

文章编号: 1671-6612 (2026) 03-354-10

基于 LSTM-Transformer 融合模型的 铁路客站集中冷源空调系统剩余使用寿命预测

林琮雲 毕海权 周远龙 王宏林

(西南交通大学机械工程学院 成都 610031)

【摘要】 铁路客站集中冷源空调系统受室外气象条件波动、客流量动态变化及长期高负荷运行等因素影响,设备磨损速率远高于一般公共建筑,准确预测其剩余使用寿命(RUL)对制定科学的运维策略至关重要。然而,常规预测模型往往面临超参数选择困难、随运行时间延长预测稳定性下降等问题。为此,利用 AMESim 软件搭建铁路客站空调系统仿真模型,通过模拟系统全周期性能退化过程生成时序数据集;然后,提出了一种融合长短期记忆网络(LSTM)与 Transformer 架构的预测模型,用于空调系统的 RUL 预测。以东南沿海地区某小型铁路客站空调系统为研究对象,将融合模型与单一 LSTM、Transformer 模型进行预测性能对比。结果表明:相较于两种单一模型,融合模型在各类关键评价指标上的表现更优(MAE=49.91、RMSE=58.57、MAPE=0.064%),且随着系统运行时间延长仍能提供更精确的 RUL 预测,揭示了 LSTM-Transformer 模型在预测空调系统 RUL 中的潜力。

【关键词】 空调系统;性能退化;剩余使用寿命;神经网络预测

中图分类号 TU831.3 文献标志码 A

Prediction of Remaining Useful Life for Railway Station Central Chilled-Water Air Conditioning Systems Based on LSTM-Transformer Fusion Model

Lin Congyun Bi Haiquan Zhou Yuanlong Wang Honglin

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu, 610031)

【Abstract】 The central chilled-water air-conditioning systems of railway stations are subject to fluctuations in outdoor meteorological conditions, dynamic changes in passenger flow, and prolonged high-load operation, leading to equipment wear rates far higher than those of typical public buildings. Accurately predicting their remaining useful life (RUL) is therefore crucial for formulating sound operation and maintenance strategies. However, conventional prediction models often face challenges such as difficult hyperparameter selection and declining predictive stability as operating time increases. To address this, this study builds a simulation model of a railway station air-conditioning system in AMESim and generates a time-series dataset by simulating the system's full life-cycle performance degradation. We then propose a prediction model that fuses a Long Short-Term Memory (LSTM) network with a Transformer architecture for RUL prediction of the air-conditioning system. Using a small railway station in China's southeastern coastal region as the case study, we compare the fused model with standalone LSTM and Transformer models. The results show that, relative to the two single models, the fused model performs better across key evaluation metrics (MAE=49.91, RMSE=58.57, MAPE=0.064%) and continues to provide more accurate RUL predictions as system operating time

基金项目: 复杂环境和线路条件下的列车空调系统节能技术研究(2682024CX114)

作者简介: 林琮雲(2001-), 男, 在读研究生, E-mail: lcy200322@my.swjtu.edu.cn

通讯作者: 毕海权(1974-), 男, 博士, 教授, E-mail: bhquan@swjtu.edu.cn

收稿日期: 2025-11-03

increases, demonstrating the potential of the LSTM-Transformer model for predicting the RUL of air-conditioning systems.

【Keywords】 Air conditioning; Performance degradation; Remaining useful life; Neural network prediction

0 引言

铁路客站空调系统承担着候车厅、集散厅等大空间环境保障任务,其运行状态直接关系到旅客热舒适、设备能耗与车站服务品质。与一般公共建筑相比,铁路客站通常具有空间尺度大、围护开口多、客流波动强以及室外热湿扰动显著等特点,空调系统长期处于高负荷、多工况切换的运行状态。一旦关键设备性能衰减或局部故障持续累积,系统不仅会出现供冷能力下降、能效恶化等问题,还可能导致室内环境波动加剧和运维响应滞后^[1]。因此,围绕铁路客站集中冷源空调系统开展寿命预测研究,对于提升系统运行可靠性和支撑预测性维护具有现实意义。

剩余使用寿命 (Remaining Useful Life, RUL) 是指设备或系统从当前时刻起至性能退化到失效阈值前的剩余可运行时间,是预测与健康管理体系 (PHM) 的核心指标之一^[2]。围绕 RUL 预测,现有研究主要可分为模型驱动、数据驱动和混合驱动三类。模型驱动方法通常基于退化机理、随机过程或失效演化方程建立寿命模型,具有物理意义明确、便于解释和与维护阈值对接等优势^[3-5];但其预测效果往往依赖于先验机理认知的完整性以及参数辨识的准确性。数据驱动方法则直接利用历史监测数据学习运行状态与寿命之间的映射关系,在航空发动机、燃料电池等对象中取得了较好的预测效果^[6,7],但在复杂工况下仍面临泛化能力不足和物理一致性约束偏弱的问题。为兼顾机理约束与数据表达能力,混合驱动方法进一步将物理模型、状态估计和智能算法结合,通过残差修正^[8,9]、贝叶斯更新^[10]或多模型融合^[11,12]等方式提高 RUL 预测的稳健性与可信度。

相较于航空发动机、轴承和液压装备等典型 PHM 对象,暖通空调系统相关研究长期更多集中于故障检测诊断、运行优化及节能控制,对长期性能衰减和寿命演化的关注相对不足^[13]。实际上,空调系统是由冷源侧、水系统、风系统及末端环境共同构成的多子系统耦合对象,其退化过程并非单一部件损伤的简单叠加。长期运行过程中,压缩机、风机和水泵等旋转机械会出现效率下降与磨损累

积,蒸发器、冷凝器等换热部件可能发生结垢堵塞,管路及阀件则可能出现泄漏、阻力增大或调节性能劣化^[14]。更重要的是,在闭环控制作用下,系统常通过提高压缩机负荷、增大风水侧输配能力或扩大阀门调节幅度等方式对局部退化进行短期代偿,使早期性能衰减被部分掩蔽^[15],并沿冷量生成、输配、送达和环境响应的能量链路向系统层面传递。由此,HVAC 系统寿命问题本质上是一个受外扰、负荷和控制共同影响的多变量动态演化过程,而非静态单设备退化问题。

对于铁路客站集中冷源空调系统而言,上述问题更为突出。一方面,铁路客站普遍面临高温高湿外扰、客流强波动以及大空间风水输配损失等复杂工况,系统退化具有更强的隐蔽性与场景依赖性;另一方面,工程中通常缺乏可直接用于训练的全寿命故障数据和真实 RUL 标签,导致寿命建模与验证难度较大。现有 HVAC 研究虽为空调系统故障诊断和健康管理提供了方法基础^[16],但针对铁路客站场景的系统级退化表征、寿命标签构造及长时序 RUL 预测研究仍相对不足。

基于此,本文以东南沿海某铁路客站集中冷源空调系统为对象,聚焦复杂工况下的系统级寿命预测问题,开展了以下研究:其一,基于健康基线与多变量残差构造综合退化强度,并形成满足单调约束的代理 RUL 监督信号,以缓解真实全寿命标签缺失带来的建模困难;其二,针对 RUL 序列长期衰减与短周期波动并存的特征,提出 LSTM-Transformer 融合模型,以协同刻画局部动态与长程依赖;其三,依托 AMESim 构建多工况长时序退化数据集,并通过与单一 LSTM 和 Transformer 模型对比验证所提方法的有效性。研究结果可为铁路客站空调系统预测性维护提供方法支撑。

1 车站空调系统退化机理

1.1 空调设备退化路径

随着车站空调系统长期运行,压缩机、风机、水泵、换热器、管路及阀件等关键部件会在高温高湿外扰、负荷波动与频繁调节作用下发生不同形式

的性能衰减^[17,18]。由于各子系统之间存在明显耦合关系,局部退化往往会在控制代偿作用下被短期掩盖,并进一步沿冷量生成、输配与送达链路传递至系统层面,最终表现为供冷能力下降、输配效率恶化及控制精度降低^[19]。基于此,结合相关文献统计以及工程经验,本文将关键退化对象划分为旋转机械、换热器、管道系统与阀门四类,并给出其在不

同负荷与环境条件下的年均退化率经验区间^[20,21]。需要说明的是,表中退化率区间仅作为仿真退化场景构造的经验边界,并不代表某一具体工程对象的固定真实退化速率;本文在相应区间内选取代表性退化率,用于后续 AMESim 平台中的参数注入与对比实验,以保证不同场景之间具有统一的尺度与可比性。具体数值如表 1 所示。

表 1 关键设备性能退化路径及退化率

Table 1 Key equipment performance degradation path and degradation rate

部件分类	部件	年均退化率区间	主导退化原因	系统层面主要表现	设定退化率
旋转机械	压缩机	2.5~3% 常规: 1.5~3% 高负载: 4~6% 高温高湿/腐蚀环境: 6~8%	轴承/转子磨损、对中偏差、润滑劣化	效率下降、功耗上升、振动增强	2.5%
	风机/水泵	常规: 1.5~3% 高负载: 4~6% 高温高湿/腐蚀环境: 6~8%	叶轮磨损、不平衡、积尘/结垢、电机绝缘老化	风/水侧输配效率下降、单位输配能耗上升	2%
	冷凝器/蒸发器	常规: 1.5~3% 高负载: 4~6% 高温高湿/腐蚀环境: 6~8%	积尘、结垢、微生物膜、腐蚀	有效传热能力下降、压降变化、换热侧响应变差	2%
管道系统	风管系统/冷媒管	常规: 3~5% 高负载: 8~12% 高温高湿/腐蚀环境: 10~15%	内壁污染、腐蚀结垢、泄漏、连接松动、保温劣化	输配阻力增大、有效流量下降、有效冷量折损	4%
阀门	热力膨胀阀	常规: 3~5% 高负载: 6~8% 高温高湿/腐蚀环境: 8~12%	阀芯/阀座磨损、卡滞、密封老化、控制漂移、结露结冰导致开度偏差	流量特性偏移、控制精度下降、响应能力减弱	3%

1.2 基于 AMESim 的空调系统性能退化模型

铁路客站空调系统并非单一设备,而是由冷源侧、水系统、风系统及末端热湿环境共同构成的多子系统耦合对象。沿能量传递方向,冷源侧负责完成制冷循环与冷量生成,水系统承担冷量的输配与分配,风系统负责将冷量由表冷器等末端换热单元搬运至站厅空间,末端热湿环境则为最终受控对象。在实际运行中,系统始终处于外扰、控制、能量链路与环境响应的闭环之中:室外温湿度变化、客流引起的显/潜热负荷波动、门厅渗透与换气负荷、运营时段带来的启停与分区切换,会持续改变系统运行点;控制器则通过调节压缩机负荷、泵/风机转速、阀门开度和送风量等动作维持室内目标

状态。由此,性能退化并不总是立即表现为室内参数越界,而常常首先表现为在相同外扰条件下需要更大的控制动作、更高的功率消耗或更激烈的调节过程才能维持近似的室内状态,这正是系统退化的耦合、传递与代偿特征。

基于上述认识,本文不再将退化简单理解为某一单一部件参数的独立漂移,而是采用等效表征量对系统能力进行统一描述。结合空调系统的典型退化机理,本文将退化对象归纳为四类:旋转机械、换热器、管道系统与阀门,并构造退化等效特征向量:

$$\mathbf{z}(t) = [\eta_{rot}(t), UA(t), K_{pipe}(t), \log K_v(t)]^T \quad (1)$$

式中: t 为时间, 单位为 h , 表示旋转机械等效率因子, 用于综合表征压缩机、风机与水泵在相同输出需求下的效率衰减; $UA(t)$ 为换热器等效退化特征, 可由蒸发侧 $\log UA_{\text{evap}}(t)$ 与冷凝侧过冷度 $SC(t)$ 融合构造; $K_{\text{pipe}}(t)$ 为风/水输配链路的等效阻力系数; $\log K_v(t)$ 为阀门等效流通能力。上述四类变量均为无量纲量, 分别对应冷源能力、换热能力、输配能力与调节能力, 因此比单一系统宏观能效比 (如 EER) 更适合描述铁路客站空调在强扰动背景下的系统级退化, 但其仍可作为辅助观测量参与状态分析, 即将其视为多变量退化表征中的一个外在结果。

为区分工况波动与真实退化, 本文在健康样本上建立健康基线模型。考虑到客站空调系统长期运行于强外扰环境, 若直接使用某一固定典型工况或固定健康能效参考值来定义退化, 容易受到工况选取方式的影响, 并可能导致不同时间段得到不一致的寿命估计。为避免该问题, 本文从数据集中选取前 300 个健康样本, 用于学习正常工况下外扰-控制-系统响应的统计关系, 并构造健康基线:

$$\hat{\mathbf{z}}^0(t) = \mathbf{g}(\mathbf{x}(t)) \quad (2)$$

式中: $\mathbf{x}(t)$ 为可观测的工况与控制特征向量, 主要包括室外温度、室外相对湿度、负荷代理量、转速、阀位、供回水温差等变量; $\mathbf{g}(\cdot)$ 为健康基线回归模型。在此基础上定义残差特征:

$$\mathbf{r}(t) = \mathbf{z}(t) - \hat{\mathbf{z}}^0(t) \quad (3)$$

当系统处于健康状态时, $\mathbf{r}(t)$ 主要由测量噪声和模型误差构成, 并在零附近波动; 当退化累积时, 残差将沿退化方向持续偏移。因此, 本文将退化定义为系统实际表现相对健康基线的持续偏离, 而不是预先假定其必须服从某种固定线性规律。

需要进一步指出的是, 仿真阶段对部分关键参数采用线性或分段线性方式进行退化注入, 主要目的是在可控条件下构造具有统一尺度的退化样本, 便于开展对比实验与后续模型训练; 该设置仅服务于样本生成, 并不意味着实际空调系统及其关键设备的退化过程必然为线性。对于压缩机、风机/水泵、换热器、管路及阀门而言, 真实退化通常会受到磨损累积、腐蚀结垢、泄漏、运行负荷变化以及控制代偿共同影响, 其演化形式可能表现为阶段性、非线性甚至带随机波动的过程。与此同时, 环

境影响也并未被忽略, 而是作为健康基线输入和系统边界条件显式进入建模过程。换言之, 室外热湿扰动、客流波动、渗透换气和启停策略不仅决定系统瞬态状态, 也会通过提高负荷水平、增加控制动作频率与幅值, 间接加速退化演化。

为得到满足工程约束的统一退化度量, 本文进一步将多通道残差映射为非负损伤分量。考虑到不同通道的退化方向可能不同, 例如效率、等效传热能力和阀门流通能力通常随退化下降, 而某些状态量也可能表现为偏高异常, 因此引入方向符号 $s_i \in \{+1, -1\}$, 并定义第 i 个通道的瞬时损伤强度为:

$$d_i(t) = \max(0, s_i r_i(t)), i \in \{\eta, UA, K_v, SC\} \quad (4)$$

为抑制极端点、控制切换和短时扰动对尺度的放大影响, 进一步采用分位数鲁棒归一化:

$$\tilde{d}_i(t) = \text{clip}\left(\frac{d_i(t) - Q_i^L}{Q_i^U - Q_i^L}, 0, 1\right) \quad (5)$$

式中: $\text{clip}(\cdot)$ 表示截断函数; Q_i^L 与 Q_i^U 分别为通道 i 的下、上分位数。随后按权重融合得到综合退化强度:

$$D_{\text{norm}}(t) = \sum_i \omega_i \tilde{d}_i(t), \sum_i \omega_i = 1, \omega_i \geq 0 \quad (6)$$

式中: ω_i 为不同退化通道的权重。当缺乏明确先验时可采用等权; 若已有机理分析或灵敏度分析结果, 也可按设备重要度进行设定。由于 $D_{\text{norm}}(t) \in [0, 1]$, 其既能反映局部部件退化经冷源-水系统-风系统-末端环境链路传递后的系统综合退化程度, 又能对短时工况波动保持鲁棒性。

在得到综合退化强度后, 本文进一步构造代理剩余使用寿命 (RUL_{proxy}) 作为监督标签。设系统名义寿命上限为 RUL_0 , 时间步长为 Δt , 则代理 RUL 递推定义为:

$$RUL_{\text{proxy}}(t + \Delta t) = RUL_{\text{proxy}}(t) - \Delta t [1 + \beta D_{\text{norm}}(t)] \quad (7)$$

式中: $\beta \geq 0$ 为尺度系数, 用于调节退化强度对寿命消耗速率的影响; t 、 Δt 、 $RUL_{\text{proxy}}(t)$ 和 RUL_0 的单位均为 h 。该式表明: 当系统接近健康状态时, 寿命按基准速率消耗; 当 $D_{\text{norm}}(t)$ 增大时, 寿命消耗被加速, 从而在寿命尺度上体现退化阶段性的差异。更重要的是, 只要 $D_{\text{norm}}(t) \geq 0$ 且 $\beta \geq 0$, 则 $RUL_{\text{proxy}}(t)$ 随时间天然保持单调不减, 满足寿命指标的基本物理约束。

通过上述定义, 本文将耦合退化、控制代偿、系统偏移与寿命消耗纳入同一建模框架, 使退化模型不再依赖单一典型工况或固定健康能效参考值, 而能够在强外扰、多工况条件下给出一致的退化表征与可学习的寿命标签。

在本文数据集上, 基于前 300 个健康样本构建的健康基线对四类等效表征量在健康段的 R^2 均达

到 0.998 以上, 在全段仍保持 0.939~0.972 的较高拟合度; 时间与综合退化强度 $D_{norm}(t)$ 的 Spearman 秩相关系数为 0.854, 而时间与代理 RUL 的 Spearman 秩相关系数为 -1.0, 单调性违背次数为 0。这表明该框架能够较好地地区分工况波动与退化信息, 并为后续 RUL 预测提供满足物理约束的监督信号。




图 1 铁路客站空调系统 AMEsim 数字孪生模型

Fig.1 AMEsim digital twin model of the air conditioning system in railway passenger stations




图 2 制冷剂充注量偏差与蒸发器结垢条件下冷凝器出口饱和温度响应面对比

Fig.2 Comparison of the condenser outlet saturation temperature responses under refrigerant charge deviation and evaporator fouling conditions

为验证模型准确性, 选取公开数据集^[22]对模型进行验证, 该数据集研究了空调系统中单一故障与双重并发故障的影响, 并获取相应工况下的系统运行的实时数据。这些故障包括制冷剂充注量异常、

换热器结垢以及多种阀门泄漏。图 2 选取制冷剂充注量与蒸发器结垢这一常见耦合故障作为代表, 对比公开数据集的响应 (a) 与模型仿真结果 (b)。可以看到, 冷凝器出口饱和温度 $R(T_c)$ 的等值线形

态与敏感方向在两幅图中保持一致: 当充注偏离额定并叠加结垢增加时, $R(T_c)$ 单调上升的区域与斜率变化带高度重合, 说明模型能够捕捉充注不足/过充与换热恶化之间的交互影响, 具备用于后续退化研究与 RUL 建模的精度基础。为进一步定量验证仿真模型对公开故障规律的复现能力, 选取若干

典型工况点, 对公开数据与仿真结果进行逐点比较, 结果如表 2 所示。可以看出, 各工况点下仿真结果与公开数据总体吻合较好, 绝对误差和相对误差均控制在可接受范围内, 表明所构建模型能够较准确地反映制冷剂充注量偏差与蒸发器结垢共同作用下冷凝器出口饱和温度的变化规律。

表 2 冷凝器出口饱和温度公开数据与仿真结果在典型工况下的定量对比

Table 2 Quantitative comparison between public data of condenser outlet saturation temperature and simulation results under typical working conditions

工况	制冷剂充注量偏差/%	蒸发器结垢热阻 $/(m^2 \cdot K \cdot W^{-1})$	公开数据值/ $^{\circ}C$	仿真值/ $^{\circ}C$	绝对误差/ $^{\circ}C$	相对误差/%
1	-10	0	44.01	45.16	1.15	2.61
2	0	0	45.06	46.32	1.26	2.80
3	10	0	46.40	47.79	1.39	3.00
4	0	0.0015	44.76	46.06	1.30	2.91
5	10	0.001	43.91	45.18	1.26	2.88
6	-10	0.001	46.30	47.37	1.09	2.36

2 LSTM-Transformer 融合模型

面向空调系统这类长期运行、负荷与环境强耦合的工业设备, RUL 预测既要刻画随老化推进的宏观衰减, 又要对日内/周内的周期性波动与短时扰动保持敏感; 传统方法如基于固定退化模型的物理拟合在复杂工况下易失配, 纯数据驱动的 LSTM/Transformer 虽能学习非线性关系, 却常因目标非平稳(随时间单调下降)与强周期/高频成分共存而出现趋势正确但振幅被压缩的问题, 尤其在使用全局平均池化或缺少频域归纳偏置时更为明显。

2.1 特征工程

针对铁路客站集中冷源空调系统在复杂工况下真实全寿命标签难以获取的问题, 本文不采用名义寿命常数与累计运行时间直接构造绝对 RUL 标签, 而是基于健康基线与多变量残差构造代理 RUL 监督信号。具体而言, 首先从近年运行数据中筛选相对健康样本, 建立各关键性能表征量在健康状态下的参考基线; 随后在相同工况输入条件下, 计算系统实际响应与健康参考之间的偏差, 并将其转换为能够表征退化程度的多变量残差特征。在此基础上, 对各通道残差进行稳健归一化与加权融合, 得到系统综合退化强度, 用以刻画复杂工况下由部件

性能衰减向系统层面传递的退化趋势。

在获得综合退化强度后, 进一步构造满足单调约束的代理 RUL 序列作为模型监督标签。设代理 RUL 初始上限为 RUL_0 , 时间步长为 Δt , 则代理 RUL 可递推表示为:

$$RUL_{proxy}(t) = \max[0, RUL_{proxy}(t-1) - \Delta t \cdot (1 + \lambda D_{norm}(t))] \quad (8)$$

式中: λ 为退化强度映射系数, 用于调节综合退化强度对寿命衰减速率的影响。当系统处于相对健康状态时, $D_{norm}(t)$ 较小, 代理 RUL 主要表现为缓慢下降; 随着退化累积增强, $D_{norm}(t)$ 增大, 代理 RUL 下降速率相应加快。该构造方式既避免了将寿命表征建立在单一名义寿命常数与理想初始时刻上的局限, 又能够在保留工况扰动影响的同时保证寿命演化方向的单调性, 从而为后续预测模型提供更稳定、合理的监督信号。

为增强模型对复杂运行节律的刻画能力, 本文在原始工况变量基础上进一步引入时间谐波特征。设 h 为按小时计的时间索引, P 为周期参数, 则对应的正弦/余弦编码可表示为:

$$\left\{ \sin(2\pi \frac{h}{P}), \cos(2\pi \frac{h}{P}) \right\} \quad (9)$$

式中: $P \in \{24, 12, 8, 6, 4, 168, 84\} h$ 。前五项分别对应日周期及其谐波成分, 主要用于描述室外环

境、客流负荷与控制响应引起的日内周期波动；后两项分别对应周周期与半周周期，用于补充表征铁路客站在周内运营组织、客流强度变化及工况切换下所呈现的低频周期节律。考虑到不同时间尺度在建模中的作用并不相同，本文将 168h 与 84h 周期项主要作为输入端的低频先验，而将 $\{24, 12, 8, 6, 4\}h$ 谐波作为短周期波动建模的主要基底。该处理方式能够在保持长期趋势可辨识性的同时，增强模型对短期扰动的适应能力，从而更合理地解释代理 RUL 序列中趋势项与周期波动项的共存现象。

2.2 融合模型架构设计

LSTM 擅长刻画局部时序依赖，Transformer 擅长捕捉长程关联，但前者在长序列中易稀释早期弱退化信息，后者则可能过度平滑短期扰动。考虑到铁路客站空调系统 RUL 序列同时包含长期衰减趋势与短周期工况波动，本文构建 LSTM-Transformer 融合网络，以实现局部动态与全局依赖的协同建模^[23,24]。

具体模型架构由单层双向 LSTM 先在输入端完成时序重构与短期依赖聚合，随后进入由多头缩放点积注意力、残差连接与规范化组成的三层 Transformer 编码器以建模长程依赖；为增强局部细节捕获能力，在编码器后并联三支一维卷积分支（小核、较大核、膨胀卷积），并改用末时刻聚合而非全局平均池化，以避免对高频振幅的过度平顺。输出端设置双头：其一为低频回归头直接预测 $\hat{r}_{low}(t)$ ；其二为高频谐波重建头，不是直接回归标量，而是预测当前时刻谐波基向量（由 24/12/8/6/4 小时的 $\sin/\cos$ 组成）的系数 C_t ，高频预测由内积 $\hat{r}_{hp}(t) = \langle C_t, H_t \rangle$ 获得，从结构上约束模型把高频能量放回可解释的频域。

本设计与传统方法及纯端到端模型相比，该方法在保证整体衰减趋势与相位准确性的基础上，显著提升了对日内齿形振动幅值的描述精度与模型可解释性，在复杂工况与非平稳场景中表现出更优的泛化能力与鲁棒性。

2.3 模型训练与参数设置

原始逐时时间序列按时间顺序构造滑动窗口样本，并按 70%/15%/15% 划分训练、验证和测试集，以避免时间泄漏；连续特征均基于训练集完成

标准化，关键超参数如表 3 所示。训练阶段采用低/高频双支路损失联合优化，其中低频头采用 SmoothL1 损失，高频头采用振幅加权 MSE 损失；同时结合 Dropout、梯度裁剪、早停及 AdamW 优化器与 ReduceLROnPlateau 学习率调度器完成模型训练。最终采用平均绝对误差（MAE）、均方根误差（RMSE）与平均绝对百分比误差（MAPE）作为评价指标，在测试集上完成模型性能验证，并输出真实值与预测值的对比图表。

以上设置在保证整体衰减趋势可拟合的同时，显式强化对日内/半日等高频振动的幅值与相位刻画；同时，通过分离标定进一步对齐尺度与偏置，兼顾可解释性与泛化稳定性，适用于空调系统在复杂工况与非平稳退化背景下的 RUL 预测任务。




图 3 LSTM-Transformer 融合模型结构

Fig.3 Structure of the LSTM-Transformer fusion model

表 3 融合模型关键超参数设置

Table 3 Key hyperparameter settings of the fusion model

名称	设定值	名称	设定值
序列长度	168	LSTM 隐藏层	128
滑窗步长	1	LSTM 层数	1 (双向)
训练集占比	70%	Transformer 隐藏层	128
验证集占比	15%	注意力头数	8
测试集占比	15%	Transformer 编码器层数	3
学习率	$1e^{-6} \sim 1e^{-3}$	训练轮次	120

3 结果分析

3.1 时序数据集

为从系统层面获得可观测征兆的长时序轨迹,并为后续特征筛选与代理 RUL 预测评估提供样本,依据上一节的建模与参数设定,选用东南沿海地区某小

型铁路客站一制冷分区空调系统,在 AMESim 中模拟了从 2024 年与 2025 年 5 月 1 日~9 月 30 日两个制冷季运行情况。表 4 给出了主要边界条件与围护结构热工参数。退化在仿真样本生成阶段以线性/分段线性扰动形式注入,仅用于构造可控退化样本,控制策略与外界扰动则随时间变化。

表 4 模型边界条件设置

Table 4 Model Boundary Condition Settings

模型边界	条件设置	模型边界	条件设置
站房面积	3200m ²	围护结构	传热系数 [W/(m ² ·K)]
分区总负荷	1124 kW	墙体	0.5
室内设计温度	26℃	玻璃幕墙	3.0
人员散热	200 W/人	楼板	0.6
设备散热	8 kW	屋顶	0.7




图 4 两个制冷季典型工况长序列仿真结果

Fig.4 Long-sequence simulation results under typical working conditions for two refrigeration seasons

图 4 展示了 2024 年和 2025 年两个独立制冷季的仿真结果,图中通过分段标记对两个制冷季进行了区分。室外环境温度呈显著的日周期与季节起伏,室内温度在控制器作用下稳定在设计点附近,送风温度随负荷波动而快速响应;蒸发器负荷与压

缩机功率与外界温度的节律保持一致。该结果表明模型在既定边界下能够稳定生成跨季、跨工况的一致时序数据,并显式保留耦合与代偿效应对能效与舒适性的影响。图 5 中出现阶段性波动的主要是综合退化强度及寿命消耗速率,而代理 RUL 本身在

构造上保持单调下降,不存在非物理性回升。前者反映了系统寿命随服役时间推进而不断消耗的总规律,后者则主要来源于气象变化、负荷波动及控制策略切换等运行扰动对系统响应的影响。因此,图中局部起伏并不意味着寿命发生反常回升,而是复杂工况下系统动态特征在寿命表征中的体现。进一步的单调性验证表明,代理 RUL 与时间推进在秩意义下完全一致, Spearman 秩相关系数为-1.0,且全序列单调性违背次数为 0,说明该标签在保留工况扰动信息的同时,仍能够严格维持正确的寿命演化方向。




图 5 综合退化强度与代理 RUL 演化结果


Fig.5 Comprehensive degradation intensity and surrogate RUL evolution results

3.2 预测结果分析


为验证所提 LSTM-Transformer 融合模型在铁路客站集中冷源空调系统剩余使用寿命预测中的适用性,本文在统一数据集、统一评价指标和统一训练条件下,将其与单一 LSTM 模型和 Transformer 模型进行对比分析。

图 6 中散点图展示了不同模型预测代理 RUL 与标签代理 RUL 的分布关系。理想情况下,各散点应尽可能靠近对角线 $y=x$,其中融合模型的点簇最贴近参考线,表明其总体预测偏差最小。时间序列图进一步给出了不同模型对代理 RUL 演化趋势的拟合结果。LSTM 在局部扰动刻画方面表现较好,但随着预测步长增加,早期弱退化信息在长序列传播中逐渐被稀释,曲线偏离标签代理 RUL;Transformer 对长期衰减趋势的刻画较为稳定,但对短周期波动的响应相对平滑;相比之下,LSTM-Transformer 融合模型能够更好兼顾长期趋势跟踪与局部扰动表征,其预测曲线与标签代理 RUL 吻合度最高。需要指出的是,图 6 (b) 中的

波动主要体现为模型预测曲线围绕代理 RUL 标签的局部偏差,而非系统真实寿命的物理性回升。本文代理 RUL 标签满足单调不增约束,因此其长期演化方向是确定的;图中局部起伏主要来源于复杂工况下周期扰动、短时波动及有限窗口学习误差的共同作用。与此同时,前文线性退化设定仅用于退化样本生成,并不意味着系统级代理 RUL 表征在时域上必须呈现严格线性变化。



(a)



(b)

图 6 不同模型代理 RUL 预测结果对比分析

Fig.6 Comparison of proxy RUL prediction results of different models

通过表 5 三项指标的一致性对比表明,融合模型在三种评价指标下均优于单一模型,其结合了 LSTM 对时序依赖的捕捉能力与 Transformer 对全局特征的建模能力,在 RUL 预测精度上具有明显优势。

表 5 预测模型评价指标结果

Table 5 Evaluation metrics results of predictive models	MAE	RMSE	MAPE
LSTM-Transformer	49.91	58.57	0.064%
Transformer	65.78	80.59	0.080%
LSTM	139.42	176.01	0.180%

4 结论

本文围绕铁路客站集中冷源空调系统 RUL 预测问题,构建了基于 AMESim 的退化仿真平台,并提出 LSTM-Transformer 融合预测方法。主要结论如下:

(1) 针对铁路客站集中冷源空调系统真实全寿命标签难以获取的问题,提出了基于健康基线与多变量残差的代理 RUL 构造方法,实现了复杂工况下退化信息与工况扰动的有效分离,并保证寿命标签满足单调约束。

(2) 针对 RUL 序列中长期衰减趋势与短周期波动并存的特点,构建了 LSTM-Transformer 融合预测模型。结果表明,该模型在 MAE、RMSE 和 MAPE 指标上均优于单一 LSTM 和 Transformer,体现出更好的趋势跟踪能力与扰动适应性。

(3) 依托 AMESim 构建的多工况长时序退化数据集,本文验证了所提方法在铁路客站空调系统场景下的适用性,为后续预测性维护与状态评估提供了可行的方法基础。

参考文献:

- [1] 肖滔,雷波.大型高铁客运站建筑能耗影响因素分析[J].制冷与空调,2021,35(1):13-17.
- [2] Ferreira C, Gonçalves G. Remaining Useful Life prediction and challenges: A literature review on the use of Machine Learning Methods[J]. Journal of Manufacturing Systems, 2022,63:550-562.
- [3] Huang Y, Lu Z, Dai W, et al. Remaining Useful Life Prediction of Cutting Tools Using an Inverse Gaussian Process Model[J]. Applied Sciences, 2021,11(11):5011.
- [4] 上官伟,巴明明,孟月月.基于Copula函数的列车定位惯性单元剩余寿命预测方法[J].铁道学报,2022,44(4):63-73.
- [5] 沈雪婷,李红阳,陈伟锋,等.面向设备性能退化监测的分步参数估计策略[J].高校化学工程学报,2024,38(2):294-301.
- [6] Vichard L, Harel F, Ravey A, et al. Degradation prediction of PEM fuel cell based on artificial intelligence[J]. International Journal of Hydrogen Energy, 2020,45(29):14953-14963.
- [7] Liu L, Song X, Zhou Z. Aircraft engine remaining useful life estimation via a double attention-based data-driven architecture[J]. Reliability Engineering & System Safety, 2022,221:108330.
- [8] Cheng S, Pecht M. A fusion prognostics method for remaining useful life prediction of electronic products[C]. 2009 IEEE International Conference on Automation Science and Engineering, 2009:102-107.
- [9] Pecht M, Jaai R. A prognostics and health management roadmap for information and electronics-rich systems[J]. Microelectronics Reliability, 2010,50(3):317-323.
- [10] Liu H, Chen J, Hissel D, et al. Remaining useful life estimation for proton exchange membrane fuel cells using a hybrid method[J]. Applied Energy, 2019,237:910-919.
- [11] Sun B, Li Y, Wang Z, et al. An improved inverse Gaussian process with random effects and measurement errors for RUL prediction of hydraulic piston pump[J]. Measurement, 2021,173:108604.
- [12] Zeng Y, Song D, Zhang W, et al. A new physics-based data-driven guideline for wear modelling and prediction of train wheels[J]. Wear, 2020,456-457:203355.
- [13] Mirnaghi M S, Haghighat F. Fault detection and diagnosis of large-scale HVAC systems in buildings using data-driven methods: A comprehensive review[J]. Energy and Buildings, 2020,229:110492.
- [14] Kelly G E, Bushby S T. Detecting faults in building air handling units – a background study for developing intelligent agents for optimizing building HVAC systems: NIST TN 1831[R]. National Institute of Standards and Technology, 2014: NIST TN 1831.
- [15] Ruiz-Arenas S, Rusák Z, Mejía-Gutiérrez R, et al. Implementation of System Operation Modes for Health Management and Failure Prognosis in Cyber-Physical Systems[J]. Sensors, 2020,20(8):2429.
- [16] 韩晓霞,宋涛,孙一杰,等.基于多变量波动特征融合的空调制冷系统故障检测[J].工程科学与技术,2026,58(2):361-371.
- [17] 张天睿,杨辰,杨静.既有公共建筑暖通节能及绿色改造现状分析[J].科技与创新,2024,(5):166-168.
- [18] Li T, Zhao Y, Zhang C, et al. A knowledge-guided and data-driven method for building HVAC systems fault diagnosis[J]. Building and Environment, 2021,198:107850.

(下转第 445 页)