 DO-178C 等软件保证框架的衔接；现有航空 AI 研究指出，由数据决定模型行为、训练过程的不确定性以及传统白盒验证方法的局限，使机器学习模型难以直接套用传统软件审定逻辑[60]。形式化验证研究进一步表明，将安全边界显式转化为可验证约束，是提高航空机器学习系统可信度的重要方向[61]。

(3) 模型复杂度与维修业务需求之间存在落差

Transformer、深度图神经网络、数字孪生等新型模型，一直在不断扩大自身的参数体量；但飞机机载的运算设备，会受到运算能力、存储空间、能耗标准和实时运行速度的多重限制。不同飞机机型、飞行航线、运行环境带来的工况差异，会让模型的运行效果出现明显下滑；目前大部分智能算法，都只针对单一仿真场景做优化调试，很难适配不同机队、不同运行工况，场景迁移适配的能力较差。从实际应用角度来看，大多数学术研究的最终评判标准，只聚焦于均方根误差、综合评分等数据指标；但航空公司在实际运营中，更需要解决何时开展维修作业、是否提前更换设备配件、如何合理调配备件资源、如何降低飞机停场风险等实际问题。因此，智能预测模型和实际维修工作规划之间，还存在明显的衔接缺口；单纯的数值预测结果，无法直接作为维修工作开展的决策依据。

5.2. 民航预测性维修工程化落地中的关键科学问题

面对上述挑战，未来民航预测性维修(PdM)相关研究不应只停留在一般性的工程化建议层面，而是需

要进一步凝练出若干开放性的科学问题，这样才有助于推动各类方法从算法验证阶段真正走向工程应用。基于此，本文认为以下四个问题可以被视为后续研究应当重点关注的方向。

问题一：如何构建面向真实运行场景的多源异构数据统一表征与可信标签生成机制？

民航预测性维修涉及多源异构数据，且普遍存在缺失、噪声、时间错位和维修干预等问题。如何在如此条件下把多源数据有效地对齐、融合，并形成统一的表达形式，同时结合维修文本记录、故障代码和拆换记录生成可用于诊断与 RUL 预测的高可信标签，是决定模型训练质量和应用上限的基础问题。

问题二：如何构建既能跨工况泛化又符合物理规律的混合预测模型？

在民航机队的实际运行中，飞机机型、发动机设备个体、航线运行环境、飞行作业场景都存在明显差异，这就使得训练时用的数据和实际部署时的数据分布出现特征偏差。因此，后续研究需要探索物理退化规律、热力运行限制、设备运行边界等基础物理知识与深度学习模型的融合方式，搭建出可以体现不同设备的退化特征、适应不同工况的迁移，同时符合物理运行逻辑的复合型预测模型框架。

问题三：如何建立符合民航适航标准的模型可信性评估与验证方法？

民航工程应用对模型的要求不只是预测精度要高，还要求模型结果可被解释、行为可被追溯、边界可被验证。当前深度学习模型在不确定性量化、异常工况鲁棒性、物理一致性约束和安全边界表达等方面还有较多欠缺，难以直接满足适航审查的需求。所以，将结果解读分析、不确定问题评估、标准化核验、人工二次审核等方式整合为一套完整的模型验证体系，是保障预测模型能够安全、可靠应用在民航场景的核心要点。

问题四：如何将健康状态评估与 RUL 预测结果转化为可执行的维修决策方案？

当前多数研究仍以 RMSE、Score 等算法指标作为主要评价标准，但航空公司更关注预测结果能否服务于维修窗口安排、备件保障、停场控制和运行风险降低。因此，需要进一步研究如何将具有不确定性的预测结果转化为可解读、可优化的维修参考指标，同时结合维修物资储备、航班运行计划、航空安全规范开展综合建模，实现维修方案的持续优化和闭环落地。

总体来看，上述问题是民航预测性维修技术从算法层面可行，转变为工程落地可用、适航审核合规、实际业务可落地的关键研究方向。后续相关研究可以从数据规范化处理、复合型模型搭建、模型可靠性验证、维修决策优化这几个维度同步推进，以此推动预测性维修技术在民航行业的实际落地。

6. 结束语

综合来看，民航飞机的预测性维修技术，不再只依靠单一的数据模型完成设备剩余使用寿命预估工作，而是能够结合物理机理、数字孪生与智能决策方式，形成一套完整的设备健康综合管理体系。CNN、LSTM、Transformer、GNN 等常见算法模型，有效优化了多源时序数据的故障特征提取效果，也提升了复杂数据关联关系的建模水平，物理信息神经网络和数字孪生技术的应用，也让模型的运行原理贴合度、内容可解释性以及线上更新能力得到了进一步提升。但在实际的民航运行场景中，场景内可用样本数据少、数据分布不均衡、不同运行工况下数据出现偏差、模型运行逻辑不透明、设备运算能力有限、模型适航认证可信度不足等诸多问题，仍然是相关成果从实验室走向工程应用过程中所面临的关键瓶颈。

后续的相关研究工作，需要减少对单一预测准确率、复杂网络结构的过度追求，研究重点可以放在多类数据整理规范、物理与数据融合应用、不确定问题量化分析、模型简化优化、可信度核验等多个方向，同时将设备剩余寿命预测工作，和维修时间规划、零部件物资保障、机队资源调配优化等工作相互结合。只有完成从精准数据预测到可靠智能决策的转型，预测性维修技术才能打造出可以落地应用、可以核验效果、可以持续优化升级的工程运行体系，进而为民航飞行运行安全、设备维修效率提升、飞机全使用周期的成本管控优化，提供切实有效的技术支撑。

参考文献

- [1] Lena Software (2026) Aviation Maintenance 101: What It Is and What Most Organizations Overlook. <https://www.lenasoftware.com/en/blog/aviation-maintenance-101-hat-it-is-and-hat-most-organizations-overlook>
- [2] 顾新, 刘松岑. 以预测性为中心的维修理论和维修方式发展研究[J]. 航空工程进展, 2021, 12(5): 7-14.
- [3] 孙见忠, 王卓健, 闫洪胜, 等. 航空预测性维修研究进展[J]. 航空学报, 2025, 46(7): 6-29.
- [4] Leal, A.S., Santos, L.C.D.C. and Berton, L. (2026) A Review of Aircraft Predictive Maintenance Techniques via Machine Learning. *IEEE Aerospace and Electronic Systems Magazine*, **41**, 4-24. <https://doi.org/10.1109/maes.2026.3653904>
- [5] Li, X., Ding, Q. and Sun, J. (2018) Remaining Useful Life Estimation in Prognostics Using Deep Convolution Neural Networks. *Reliability Engineering & System Safety*, **172**, 1-11. <https://doi.org/10.1016/j.ress.2017.11.021>
- [6] Li, Q. and Yang, Y. (2022) Transformer Model for Remaining Useful Life Prediction of Aeroengine. *Journal of Physics: Conference Series*, **2171**, Article 012072. <https://doi.org/10.1088/1742-6596/2171/1/012072>
- [7] Marevac, E., Kadišić, E., Živić, N., Hamzić, D. and Hadžajlić, N. (2025) Data-Driven Predictive Analytics for Dynamic Aviation Systems: Optimising Fleet Maintenance and Flight Operations through Machine Learning. *Future Internet*, **17**, Article 508. <https://doi.org/10.3390/fi17110508>
- [8] 王玉童. 物理-数据驱动的滚动轴承疲劳剥落剩余使用寿命预测[D]: [硕士学位论文]. 沈阳: 沈阳建筑大学, 2024.
- [9] Ezhilarasu, C.M., Skaf, Z. and Jennions, I.K. (2019) The Application of Reasoning to Aerospace Integrated Vehicle Health Management (IVHM): Challenges and Opportunities. *Progress in Aerospace Sciences*, **105**, 60-73. <https://doi.org/10.1016/j.paerosci.2019.01.001>
- [10] Wang, L., Wu, C. and Sun, R. (2014) An Analysis of Flight Quick Access Recorder (QAR) Data and Its Applications in Preventing Landing Incidents. *Reliability Engineering & System Safety*, **127**, 86-96. <https://doi.org/10.1016/j.ress.2014.03.013>
- [11] Benedettini, O., Baines, T.S., Lightfoot, H.W. and Greenough, R.M. (2009) State-of-the-Art in Integrated Vehicle Health Management. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, **223**, 157-170. <https://doi.org/10.1243/09544100jaero446>
- [12] Scott, M.J., Kirkpatrick, O., Verhagen, W.J.C., et al. (2024) Application of Natural Language Processing for Aircraft Defect Tracking in Maintenance Operations. *Proceedings of the 34th Congress of the International Council of the Aeronautical Sciences*, Florence, 9-13 September 2024, 83.
- [13] Arias Chao, M., Kulkarni, C., Goebel, K. and Fink, O. (2021) Aircraft Engine Run-To-Failure Dataset under Real Flight Conditions for Prognostics and Diagnostics. *Data*, **6**, Article 5. <https://doi.org/10.3390/data6010005>
- [14] NASA Open Data Portal (2026) C-MAPSS Aircraft Engine Simulator Data. <https://data.nasa.gov/dataset/c-mapss-aircraft-engine-simulator-data>
- [15] Chatterjee, S. and Keprate, A. (2021) Exploratory Data Analysis of the N-CMAPSS Dataset for Prognostics. 2021 *IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, Singapore, 13-16 December 2021, 1114-1121. <https://doi.org/10.1109/ieem50564.2021.9673064>
- [16] 李鉴航. 基于深度学习的航空发动机风险评估方法研究[D]: [硕士学位论文]. 天津: 中国民航大学, 2024.
- [17] 陈自强. 基于 LSTM 网络的设备健康状况评估与剩余寿命预测方法的研究[D]: [硕士学位论文]. 合肥: 中国科学技术大学, 2019.
- [18] 林荣祥. 基于融合数据驱动的涡扇发动机剩余使用寿命预测方法研究[D]: [硕士学位论文]. 昆明: 昆明理工大学, 2025.
- [19] Li, J., Jia, Y., Niu, M., Zhu, W. and Meng, F. (2023) Remaining Useful Life Prediction of Turbofan Engines Using CNN-LSTM-SAM Approach. *IEEE Sensors Journal*, **23**, 10241-10251. <https://doi.org/10.1109/jsen.2023.3261874>
- [20] 史国华. 数据驱动的航空发动机 RUL 预测模型研究[D]: [硕士学位论文]. 大连: 大连理工大学, 2021.
- [21] Zhao, C., Huang, X., Li, Y. and Yousaf Iqbal, M. (2020) A Double-Channel Hybrid Deep Neural Network Based on CNN and BiLSTM for Remaining Useful Life Prediction. *Sensors*, **20**, Article 7109. <https://doi.org/10.3390/s20247109>
- [22] Keshun, Y., Guangqi, Q. and Yingkui, G. (2024) A 3-D Attention-Enhanced Hybrid Neural Network for Turbofan Engine Remaining Life Prediction Using CNN and BiLSTM Models. *IEEE Sensors Journal*, **24**, 21893-21905. <https://doi.org/10.1109/jsen.2023.3296670>
- [23] 李杰, 贾渊杰, 张志新, 等. 基于融合神经网络的航空发动机剩余寿命预测[J]. 推进技术, 2021, 42(8): 1725-1734.
- [24] Chen, W., Liu, C., Chen, Q. and Wu, P. (2023) Multi-Scale Memory-Enhanced Method for Predicting the Remaining Useful Life of Aircraft Engines. *Neural Computing and Applications*, **35**, 2225-2241. <https://doi.org/10.1007/s00521-022-07378-z>

- [25] Ren, G., Wang, Y., Shi, Z., Zhang, G., Jin, F. and Wang, J. (2022) Aero-Engine Remaining Useful Life Estimation Based on CAE-TCN Neural Networks. *Applied Sciences*, **13**, 17. <https://doi.org/10.3390/app13010017>
- [26] Li, H., Wang, Z. and Li, Z. (2022) An Enhanced CNN-LSTM Remaining Useful Life Prediction Model for Aircraft Engine with Attention Mechanism. *PeerJ Computer Science*, **8**, e1084. <https://doi.org/10.7717/peerj-cs.1084>
- [27] Deng, S. and Zhou, J. (2024) Prediction of Remaining Useful Life of Aero-Engines Based on CNN-LSTM-Attention. *International Journal of Computational Intelligence Systems*, **17**, Article No. 232. <https://doi.org/10.1007/s44196-024-00639-w>
- [28] 马依琳, 陶慧玲, 董启文等. 基于 Transformer 的多特征融合的航空发动机剩余使用寿命预测[J]. 华东师范大学学报 (自然科学版), 2022(5): 219-232.
- [29] Hu, Q., Zhao, Y. and Ren, L. (2023) Novel Transformer-Based Fusion Models for Aero-Engine Remaining Useful Life Estimation. *IEEE Access*, **11**, 52668-52685. <https://doi.org/10.1109/access.2023.3277730>
- [30] Wang, X., Li, Y., Xu, Y., Liu, X., Zheng, T. and Zheng, B. (2023) Remaining Useful Life Prediction for Aero-Engines Using a Time-Enhanced Multi-Head Self-Attention Model. *Aerospace*, **10**, Article 80. <https://doi.org/10.3390/aerospace10010080>
- [31] Zhao, K., Jia, Z., Jia, F. and Shao, H. (2023) Multi-Scale Integrated Deep Self-Attention Network for Predicting Remaining Useful Life of Aero-Engine. *Engineering Applications of Artificial Intelligence*, **120**, Article 105860. <https://doi.org/10.1016/j.engappai.2023.105860>
- [32] Zhang, D., Li, B., Wang, F., Zhao, Z., Gao, J. and Li, X. (2026) Cross-Attention Multi-Scale State Space Model for Remaining Useful Life Prediction of Aircraft Engines. *Advanced Engineering Informatics*, **69**, Article 103817. <https://doi.org/10.1016/j.aei.2025.103817>
- [33] Zhang, X., Sun, J., Wang, J., Jin, Y., Wang, L. and Liu, Z. (2023) Paoltransformer: Pruning-Adaptive Optimal Lightweight Transformer Model for Aero-Engine Remaining Useful Life Prediction. *Reliability Engineering & System Safety*, **240**, Article 109605. <https://doi.org/10.1016/j.res.2023.109605>
- [34] Ren, L., Wang, H., Mo, T. and Yang, L.T. (2025) A Lightweight Group Transformer-Based Time Series Reduction Network for Edge Intelligence and Its Application in Industrial RUL Prediction. *IEEE Transactions on Neural Networks and Learning Systems*, **36**, 3720-3729. <https://doi.org/10.1109/tnnls.2023.3347227>
- [35] Zhou, M., Li, Y., Cao, Y., Ma, X. and Xu, Z. (2025) Physics-Informed Spatio-Temporal Hybrid Neural Networks for Predicting Remaining Useful Life in Aircraft Engine. *Reliability Engineering & System Safety*, **256**, Article 110685. <https://doi.org/10.1016/j.res.2024.110685>
- [36] Huang, Z., He, Y. and Sick, B. (2023) Spatio-Temporal Attention Graph Neural Network for Remaining Useful Life Prediction. 2023 *International Conference on Computational Science and Computational Intelligence (CSCI)*, Las Vegas, 13-15 December 2023, 99-105. <https://doi.org/10.1109/csci62032.2023.00022>
- [37] 丁家宇, 汪永超, 李锋, 等. 基于多尺度动态图神经微分方程的航空发动机剩余寿命预测[J]. 仪器仪表学报, 2026, 47(5): 201-214.
- [38] Hua, J., Zhang, Y., Zhang, D., He, J., Wang, J. and Fang, X. (2024) Dynamic Feature-Aware Graph Convolutional Network with Multisensor for Remaining Useful Life Prediction of Turbofan Engines. *IEEE Sensors Journal*, **24**, 29414-29428. <https://doi.org/10.1109/jsen.2024.3435071>
- [39] Wen, Z., Fang, Y., Wei, P., Liu, F., Chen, Z. and Wu, M. (2025) Temporal and Heterogeneous Graph Neural Network for Remaining Useful Life Prediction. *IEEE Transactions on Neural Networks and Learning Systems*, **36**, 19748-19761. <https://doi.org/10.1109/tnnls.2025.3592788>
- [40] Wang, F., Zhai, Z., Zhao, Z., Di, Y. and Chen, X. (2024) Physics-Informed Neural Network for Lithium-Ion Battery Degradation Stable Modeling and Prognosis. *Nature Communications*, **15**, Article No. 4332. <https://doi.org/10.1038/s41467-024-48779-z>
- [41] Karniadakis, G.E., Kevrekidis, I.G., Lu, L., Perdikaris, P., Wang, S. and Yang, L. (2021) Physics-Informed Machine Learning. *Nature Reviews Physics*, **3**, 422-440. <https://doi.org/10.1038/s42254-021-00314-5>
- [42] Hwang, H., Song, J., Kim, H.S. and Chattopadhyay, A. (2023) Real-Time Fatigue Crack Prediction Using Self-Sensing Buckypaper and Gated Recurrent Unit. *Journal of Mechanical Science and Technology*, **37**, 1401-1409. <https://doi.org/10.1007/s12206-023-0226-y>
- [43] Xiong, J., Fink, O., Zhou, J. and Ma, Y. (2023) Controlled Physics-Informed Data Generation for Deep Learning-Based Remaining Useful Life Prediction under Unseen Operation Conditions. *Mechanical Systems and Signal Processing*, **197**, Article 110359. <https://doi.org/10.1016/j.ymssp.2023.110359>
- [44] 李嘉然. 基于混合驱动数字孪生模型的进给系统剩余寿命预测[D]: [硕士学位论文]. 兰州: 兰州理工大学, 2023.
- [45] Li, H., Gou, L., Li, H. and Liu, Z. (2023) Physics-Guided Neural Network Model for Aeroengine Control System Sensor Fault Diagnosis under Dynamic Conditions. *Aerospace*, **10**, Article 644. <https://doi.org/10.3390/aerospace10070644>

-
- [46] He, Y., Su, H., Zio, E., Peng, S., Fan, L., Yang, Z., *et al.* (2023) A Systematic Method of Remaining Useful Life Estimation Based on Physics-Informed Graph Neural Networks with Multisensor Data. *Reliability Engineering & System Safety*, **237**, Article 109333. <https://doi.org/10.1016/j.ress.2023.109333>
 - [47] 于海威. 基于混合模型驱动的航空轴承剩余寿命预测方法研究[D]: [硕士学位论文]. 哈尔滨: 哈尔滨工业大学, 2025.
 - [48] Wang, S., Zhu, J., Hu, Z., Huang, C. and Wang, H. (2027) Bayesian Mamba Physics-Informed Neural Network for Aero-Engine Remaining Useful Life Prediction with Uncertainty Estimation. *Reliability Engineering & System Safety*, **277**, Article 113091. <https://doi.org/10.1016/j.ress.2026.113091>
 - [49] Fu, S., Avdelidis, N.P. and Plastropoulos, A. (2025) Novel Hybrid Prognostics of Aircraft Systems. *Electronics*, **14**, Article 2193. <https://doi.org/10.3390/electronics14112193>
 - [50] 李思雨, 程中华, 岳光, 等. 基于数字孪生的航空发动机故障预测与健康管理技术研究综述[J]. 兵工自动化, 2025, 44(9): 6-13.
 - [51] 董雷霆, 周轩, 赵福斌, 等. 飞机结构数字孪生关键建模仿真技术[J]. 航空学报, 2021, 42(3): 113-141.
 - [52] Wu, Z. and Li, J. (2021) A Framework of Dynamic Data Driven Digital Twin for Complex Engineering Products: The Example of Aircraft Engine Health Management. *Procedia Manufacturing*, **55**, 139-146. <https://doi.org/10.1016/j.promfg.2021.10.020>
 - [53] 黄蕾, 郭聪, 张小波, 等. 基于飞参-载荷-寿命数字孪生模型的飞机结构健康管理方法[J]. 航空学报, 2025, 46(21): 143-161.
 - [54] Ren, J., Cheng, Y., Zhang, Y. and Tao, F. (2024) A Digital Twin-Enhanced Collaborative Maintenance Paradigm for Aero-Engine Fleet. *Frontiers of Engineering Management*, **11**, 356-361. <https://doi.org/10.1007/s42524-024-0299-z>
 - [55] de Pater, I. and Mitici, M. (2023) Developing Health Indicators and RUL Prognostics for Systems with Few Failure Instances and Varying Operating Conditions Using a LSTM Autoencoder. *Engineering Applications of Artificial Intelligence*, **117**, Article 105582. <https://doi.org/10.1016/j.engappai.2022.105582>
 - [56] Ragab, M., Chen, Z., Wu, M., Foo, C.S., Kwok, C.K., Yan, R., *et al.* (2021) Contrastive Adversarial Domain Adaptation for Machine Remaining Useful Life Prediction. *IEEE Transactions on Industrial Informatics*, **17**, 5239-5249. <https://doi.org/10.1109/tii.2020.3032690>
 - [57] Mansourvar, Z., Jahangoshai Rezaee, M. and Eshkevari, M. (2025) An Explainable Approach for Prediction of Remaining Useful Life in Turbofan Condition Monitoring. *Neural Computing and Applications*, **37**, 10621-10645. <https://doi.org/10.1007/s00521-024-10605-4>
 - [58] Moradi, M., Komninos, P. and Zarouchas, D. (2024) Constructing Explainable Health Indicators for Aircraft Engines by Developing an Interpretable Neural Network with Discretized Weights. *Applied Intelligence*, **55**, Article No. 143. <https://doi.org/10.1007/s10489-024-05981-2>
 - [59] Yuan, C., Cai, Y. and Zhang, Z. (2026) Application of Shap-Based Explainable Machine Learning in Remaining Useful Life Prediction for Aircraft Engine Systems. *International Journal of Machine Learning and Cybernetics*, **17**, Article No. 417. <https://doi.org/10.1007/s13042-026-03246-7>
 - [60] Luettig, B., Akhiat, Y. and Daw, Z. (2024) ML Meets Aerospace: Challenges of Certifying Airborne AI. *Frontiers in Aerospace Engineering*, **3**, Article ID: 1475139. <https://doi.org/10.3389/fpace.2024.1475139>
 - [61] Razzaghi, P., Memarzadeh, M. and Kalyanam, K. (2025) Formal Verification of a Machine Learning Tool for Runway Configuration Assistance. *Frontiers in Aerospace Engineering*, **4**, Article ID: 1463425. <https://doi.org/10.3389/fpace.2025.1463425>