

一种面向长航时固定翼无人机推进系统的状态预测方法

李思成^{①②③} 王连清^{*③④} 李志永^{*①②} 王国昌^{①②}
葛凯华^⑤ 陈俊锋^⑥ 谭荣清^{①②}

^①(中国科学院空天信息创新研究院 北京 100094)

^②(中国科学院大学电子电气与通信工程学院 北京 100049)

^③(国防科技大学智能科学学院 长沙 410073)

^④(信息支援部队工程大学指挥控制保障系 武汉 430030)

^⑤(中国航空气动力技术研究院创新与应用中心 北京 100074)

^⑥(中国人民解放军92728部队 上海 200436)

摘要: 面向长航时固定翼无人机推进系统关键状态预测的工程应用需求, 该文优化设计出一种融合多尺度嵌入与分组通道注意力的时序卷积模型(Grouped Squeeze-and-Excitation Multi-scale Temporal Convolutional Networks, GEMS-TCN)。该模型采用多尺度嵌入层自适应提取短期波动与长期趋势的混合时序表征, 通过分组通道注意力实现变量内与跨变量特征的层次化加权。基于实飞数据集的实验结果表明, GEMS-TCN在推进系统16维关键状态的单步预测精度优越, 测试集中平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Squared Error, MSE)分别达到0.171、0.069, 且在不同特征及昼夜工况下均保持一致的精度优势, 为固定翼无人机推进系统多维状态预测提供了切实可行且性能优异的实施方案。

关键词: 固定翼无人机; 状态预测; 时序卷积网络; 多尺度嵌入; 分组通道注意力

中图分类号: TP183

文献标识码: A

文章编号: 1009-5896(2026)00-0001-12

DOI: 10.11999/JEIT260188

CSTR: 32379.14.JEIT260188

1 引言

近年来, 无人机在环境监测、灾害应急、基础设施巡检^[1]等领域得到广泛应用。相较于多旋翼无人机, 固定翼无人机具备航程长、速度快、载能力强等优势, 在长航时飞行中展现出广阔的应用前景^[2]。此类任务中, 固定翼无人机需要在7 000-20 000 m高空复杂环境下稳定飞行不少于24 h, 而其推进系统状态参数呈现多时间常数与强耦合特性, 故障也往往以这些参数的异常演化为先兆。因此, 针对固定翼无人机推进系统开展时序状态预测, 不仅能够故障预警与容错控制提供依据, 也是推动无人机自主健康管理体系构建的关键环节之一, 对保障飞行安全与任务稳定性具有重要意义^[3]。

在无人机故障诊断与健康管理的不断发展中, 相关研究可分为基于模型的方法与数据驱动的方法^[4]。基于模型的方法通常依赖系统动力学模型及观测器建模状态演化关系, 并在此基础上实现故障检测、状态估计与控制补偿。近年来, 该技术路线已由单纯的状态观测延伸至故障重构与容错控制。Gong等人^[5]围绕执行器故障构建了基于扩张状态观测器

的预设时间容错控制方案, Zhou等人^[6]进一步利用双通道故障观测器实现了执行器故障的快速识别与定位。这类方法在机理清晰、可解释性强等方面具有优势, 但其性能高度依赖模型精度。当系统同时具有非线性、时变性、强耦合特性时, 精确建模难度显著增加, 工程应用中的泛化能力也因此受限。对于长航时固定翼无人机推进系统而言, 这一矛盾尤为突出。

相较之下, 数据驱动方法直接从飞行数据中学习状态演化规律与故障表征, 更适合处理无人机飞行过程中普遍存在的多变量耦合、工况迁移和噪声扰动问题。围绕固定翼无人机应用场景, Liang等人^[7]针对完整飞行任务中多工况交替的特点, 构建了面向固定翼无人机的多工况数据驱动故障诊断框架; 在此基础上, Zhang等人^[8]进一步面向小样本条件引入异构深度多任务学习, 通过时空特征互补提升了固定翼无人机故障诊断性能。随着深度学习方法的发展, 相关研究又进一步转向更强的时序特征建模。Guo等人^[9]提出不确定性感知长短期记忆网络(Uncertainty-Aware Long Short-Term Memory, UA-LSTM), 用于无人机执行器动态飞行故障检测; Chu等人^[10]结合相似空间映射与改进自注意力LSTM, 优化实现了无人机传感器故障检测; Wang等人^[11]进一步引入自监督对比学习和多变量飞行数

收稿日期: 2026-02-12; 改回日期: 2026-07-08

*通信作者: 王连清 lianqingw@126.com;

李志永 zhiyongli@aircas.ac.cn

据的时空信息,以仅使用正常样本的方式完成故障检测与解释;Fang等人^[12]则面向小样本传感器故障诊断提出多辅助任务学习框架;张景森等人^[13]进而针对故障诊断中标注样本不足问题,引入半监督生成式模型提升飞控系统故障诊断能力。上述研究路径表明,数据驱动方法正由传统监督学习逐步向半监督学习、自监督学习与任务协同学习演进。

需要指出,现有数据驱动研究虽然为无人机故障检测与状态识别提供了重要基础,但其研究目标多集中于故障类别判别和异常告警,尚难直接满足长航时固定翼无人机推进系统关键状态连续预测的需求。面对兼具短时波动、缓慢演化与跨变量耦合特征的推进系统信号,如何统一建模长时间依赖、多尺度时序模式及变量间复杂关联,仍是有待进一步解决的问题^[14,15]。

与此同时,通用时序预测领域的快速发展,也为无人机推进系统状态预测提供了新的方法启发。PatchTST通过分块切分与通道独立建模增强了长序列预测能力^[16];TimesNet则将一维时间序列重构为二维变化表征,从而更有效地刻画多周期时序变化^[17]。在此基础上,Zeng等人^[18]研究表明,时序预测性能的提升并不必然依赖更复杂的Transformer结构,而应更加重视模型结构与任务特性的匹配关系;ModernTCN进一步回到卷积建模范式,通过扩大有效感受野并将时间、变量和通道三个维度解耦建模,在多个主流时序分析任务上取得了较好的性能与效率平衡^[19]。然而,这些通用框架并非针对固定翼无人机推进系统的多时间常数、强耦合、强工况变化场景而设计,若直接迁移,仍难以充分刻画关键状态中快速扰动与缓慢演化并存的动态特征,也难以兼顾变量内部表征与跨变量关联的层次化建模需求。

鉴于此,本文聚焦于长航时固定翼无人机推进系统的多特征单步预测任务,充分利用ModernTCN的有效感受野优势与解耦思想,优化设计出一种融合多尺度嵌入与分组通道注意力的时序状态预测方法——GEMS-TCN。针对原预测框架时间尺度提取单一、通道特征利用不充分的问题,本方法对应引入多尺度嵌入层(Multi-scale Embedding, MsE)^[20]与分组通道注意力(Grouped Squeeze-and-Excitation, GroupSE)^[21],使MAE、MSE分别达到0.171、0.069,有效提高了长航时场景下固定翼无人机状态预测精度,显示出本文方法在该场景的应用潜力。

本文结构安排如下:第2节详细介绍模型架构与实现;第3节呈现对比实验、消融实验的实验设计及结果分析;最后,第4节总结全文工作。

2 融合多尺度嵌入与分组通道注意力的GEMS-TCN模型

本文优化设计出的GEMS-TCN模型架构如图1所示。GEMS-TCN模型包括MsE、由GEMS-TCN Blocks构成的主干以及根据预测任务变化的映射层。其中,MsE负责将原始输入序列映射为高维潜空间表示,以便后续网络捕捉时序变化趋势;主干部分由 n 个堆叠的GEMS-TCN Block构成,每个Block包含五个部分:逐深度卷积(Depthwise Convolution, DWConv)^[22]、前馈卷积网络(Convolutional Feed-Forward Network, ConvFFN)、GroupSE、层间残差连接^[23]以及批归一化^[24];最后,映射层对提取到的多尺度时序特征进行展平并通过线性层输出目标的预测值。

2.1 模型架构与数据流

模型输入为 $\mathbf{X}_{in} \in \mathbb{R}^{B \times M \times L}$,其中 B 、 M 和 L 分别代表批次大小、变量维度(即无人机状态变量的数量)以及时间窗口长度。在嵌入阶段,模型采用 $\{P_1, P_2, P_3\}$ 三个具有不同大小卷积核的一维卷积实现并行滑动窗口式特征提取,通过卷积核大小 P 与步幅 S 控制时间维的压缩比,对各变量划分出 N 个时间片。为了保持每个变量的独立性,卷积操作仅在时间维展开,通道方向不共享权重,从而得到变量独立的嵌入表示 $\mathbf{X}_{emb} \in \mathbb{R}^{B \times M \times D \times N}$,其中 D 为特征嵌入维度, N 为时间片数量, $N = \lceil L/S \rceil$ 。

主干由 n 个堆叠的GEMS-TCN Block构成。每个Block首先通过DWConv沿时间维捕获特征变化,卷积核大小取推荐值51以扩大有效感受野^[25],从而在不增加网络深度的情况下增强长期依赖建模能力。随后进行批归一化,以维持数据尺度的一致性并加快训练速度。

在完成时间维特征提取后,Block通过分组前馈卷积网络以及与其配合的分组通道注意力实现变量与通道维的“解耦-再耦合”。具体而言,ConvFFN1按变量分组($\text{groups}=M$),对单变量的多维特征通道进行非线性映射,实现变量内表征的非线性重构;GroupSE1在同一变量内部重新分配特征权重,以学习变量内特征的相对重要性。随后将输入沿特征维转置,ConvFFN2按特征分组($\text{groups}=D$)建模跨变量耦合关系;GroupSE2学习同一特征维在不同变量间的动态权重,实现跨变量的权重调制。

这种逐变量卷积配合跨变量卷积的层次化结构以及权重重标定确保了时序关系、变量间关联和特征抽象的分离建模,能够显著提升模型学习能力与泛化性能。同时,GEMS-TCN Block配置了残差连接以缓解深层训练的梯度不稳定问题。经过 n 个




图 1 GEMS-TCN模型架构图

GEMS-TCN Block堆叠，模型获得了多尺度的时间序列表达 $\tilde{\mathbf{X}} \in \mathbb{R}^{B \times M \times D \times N}$ ，再由映射层将各变量的嵌入特征重排得到 $\mathbf{Z} \in \mathbb{R}^{B \times M \times (D \times N)}$ ，并最终通过线性层映射到目标输出维度。通过结构化地引入MsE、GroupSE，GEMS-TCN由均匀建模转向差异化自适应建模，更加符合固定翼无人机推进系统的数据特性。

2.2 多尺度嵌入层

MsE通过三个并行一维卷积在不同时间感受野上提取时序特征，旨在丰富时间特征的尺度表达，使模型能同时捕获短周期和长周期动态变化。本层输入表示为 $\mathbf{X}_{in} \in \mathbb{R}^{B \times M \times L}$ ，而ModernTCN的嵌入层可表示为：

$$\mathbf{X}_{emb} = \text{Conv1d}(\mathbf{X}_{in}; P, S, D) \quad (1)$$

其中 D 为特征嵌入维度，而卷积核大小 P 和步幅 S 固定，这种单一尺度会造成时间特征的分辨率瓶颈，降低时间特征丰富度。MsE通过引入多尺度卷积核集合 $\{P_1, P_2, P_3\}$ ，并行提取不同时间窗口下的特征，得到三种不同时间尺度的嵌入表示：

$$P_1 = P_2/2; P_3 = 2 \times P_2 \quad (2)$$

$$\mathbf{X}_{emb}^k = \text{Conv1d}(\mathbf{X}_{in}; P_k, S, D_k), k = 1, 2, 3 \quad (3)$$

接着，各分支输出经时间维对齐后在通道方向拼接，形成多时间尺度融合的嵌入表示 $\mathbf{X}_{emb} \in \mathbb{R}^{B \times M \times D \times N}$ ；

$$\mathbf{X}_{emb} = \text{Concat}[\mathbf{X}_{emb}^1, \mathbf{X}_{emb}^2, \mathbf{X}_{emb}^3] \quad (4)$$

多尺度嵌入可以视为一种隐式的多频带滤波机制。小卷积核在时间域上相当于高通滤波器，强调局部差异；大卷积核则类似低通滤波器，平滑长期趋势；中尺度核在两者之间起桥梁作用。这种“多频带融合”有助于捕捉电气与热学参量的多时间常数特性，使模型能同时对突发响应与缓变积累进行建模。

2.3 分组通道注意力

GroupSE在保持解耦结构的前提下，为变量内特征和跨变量特征赋予差异化权重，实现注意力的层级分配。GEMS-TCN Block中，经ConvFFN1和ConvFFN2处理后，不同变量与特征维的通道响应强度往往存在差异。原始的通道注意力通过全局池化和非线性映射生成统一权重，对所有通道施加同等尺度的校准^[21]。在多变量时序预测场景中，不同变量组的特征相关性差异显著，温度特征间高度相关，而电压特征则对外部扰动更敏感，统一加权可能导致重要特征被掩盖。因此，本文提出分组通道注意力，GroupSE引入分组机制，即通道间分组独立学习权重，实现变量内独立标定，变量间独立调制，从而在不破坏解耦结构的前提下为每个通道组赋予独立的注意力分布。

GroupSE_i模块的输入表示为 $\mathbf{X}_i \in \mathbb{R}^{B \times C_i \times N}$ ($i = 1, 2$)，其中 $C_1 = M \times D$, $C_2 = D \times M$ 。Group-

SE i 将通道划分为 $G_i(i = 1, 2)$ 个独立组, 其中分组数为 $G_1 = M, G_2 = D$, 每组通道数可表示为:

$$C_i^g = C_i / G_i, i = 1, 2 \quad (5)$$

首先对输入数据 $\mathbf{X}_i$ 在时间维上进行全局平均池化, 得到全局时间维度的统计向量:

$$\mathbf{z}_i = \frac{1}{N} \sum_{n=1}^N \mathbf{X}_i(:, n), \mathbf{z}_i \in \mathbb{R}^{B \times C_i \times 1} \quad (6)$$

Squeeze-Excitation阶段, 对组内的特征信息进行压缩和激活, 每个通道组独立地通过两层卷积核大小为1的逐点卷积(Pointwise Convolution, PWConv), 学习非线性权重向量:

$$\mathbf{s}_i^g = \sigma(\mathbf{W}_i^{2,g} \delta(\mathbf{W}_i^{1,g} \mathbf{z}_i)) \quad (7)$$

其中权重矩阵 $\mathbf{W}_i^{1,g} \in \mathbb{R}^{C_i/r \times C_i}$, $\mathbf{W}_i^{2,g} \in \mathbb{R}^{C_i \times C_i/r}$, r 为压缩比(r 需保证经压缩后 C_i/r 能够被分组数 G_i 整除), $\delta(\cdot)$ 代表ReLU激活函数, $\sigma(\cdot)$ 代表Sigmoid归一化。接着, 利用 $\mathbf{s}_i^g$ 进行特征权重重标定, 将注意力权重扩展至整个时间维并与输入数据逐元素相乘:

$$\tilde{\mathbf{X}}_i = \mathbf{s}_i^g \odot \mathbf{X}_i, \tilde{\mathbf{X}}_i \in \mathbb{R}^{B \times C_i \times N} \quad (8)$$

整个过程是一种组内通道自适应缩放机制, 由各通道所在的分组独立学习权重, 保留了变量间的独立性与语义一致性。GroupSE的引入可视为在卷积输出后附加一个通道加权滤波器, 通过学习到的注意力权重 $\mathbf{s}_i^g$ 动态调整不同通道的信号增益, 相当于在模型内部形成了一种自适应能量分配机制。

3 实验设计与结果分析

3.1 实验数据与预处理

本文实验数据来源于某型长航时固定翼无人机在实际飞行任务中的系统运行记录, 由中国航天空气动力技术研究院创新与应用中心提供。该型固定翼无人机推进系统主要由电机、驱动器、电源及温

控电路构成, 其中驱动器包含数字控制、功率驱动以及电压采样等模块。该无人机连续采集9天得到共806 629个时间步的实验数据集, 数据采集过程如图2所示, 飞行过程中, 数据采集系统以1 Hz采样频率通过数据组帧将关键状态参数实时传送至上位机通讯模块, 经同步处理后由遥测链路传输到地面站。

原始数据涵盖固定翼无人机推进系统的多物理量耦合特征及环境参量, 共计72个维度。本方法以完整72维时序特征作为模型输入, 以1#-4#电机的母线电压、控制单元温度、绕组温度以及功率器件温度共16维关键特征作为预测目标。根据文献调研及工程经验, 上述16维关键特征与推进系统供电异常、热失效及性能退化过程紧密相关, 其与故障预警任务的对应关系详见表1。

本研究为分析待预测关键特征与输入特征之间的统计关联, 开展了基于互信息的相关性分析。依据物理含义将72维输入特征划分为推进系统、供电系统、飞行控制、大气与环境以及辅助特征5个特征组, 具体分组见表2。考虑到不同目标特征对应的组级互信息存在数值尺度差异, 本文在组级互信息 I_{ij} 的基础上进一步构造归一化相对互信息: $\tilde{I}_{ij} = I_{ij} / \max_j I_{ij}$ 。

其中, I_{ij} 表示第 i 个关键特征与第 j 类输入特征组之间的组级互信息, $\tilde{I}_{ij} \in [0, 1]$ 表示同一目标状态下各特征组的相对关联强弱, 当 $\tilde{I}_{ij} = 1$ 时, 说明该特征组在对应目标状态下具有最强统计关联。

考虑四台电机在结构组成、测量维度及工作机理上具有一致性, 本文选取1#电机的母线电压、控制单元温度、绕组温度和功率器件温度4个关键特征进行展示, 为避免特征自身参与统计而引入显著偏置, 互信息计算时已将待分析特征从特征组中剔除。结果如图3所示, 母线电压与供电系统特征组的相对互信息最高, 而控制单元温度、绕组温度




图2 固定翼无人机推进系统数据采集示意图

表 1 16维待预测关键特征与故障预警任务关系表

1#-4#电机特征组	单位	物理含义	与故障预警任务的关系
母线电压	V	电机驱动侧直流供电水平以及负载扰动下的母线稳定性	异常下降或波动表征电池接近截止放电阈值、剩余航时下降及供电链路异常，是续航预测与任务级预警的重要先兆 ^[26]
控制单元温度	℃	电机控制电子单元的热负荷水平与散热状态	异常升高常对应故障、开关异常或散热退化，可用于推进系统早期告警与故障隔离 ^[3]
绕组温度	℃	电机定子绕组的热积累程度和绝缘系统受热水平	持续升高通常意味着过流、绕组绝缘退化或退化向电机侧传递，可作为电机热失效与性能衰退的关键预警量 ^[27]
功率器件温度	℃	电机驱动器功率半导体器件的热应力水平	异常升高直接指向功率器件退化、开关频率异常与效率下降，严重时可导致失推，是驱动级健康管理的重要监测量 ^[3]

表 2 数据集72维特征分组表

序号	特征组	数据项
1	推进系统	1#-4#电机实际转速、指令转速、母线电压、母线电流、D/Q轴电流、解算力矩、转子位置、控制单元温度、绕组温度、功率器件温度
2	供电系统	1#-8#单体电池电压
3	飞行控制	指示空速、真空速、地速
4	大气与环境	气压高度、海拔高度、左右两侧大气静温
5	辅助特征	帧计数器；1#-4#电机电机序号、电机系统状态、通讯状态字




图 3 各特征组与1#电机关键特征的相对互信息热图

和功率器件温度均与大气与环境特征组表现出强关联；同时，三类温度状态与推进系统、供电系统及飞行控制特征组也保持较高相关性，辅助特征组的关联性整体较弱。上述结果表明，16维关键状态与72维输入特征之间存在明确且符合工程机理的统计依赖关系，其中电压类状态主要表征供电侧变化，温度类状态则综合反映外部环境、负载水平及推进工况的耦合影响。因此，以72维输入特征预测推进系统16维关键状态具有合理性，也为模型的解耦设计提供了可解释性支撑。

原始数据在输入模型之前需经过如图4系统化的清洗与标准化处理。首先，根据采集系统输出的日期与时间字段生成统一的时间索引。随后，将所有非数值型字段转换为浮点型。数据清洗部分采用基于四分位距(Interquartile Range, IQR)的统计判别方法， Q_1 和 Q_3 分别表示第1、第3四分位数，当样本点超出所在列 $[Q_1 - 1.5 \times IQR, Q_3 + 1.5 \times IQR]$




图 4 数据预处理流程图

区间时视为异常，并将该点置为缺失。为减弱噪声引入的瞬态扰动，采用线性插值双向填补缺失数据，并在插值后再次进行异常检测与插值迭代，从而确保序列的连续性与平滑性。最后，对所有数值列统一进行数据类型优化，将64位浮点数压缩为32位，以降低内存占用。

数据划分方面，本文严格遵循时间顺序切分原则，确保未来信息不泄露至训练过程。按8:1:1划分训练集、验证集与测试集，接着对训练集进行标准化拟合，并将同一变换应用于验证集与测试集。

固定翼无人机推进系统时序状态预测为监督学习问题，需要在划分好的数据集上构造样本及标签，构造方法如图5。其中，行代表时间步，列代表样本或标签的特征。从首个时间步开始，时间窗口长度设定为96秒(time step=96)，将72维变量特征均作为第一个样本sample1，待预测时间步与样本末尾时间步时距为10秒(horizon=10)，并取16维推进系统特征作为标签y1。为确保充分利用数据集，样本和标签选取框滑动间隔s设为1，进而批量构造出样本及对应标签。

3.2 实验配置与模型参数

为验证本文方法的有效性,我们采用2个GEMS-TCN Block堆叠得到实验模型。对比模型选取PatchTST^[16]、ModernTCN^[19]、FEDformer^[28]、DLinear^[18]以及TimesNet^[17],覆盖当前典型时序预测建模范式。本文任务中原始输入状态变量共计72维,因此将变量维度 M 设为72;根据3.1节样本构造方式,对应将输入时间窗口长度 L 设为96。模型训练采用MSE作为损失函数,该损失在时序预测任务中效果较优^[29],并与本文MSE评价指标保持一致;优化算法采用Adam^[30],并结合验证集收敛情况、训练稳定性和显存条件确定出实验超参数,学习率为 1×10^{-4} ,训练批次大小为128,每次训练迭代100轮,实验环境配置如表3所示。

针对MsE,本文将式(1)中的步幅 S 设为4,该设置参考ModernTCN面向长期预测任务的默认步幅^[19],在保持时序信息完整性的同时减少时间片数量。卷积核大小 P 和嵌入维度 D 分别用于调节时间维感受野以及表征能力,两参数具体取值由3.4节单因素敏感性分析确定。对于GroupSE模块,参考通道注意力机制中的默认配置将压缩比 p 设为16^[21],同时满足本文分组通道重标定中的维度压缩与分组约束要求。由于GEMS-TCN设计时将变量维与特征维解耦建模,GroupSE模块的关键分组参数由模型结构直接确定:GroupSE1模块的总通道数 $C_1 = M \times D$,分组数 $G_1 = M$;GroupSE2模块的总通道数 $C_2 = D \times M$,分组数 $G_2 = D$ 。




图 5 样本构造示意图

表 3 实验环境配置

硬件	配置	软件	配置
CPU	Intel Xeon Gold 6330	操作系统	Ubuntu 22.04
GPU	NVIDIA A100 PCIe 40GB	编程框架	PyTorch 2.0.0

3.3 实验指标与评估方法

为了从不同角度衡量模型性能,实验采用三类典型回归指标综合评估:MSE、MAE以及平均绝对百分比误差(Symmetric Mean Absolute Percentage Error, SMAPE)。其中,MAE用于衡量预测值与真实值之间的平均绝对偏差,MSE对较大预测误差更为敏感,可反映模型对异常偏差的抑制能力;SMAPE为无量纲相对误差指标,能够在不同量纲和不同数值范围的状态变量之间提供更具可比性的评价结果。三者公式如下:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |P_i - R_i| \quad (9)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (P_i - R_i)^2 \quad (10)$$

$$\text{SMAPE} = \frac{1}{n} \sum_{i=1}^n \frac{2|P_i - R_i|}{|P_i| + |R_i| + \varepsilon} \quad (11)$$

P_i 、 R_i 分别代表时间步 i 的预测特征向量与真实特征向量, ε 为避免分母为零引入的极小正数。上述指标均在测试集上独立计算,指标值越小,说明模型预测结果与真实结果越接近,模型性能越优。

3.4 实验超参数优化配置

为给出关键超参数的可复用选取依据,本文对卷积核大小 P 与嵌入维度 D 进行了单因素敏感性分析,在保证数据划分与其余训练参数设置保持一致的条件下,分别令 $P \in \{2, 4, 8, 16, 32\}$ 、 $D \in \{32, 64, 128, 256, 512\}$,得到如图6的两组敏感性分析曲线。由图6(a)可见,随 P 增大,模型误差先显著下降后趋于饱和,说明较小 P 对长时间依赖表征不足,而过大的 P 会带来更强的时间平滑与更粗的片段化表示,导致有效信息密度下降,误差不再改善甚至回升。因此,综合MAE、MSE的最优点与稳定性,本文选择 $P=16$ (对应 $\{8, 16, 32\}$ 的多尺度卷积核组合)作为实验超参数。观察图6(b)可知, D 对误差呈现容量-泛化折中,较小 D 限制表征容量,较大 D 引入冗余通道并增大优化难度与过拟合风险,且会改变GroupSE2的分组粒度($\text{groups}=D$),影响重标定的细粒度程度,本文在综合误差最小与结构耦合一致性后取 $D=256$ 。综上,针对本文任务确定超参数为 $P=16$ 、 $D=256$,并在后续实验中保持一致。

3.5 对比实验的分析与讨论

本文对同一训练集优化超参数配置下训练得到的PatchTST、ModernTCN、FEDformer、DLinear、TimesNet以及GEMS-TCN模型在测试

集上开展了对比实验, 1#电机特征预测结果对比如图7所示。

固定翼无人机状态变化主要受高空环境影响, 而其所处临近空间的热环境和风场条件波动具有明显的昼夜差异^[31]。因此, 为验证模型在不同环境下的泛化性, 对比模型在白天、黑夜不同工况下的预测精度差异, 本文依据05:10-06:00和19:15-20:00两段模糊过渡时段划分出白天段与黑夜段。图7对模型预测结果进行了可视化, 白天段中, 电压与温度在推力跃升、工况切换处存在相对强的短时扰动, 本模型对转折位置的对齐更精确、超调与毛刺更

小; 黑夜段中, 温度缓变、噪声更弱但易出现长期漂移, 本模型依旧能保持更低的系统性偏差与更好的趋势跟踪。

计算各模型三项误差指标详见表4, 对比之下, GEMS-TCN在白天、黑夜及全天的误差指标均为最优或次优。相较面向短时预测任务的最优模型TimesNet, 本模型在16维特征全天MAE和SMAPE与其保持基本一致的精度水平, 同时MSE达到0.069, 实现了28.1%的显著降幅, 具备优良的预测精度。同时, 不同于PatchTST、FEDformer和DLinear等模型在白天、夜晚时段预测精度的明





图 6 GEMS-TCN模型关键超参数单因素敏感性分析(指标选用MAE、MSE, 其余训练参数设置保持一致)



注: 测试集数据总采集时长约24小时, 图中黄色、蓝色和灰色区分别表示测试集中白天时段、黑夜时段及模糊过渡时段。

图 7 1#电机特征预测结果对比图

表 4 模型预测精度对比

方法	特征	MAE			MSE			SMAPE		
		白天	夜晚	全天	白天	夜晚	全天	白天	夜晚	全天
PatchTST	A	0.406	0.322	0.371	0.303	0.174	0.249	0.115	0.025	0.078
	B	0.269	0.261	0.265	0.128	0.105	0.117	0.001	0.001	0.001
	C	0.546	0.417	0.494	0.476	0.264	0.389	0.188	0.065	0.131
	W	0.482	0.352	0.427	0.435	0.211	0.338	0.144	0.012	0.093
	P	0.326	0.256	0.298	0.175	0.117	0.153	0.127	0.023	0.086
ModernTCN	A	0.330	0.260	0.303	0.230	0.130	0.190	0.110	0.019	0.071
	B	0.278	0.218	0.253	0.152	0.091	0.126	0.001	0.001	0.001
	C	0.221	0.198	0.211	0.092	0.068	0.082	0.148	0.043	0.097
	W	0.491	0.320	0.425	0.453	0.189	0.349	0.159	0.012	0.100
	P	0.331	0.306	0.323	0.221	0.170	0.204	0.133	0.022	0.087
FEDformer	A	0.224	0.142	0.186	0.226	0.091	0.162	0.088	0.016	0.058
	B	0.204	0.157	0.182	0.153	0.083	0.120	0.001	0.001	0.001
	C	0.140	0.116	0.130	0.092	0.076	0.085	0.133	0.040	0.087
	W	0.355	0.153	0.263	0.517	0.106	0.324	0.109	0.006	0.072
	P	0.196	0.144	0.170	0.141	0.097	0.119	0.109	0.016	0.072
DLinear	A	0.247	0.194	0.224	0.128	0.071	0.103	0.100	0.017	0.065
	B	0.184	0.175	0.179	0.095	0.071	0.084	0.001	0.001	0.001
	C	0.215	0.188	0.204	0.081	0.059	0.072	0.149	0.043	0.098
	W	0.358	0.214	0.296	0.243	0.087	0.174	0.132	0.008	0.083
	P	0.231	0.198	0.216	0.093	0.067	0.081	0.119	0.017	0.077
TimesNet	A	0.178	0.122	0.152	0.126	0.061	0.096	0.085	0.014	0.055
	B	0.173	0.153	0.163	0.108	0.079	0.094	0.001	0.001	0.001
	C	0.126	0.098	0.114	0.068	0.050	0.060	0.133	0.036	0.085
	W	0.263	0.126	0.200	0.257	0.066	0.167	0.102	0.005	0.067
	P	0.148	0.111	0.130	0.071	0.050	0.061	0.104	0.014	0.068
GEMS-TCN(Ours)	A	0.189	0.150	0.171	0.085	0.051	0.069	0.092	0.015	0.059
	B	0.155	0.151	0.153	0.081	0.066	0.073	0.001	0.001	0.001
	C	0.153	0.125	0.141	0.053	0.036	0.045	0.139	0.037	0.089
	W	0.254	0.174	0.220	0.133	0.055	0.097	0.114	0.006	0.072
	P	0.191	0.149	0.171	0.074	0.047	0.061	0.113	0.015	0.073

注：特征列中A代表1#-4#电机完整16维特征，而B、C、W、P分别代表1#-4#电机的母线电压、控制单元温度、绕组温度以及功率器件温度。

显差异，本模型全维特征在昼夜段的MAE和MSE分别为0.189、0.150和0.085、0.051，不同时段预测值精度基本一致，展现出对工况变化的鲁棒性。此外，本模型不仅在1#-4#电机完整16维特征(A)预测上保持优势，针对四类(B、C、W、P)单特征预测也同样表现较优，全天MSE分别为0.073、0.045、0.097和0.061，展现出对不同时间常数物理量普适的预测能力。

为进一步从数据掉点、随机噪声及局部传感器失效等角度评估模型鲁棒性，本文在标准化后的测试集上构造了1%和5%的随机掉点、标准差为0.05和0.1的高斯噪声注入以及60 s连续缺失等扰动场景，其中连续缺失由1#电机4个待预测特征分别

模拟测试后取均值。由表5可见，GEMS-TCN在无扰动时取得最低MSE，且在随机掉点与连续缺失场景下误差变化极小，MSE均小于0.07，表明所提方法对局部数据缺失和短时传感器异常具有较强稳定性。然而，在两组高斯噪声扰动下，各模型误差均显著增大，GEMS-TCN虽未表现为最优，但其在无扰动及缺失类扰动下的优势依然明显。上述结果表明，方法在数据缺失与短时掉点场景中具有较强鲁棒性，同时也说明针对强随机噪声干扰的稳健性仍有进一步提升空间。

实际部署结果表明，GEMS-TCN参数量为27.88 M，单样本计算量为641.12 MMACs。虽然其模型规模大于DLinear等轻量方法，但推

表 5 模型鲁棒性对比(MSE)

模型	无扰动	数据掉点(1%)	数据掉点(5%)	高斯噪声(0.05)	高斯噪声(0.1)	连续缺失(60s)
PatchTST	0.2493	0.2493	0.2496	2.4646	9.1779	0.2493
ModernTCN	0.1903	0.1903	0.1904	2.1375	8.0099	0.1903
FEDformer	0.1623	0.1623	0.1622	2.0433	7.7212	0.1623
DLinear	0.1026	0.1026	0.1028	2.0310	7.8473	0.1026
TimesNet	0.0956	0.0956	0.0956	2.0407	7.8970	0.0956
GEMS-TCN(Ours)	0.0693	0.0694	0.0697	2.2460	8.8151	0.0693

理延迟远低于1 s采样周期，具备实时部署能力。与TimesNet相比，GEMS-TCN在保持较高预测精度的同时，将单样本推理时间由2.81 ms缩短至0.90 ms，降幅约68.1%，体现出更优的精度效率折中，更适合面向工程场景的在线部署。

GEMS-TCN的综合实验表现主要来源于其架构设计与推进系统状态演化特性的匹配。一方面，MsE能够在不同时间感受野下提取特征，使模型兼顾母线电压等变量的短时波动和温度类变量的缓慢演化，从而提升对工况切换及不同特征的代表能力；另一方面，GroupSE在变量内和跨变量两个层次进行通道权重标定，有助于突出与预测目标关联性更强的特征，削弱弱相关及扰动特征的影响。同时，上述两方面设计使模型在随机掉点和连续缺失场景下能够利用邻近时间步及相关变量进行信息补偿，从而表现出较好的缺失鲁棒性。总体而言，GEMS-TCN能够更充分地利用多变量耦合信息，并在预测精度、工况适应性、缺失鲁棒性和实时推理效率之间取得较好的平衡。

3.6 消融实验的分析与讨论

为验证各模块对模型性能的具体贡献，本文在同一数据集与训练配置下设计了系列消融实验。以ModernTCN作为基线模型，逐步引入多尺度嵌入层与分组通道注意力，并比较不同组合下模型的预测精度差异。实验结果详见表6。

消融实验结果表明，仅引入多尺度嵌入(Model1)即可使MAE由0.303降至0.199，降幅达34.3%，说明分频提取、扩大有效感受野对多时间常数特征的并行表征十分关键；仅加入分组通道注意力(Model2)时，MAE由0.303降至0.219，降幅达27.7%，表

明特征权重重标定也能够有效抑制噪声信号，提高对关键特征的注意力。两者配合(Model3)产生互补效应，MAE进一步降至0.171，优于任一单独改进，进一步佐证了GEMS-TCN架构设计的合理性。

4 结束语

面向长航时固定翼无人机推进系统的母线电压、控制单元温度、绕组温度、功率器件温度等关键状态的预测需求，本文优化设计出一种融合多尺度嵌入与分组通道注意力的状态预测方法(GEMS-TCN)。在基于实飞工作状态数据的单步预测实验中，本文方法的MAE、MSE分别达到0.171、0.069，同时在昼夜工况切换、不同特征类别及数据缺失场景下均展现出良好的鲁棒性，显示出该方法在长航时固定翼无人机健康监测、故障预警与自主健康管理等方面广阔的应用前景。

参考文献

- [1] PAL O K, SHOVON M S H, MRIDHA M F, *et al.* In-depth review of AI-enabled unmanned aerial vehicles: Trends, vision, and challenges[J]. *Discover Artificial Intelligence*, 2024, 4(1): 97. doi: [10.1007/s44163-024-00209-1](https://doi.org/10.1007/s44163-024-00209-1).
- [2] RAI S, RAWAT A, and KUMAR A. Design and performance analysis of high-altitude UAVs: Trends, challenges, and innovations[J]. *Discover Applied Sciences*, 2025, 7(8): 833. doi: [10.1007/s42452-025-07357-8](https://doi.org/10.1007/s42452-025-07357-8).
- [3] TANG Liang, SAXENA A, and YOUNSI K. Prognostics and health management for electrified aircraft propulsion: State of the art and challenges[J]. *Journal of Engineering for Gas Turbines and Power*, 2025, 147(4): 041018. doi: [10.1115/1.4066598](https://doi.org/10.1115/1.4066598).
- [4] ADAIKA Z, AL-HADDAD L A, GIERNACKI W, *et al.* Fault detection and diagnosis methodologies for unmanned aerial vehicles: State-of-the-art[J]. *Journal of Intelligent & Robotic Systems*, 2025, 111(2): 63. doi: [10.1007/s10846-025-02267-8](https://doi.org/10.1007/s10846-025-02267-8).
- [5] GONG Wenquan, LI Bo, AHN C K, *et al.* Prescribed-time extended state observer and prescribed performance control of quadrotor UAVs against actuator faults[J]. *Aerospace*

表 6 不同模块对预测精度的影响

模型	Multi-Scale Embedding	GroupSE	MAE	MSE
ModernTCN	×	×	0.303	0.190
Model1	✓	×	0.199	0.085
Model2	×	✓	0.219	0.098
Model3	✓	✓	0.171	0.069

- Science and Technology*, 2023, 138: 108322. doi: [10.1016/j.ast.2023.108322](https://doi.org/10.1016/j.ast.2023.108322).
- [6] ZHOU Laihong, JIN Hong, CHEN Ping, *et al.* Actuator fault detection method of quadrotor UAV based on dual channel inertial sensors[J]. *Discover Applied Sciences*, 2025, 7(7): 736. doi: [10.1007/s42452-025-07403-5](https://doi.org/10.1007/s42452-025-07403-5).
- [7] LIANG Shaojun, ZHANG Shirong, HUANG Yuping, *et al.* Data-driven fault diagnosis of FW-UAVs with consideration of multiple operation conditions[J]. *ISA Transactions*, 2022, 126: 472–485. doi: [10.1016/j.isatra.2021.07.043](https://doi.org/10.1016/j.isatra.2021.07.043).
- [8] ZHANG Yizong, LI Shaobo, ZHANG Ansi, *et al.* FW-UAV fault diagnosis based on knowledge complementary network under small sample[J]. *Mechanical Systems and Signal Processing*, 2024, 215: 111418. doi: [10.1016/j.ymssp.2024.111418](https://doi.org/10.1016/j.ymssp.2024.111418).
- [9] GUO Kai, WANG Na, LIU Datong, *et al.* Uncertainty-aware LSTM based dynamic flight fault detection for UAV actuator[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3502113. doi: [10.1109/TIM.2022.3225040](https://doi.org/10.1109/TIM.2022.3225040).
- [10] CHU Xiaoyan, ZHOU Xu, BU Qixuan, *et al.* Sensor fault detection for UAVs using improved self-attention LSTM network with similarity space mapping[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 3528612. doi: [10.1109/TIM.2024.3450064](https://doi.org/10.1109/TIM.2024.3450064).
- [11] WANG Shengdong, JIA Zhen, LIU Zhenbao, *et al.* Self-supervised contrast learning based UAV fault detection and interpretation with spatial-temporal information of multivariate flight data[J]. *Expert Systems with Applications*, 2025, 267: 126156. doi: [10.1016/j.eswa.2024.126156](https://doi.org/10.1016/j.eswa.2024.126156).
- [12] FANG Jie, LI Shaobo, ZHANG Yizong, *et al.* Fault diagnosis of UAV sensors based on multi-auxiliary task learning with few samples[J]. *Journal of Computational Design and Engineering*, 2025, 12(12): 142–160. doi: [10.1093/jcde/qwaf117](https://doi.org/10.1093/jcde/qwaf117).
- [13] 张景森, 侯彪, 李志杰, 等. 结合姿态不变性特征和半监督复兴稠密生成对抗分类网络模型的飞控系统故障诊断方法[J]. *电子与信息学报*, 2026, 48(1): 264–276. doi: [10.11999/JEIT250964](https://doi.org/10.11999/JEIT250964).
- ZHANG Jingsen, HOU Biao, LI Zhijie, *et al.* A fault diagnosis method for flight control systems combining pose-invariant features and a semi-supervised RDC-GAN model[J]. *Journal of Electronics & Information Technology*, 2026, 48(1): 264–276. doi: [10.11999/JEIT250964](https://doi.org/10.11999/JEIT250964).
- [14] 潘金伟, 王乙乔, 钟博, 等. 基于统计特征搜索的多元时间序列预测方法[J]. *电子与信息学报*, 2024, 46(8): 3276–3284. doi: [10.11999/JEIT231264](https://doi.org/10.11999/JEIT231264).
- PAN Jinwei, WANG Yiqiao, ZHONG Bo, *et al.* Statistical feature-based search for multivariate time series forecasting[J]. *Journal of Electronics & Information Technology*, 2024, 46(8): 3276–3284. doi: [10.11999/JEIT231264](https://doi.org/10.11999/JEIT231264).
- [15] 杨真真, 徐奕, 万成业, 等. 融合多尺度频域适配器和双路注意力的时序预测[J]. *电子与信息学报*, 2026, 48(4): 1795–1805. doi: [10.11999/JEIT251188](https://doi.org/10.11999/JEIT251188).
- YANG Zhenzhen, XU Yi, WAN Chengye, *et al.* Multi-scale frequency adapter and dual-path attention for time series forecasting[J]. *Journal of Electronics & Information Technology*, 2026, 48(4): 1795–1805. doi: [10.11999/JEIT251188](https://doi.org/10.11999/JEIT251188).
- [16] NIE Yuqi, NGUYEN N H, SINTHONG P, *et al.* A time series is worth 64 words: Long-term forecasting with transformers[C]. The Eleventh International Conference on Learning Representations, Kigali, Rwanda, 2023.
- [17] WU Haixu, HU Tengge, LIU Yong, *et al.* TimesNet: Temporal 2D-variation modeling for general time series analysis[C]. The Eleventh International Conference on Learning Representations, Kigali, Rwanda, 2023.
- [18] ZENG Ailing, CHEN Muxi, ZHANG Lei, *et al.* Are transformers effective for time series forecasting?[C]. Proceedings of the 37th AAAI Conference on Artificial Intelligence, Washington, USA, 2023: 11121–11128. doi: [10.1609/aaai.v37i9.26317](https://doi.org/10.1609/aaai.v37i9.26317).
- [19] LUO Donghao and WANG Xue. ModernTCN: A modern pure convolution structure for general time series analysis[C]. The Twelfth International Conference on Learning Representations, Vienna, Austria, 2024: 1–43.
- [20] SZEGEDY C, LIU Wei, JIA Yangqing, *et al.* Going deeper with convolutions[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, USA, 2015: 1–9. doi: [10.1109/CVPR.2015.7298594](https://doi.org/10.1109/CVPR.2015.7298594).
- [21] HU Jie, SHEN Li, and SUN Gang. Squeeze-and-excitation networks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 7132–7141. doi: [10.1109/CVPR.2018.00745](https://doi.org/10.1109/CVPR.2018.00745).
- [22] HOWARD A G, ZHU Menglong, CHEN Bo, *et al.* MobileNets: Efficient convolutional neural networks for mobile vision applications[EB/OL]. <https://arxiv.org/abs/1704.04861>, 2017. doi: [10.48550/arXiv.1704.04861](https://doi.org/10.48550/arXiv.1704.04861).
- [23] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016: 770–778. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- [24] IOFFE S and SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. Proceedings of the 32nd International

- Conference on Machine Learning, Lille, France, 2015: 448–456.
- [25] LUO Wenjie, LI Yujia, URTASUN R, *et al.* Understanding the effective receptive field in deep convolutional neural networks[C]. Proceedings of the 30th International Conference on Neural Information Processing Systems, Barcelona, Spain, 2016: 4905–4913.
- [26] ALCIBAR J, AIZPURUA J I, ZUGASTI E, *et al.* A hybrid probabilistic battery health management approach for robust inspection drone operations[J]. *Engineering Applications of Artificial Intelligence*, 2025, 146: 110246. doi: [10.1016/j.engappai.2025.110246](https://doi.org/10.1016/j.engappai.2025.110246).
- [27] YANG Mengchen and PHUNG B T. Motor winding insulation degradation under repetitive voltage pulses[J]. *IEEE Access*, 2024, 12: 77658–77674. doi: [10.1109/ACCESS.2024.3406490](https://doi.org/10.1109/ACCESS.2024.3406490).
- [28] ZHOU Tian, MA Ziqing, WEN Qingsong, *et al.* FEDformer: Frequency enhanced decomposed transformer for long-term series forecasting[C]. Proceedings of the 39th International Conference on Machine Learning, Baltimore, USA, 2022: 27268–27286.
- [29] WANG Yuxuan, WU Haixu, DONG Jiaxiang, *et al.* Deep time series models: A comprehensive survey and benchmark[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2026: 1–20. doi: [10.1109/TPAMI.2026.3690845](https://doi.org/10.1109/TPAMI.2026.3690845).
- [30] KINGMA D and BA J. Adam: A method for stochastic optimization[C]. 3rd International Conference on Learning Representations, San Diego, USA, 2015.
- [31] SWEENEY A J and FU Qiang. Diurnal cycles of synthetic microwave sounding Lower-stratospheric temperatures from radio occultation observations, reanalysis, and model simulations[J]. *Journal of Atmospheric and Oceanic Technology*, 2021, 38(12): 2045–2059. doi: [10.1175/JTECH-D-21-0071.1](https://doi.org/10.1175/JTECH-D-21-0071.1).
- 李思成：男，硕士生，研究方向为固定翼无人机状态预测、时序数据建模与深度学习，邮箱：15533151020@163.com。
- 王连清：男，副教授，研究方向为飞行器状态监测、故障诊断及健康管理，邮箱：lianqingw@126.com。
- 李志永：男，副研究员，研究方向为大数据分析及应用，邮箱：zhiyongli@aircas.ac.cn。
- 王国昌：男，硕士生，研究方向为大数据分析及应用。
- 葛凯华：男，高级工程师，研究方向为飞行器推进系统试验测试、状态监测与故障诊断。
- 陈俊锋：男，高级工程师，研究方向为无人机系统应用、飞行状态监测与故障预警。
- 谭荣清：男，研究员，研究方向为激光技术及应用。

责任编辑：廖海贝

A State Prediction Method for Long-Endurance Fixed-Wing UAV Propulsion Systems

LI Sicheng^{①②③} WANG Lianqing^{③④} LI Zhiyong^{①②} WANG Guochang^{①②}
GE Kaihua^⑤ CHEN Junfeng^⑥ TAN Rongqing^{①②}

^①(Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China)

^②(School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049, China)

^③(College of Intelligent Science, National University of Defense Technology, Changsha 410073, China)

^④(Department of Command and Control Support, Information Support Force Engineering University, Wuhan 430030, China)

^⑤(Innovation and Application Center, China Academy of Aerospace Aerodynamics, Beijing 100074, China)

^⑥(Unit 92728, Chinese People's Liberation Army, Shanghai 200436, China)

Abstract:

Objective Accurate single-step prediction of key propulsion-system states is essential for early fault warning and autonomous health management of long-endurance fixed-wing unmanned aerial vehicles (UAVs). During high-altitude missions lasting more than 24 h, electrical and thermal variables in the propulsion system exhibit strong coupling, multi-time-constant dynamics, and pronounced day-night regime shifts. These characteristics cause short-term disturbances and long-term drifts to coexist, and hinder adaptive feature weighting under time-varying variable sensitivities. General-purpose time-series predictors may therefore fail to meet the accuracy and robustness requirements of multivariate propulsion-state prediction. To address these challenges, a

Grouped Squeeze-and-Excitation Multi-scale Temporal Convolutional Network (GEMS-TCN) is developed by enhancing a modern pure-convolution forecasting backbone with multi-scale embedding and grouped channel attention. The aim is to obtain accurate 10 s-ahead single-step forecasts for 16 key propulsion states from 72-dimensional flight telemetry while satisfying the real-time inference requirement of the 1 Hz telemetry cycle.

Methods Real flight telemetry from a representative long-endurance fixed-wing UAV is used for model construction and evaluation. The data are sampled at 1 Hz for 9 consecutive days, yielding 806,629 time steps and 72 variables. (Fig.2) Sixteen propulsion-related key states, including the bus voltage, control-unit temperature, winding temperature, and power-device temperature of four motors, are selected as prediction targets, and all 72 variables are used as inputs. (Table 1) The raw data are processed through time indexing, interquartile range (IQR)-based anomaly handling, and interpolation, and are then chronologically divided into training, validation, and test sets at a ratio of 8:1:1 to avoid information leakage. (Fig.4) (Fig.5) GEMS-TCN uses a multi-scale embedding layer with parallel one-dimensional convolutions to extract temporal patterns at different receptive-field scales. Stacked GEMS-TCN blocks combine depthwise temporal convolution, grouped convolutional feed-forward networks, and Grouped Squeeze-and-Excitation (GroupSE) modules to recalibrate intra-variable and cross-variable channel responses hierarchically. (Fig.1) The models are trained with Adam and mean squared error (MSE) loss, and are evaluated using mean absolute error (MAE), MSE, and symmetric mean absolute percentage error (SMAPE). PatchTST, ModernTCN, FEDformer, DLinear, and TimesNet are used as comparison models, with ablation and robustness experiments conducted for further verification.

Results and Discussions On the full 16-dimensional target set, GEMS-TCN achieves a test-set MAE of 0.171 and an MSE of 0.069. (Table 4) Compared with TimesNet, the strongest baseline in overall trend tracking, GEMS-TCN reduces MSE by 28.1% while maintaining comparable MAE and SMAPE, indicating stronger suppression of large prediction deviations. (Table 4) Stable accuracy is obtained in both daytime and nighttime segments, with MAE/MSE values of 0.189/0.085 and 0.150/0.051, respectively, demonstrating robustness to diurnal operating-condition changes. (Table 4) The prediction trajectories show tighter alignment at thrust-transition points, reduced overshoot, and fewer spurious spikes, while low-bias tracking is preserved for slowly varying nighttime temperature profiles. (Fig.7) Ablation results show that multi-scale embedding and GroupSE provide complementary improvements, and their combination achieves the best overall performance among the ablation settings. (Table 6) Under 1% and 5% random dropouts and 60 s continuous missing intervals, the MSE remains below 0.07, indicating tolerance to practical data-loss scenarios. (Table 5) In addition, GEMS-TCN contains 27.88 M parameters and achieves an inference latency of 0.90 ms per sample, which is well below the 1 s sampling interval.

Conclusions GEMS-TCN provides a practical convolution-based solution for multivariate propulsion-state prediction in long-endurance fixed-wing UAVs. By integrating multi-scale temporal embedding with hierarchical group-wise channel recalibration, the proposed method jointly represents rapid fluctuations and slow evolution, and better captures multi-time-constant dynamics and multivariate coupling in propulsion telemetry. Real-flight experiments demonstrate stable prediction performance across diurnal regimes, state categories, and data-missing scenarios. Ablation results further confirm the effectiveness and complementarity of multi-scale embedding and GroupSE. These findings indicate that structure-aware modeling tailored to propulsion-state evolution can support health monitoring, early fault warning, and autonomous health management of long-endurance fixed-wing UAVs.

Key words: Fixed-wing UAV; State prediction; Temporal convolutional network; Multi-scale embedding; Grouped channel attention