



DOI: 10.12382/bgxb.2022.0615

一种基于 TCN-LGBM 的航空发动机气路故障诊断方法

吕卫民*, 孙晨峰, 任立坤, 赵杰, 李永强
(海军航空大学, 山东 烟台 264000)

摘要: 长时间工作在高温高压、强振动等恶劣气路环境下的航空发动机经常面临部件疲劳、腐蚀和性能退化的问题,且其故障诊断时序逻辑性不强、故障参数耦合较深等特点十分明显,为此提出一种基于时间卷积神经网络(Temporal Convolutional Network, TCN)和轻量级梯度提升机(Light Gradient Boosting Machine, LGBM)的航空发动机气路故障诊断方法。故障诊断分为故障特征提取和分类诊断两个过程:引入 TCN 框架,在保证故障数据训练时序逻辑的基础上,实现对远层历史信息 and 当前层信息的特征融合构建,融合通道注意力机制增强了高质量特征的权重;基于 LGBM 模型实现对特征的快速分类,利用贝叶斯方法实现对模型超参数的快速优化。以基于 PROOSIS 软件建模的某军用小涵道比涡扇发动机故障仿真数据为例,对 6 种故障模式进行诊断识别。仿真结果表明了所提方法的有效性;通过与其他模型对比体现了该方法的优越性。

关键词: 航空发动机; 故障诊断; 时间卷积神经网络; 轻量级梯度提升机; 注意力机制
中图分类号: V267 **文献标志码:** A **文章编号:** 1000-1093(2024)01-0253-11

A Gas Path Fault Diagnosis Method for Aero-engine Based on TCN-LGBM Model

LÜ Weimin*, SUN Chenfeng, REN Likun, ZHAO Jie, LI Yongqiang
(Naval Aviation University, Yantai 264000, Shandong, China)

Abstract: With the obvious characteristics of poor temporal logic in fault diagnosis and the strongly coupled feature parameters, the aero-engines working in the hostile gas path conditions of high temperature, pressure and strong vibration face with the degradation performance and structure defect problems such as fatigue and corrosion. And an aero-engine gas path fault diagnosis method based on temporal convolutional networks (TCN) and light gradient boosting machine (LGBM) is proposed to provide a feasible solution to the problems above. The diagnosis process can be divided into feature extraction and classification; TCN is introduced to guarantee the fault diagnosis training temporal logic and achieve the features fusion of distant layers and current layers, which is also strengthened by channel attention mechanism; the features are quickly classified based on LGBM model, and the Bayesian method is used to quickly optimize the model hyperparameters. Based on the aero-engine performance modelled by PROOSIS software, six types of fault mode are diagnosed and identified by taking a military low-bypass ratio turbofan engine as an example. The results indicate that the proposed model is effective for fault diagnosis and shows the superiority by comparing with other models.

收稿日期: 2022-07-07

基金项目: 山东省自然科学基金项目(ZR2021QE193)

* 通信作者邮箱: 13963826998@139.com

Keywords: aero-engine; fault diagnosis; temporal convolutional network; light gradient boosting machine; attention mechanism

0 引言

航空发动机是为飞行器提供动力的关键设备,也是战机正常执行飞行任务、有效履行职责使命的根本保证。作为一种结构精密、多学科技术集成的复杂机电系统,航空发动机工作状态下外受云层雨雾等运行环境的长期影响,内受高温高压、振动等恶劣气路条件的耦合作用,导致发动机常由于疲劳或腐蚀等原因产生性能退化,以及由于部件断裂或外物飞入造成机械损伤^[1]。发动机各部件及分系统的异常会进一步导致发动机推力下降和运行效率的降低,若未能及时准确地发现故障隐患、确定故障模式、实现故障隔离,可能造成巨大的经济损失和严重的飞行事故,直接影响飞行安全和任务可靠性水平。因此研究快速准确的航空发动机故障诊断方法,对于监测发动机健康状态变化、制定精准经济的维修保障策略,具有十分重要的意义^[2]。

航空发动机等多元退化设备故障按照时间特性可分为突发性故障和退化性故障两类^[2-4]。突发性故障由于部件功能突然丧失而直接导致发动机熄火停车,其在运行过程中故障逻辑不可控、故障过程不具备可测试性,因此本文中的故障主要是指发动机在使用过程中多部件受腐蚀、侵蚀、结垢等失效作用并沿气路叠加所引发的渐进式故障模式,此类故障状态过程可监测、具有一定的规律性,能够通过早期的状态运行数据进行预测管理。从气路故障特点来看,基于数据驱动的气路分析方法适用于关注上述因部件退化导致气路性能降级的失效模式,当气路监测性能水平低于不同等级阈值时,即可认为发生不同程度的故障并开展相应模式识别和故障诊断工作;从具体实践来看,故障诊断领域的数据大多来自于多维传感器的采集,属于典型的一维时间序列,因此对相关装备的故障诊断分析和剩余寿命预测,又可以抽象为时间序列分类及预测问题。

目前对该问题的研究热点多属于深度学习范畴,并进一步分为基于一维时序数据特征分类^[5-9]和基于二维时频域图像特征识别^[10-12]两种故障诊断方式。对多维传感器数据直接进行特征提取和分类,是利用不同网络在卷积运算效率、历史信息存储、梯度消失缓解上的优势,结合多传感器融合策略^[5]、注意力机制^[7]、软阈值和超参数自动选择^[8]

等方法进一步提高特征提取的鲁棒性和可解释性,增强分类的速度和准确度。作为描述数据信号的基本性质,时频域图像分析方法的拓展为故障诊断分类提供了更多特征细节和应用前景。邓飞跃等^[10]基于上述思想,以 Howard 等^[13]提出的轻量级网络 Shuffle Net 为基本模块搭建故障诊断模型,有效减少了参数数量和算力需求,并为选择硬件配置、满足移动端使用提供了可行的思路。潘宏侠等^[11]通过时频图灰度处理,进一步丰富了特征提取的纹理细节。Shokrolahi 等^[12]选择功率谱密度实部等信号特征作为卷积神经网络(Convolutional Neural Networks, CNN)模型的输入图像,验证了方法的优越性。同时,为了有效回应数据驱动模型方法的黑盒问题,增强模型特征提取及分类的可解释性,许多学者也在故障诊断方法中采用了降维聚类的方式,对提取的高维特征进行低维可视化,从而对不同故障类型有直观上的差异感受。

以上研究在准确度、召回率等多个分类指标上取得了不俗的诊断效果,但 CNN、循环神经网络(Rerrent Neural Network, RNN)、长短期记忆网络(Long Short Term Memory, LSTM)等时间序列模型往往采用所有时间序列数据训练每一时刻输出的模型参数,理论上不符合对未来时序预测的逻辑规律^[14],从而对当前时刻预测存在未来信息泄露问题,且随着网络深度的增加,LSTM 等记忆网络也会逐步遗忘其认为不重要的、来自较远网络层中的特征信息(即历史特征遗漏问题),进一步降低了特征提取的质量,历史特征的时序记忆性不够好;同时深度学习需要进行大量的参数计算,其在高维特征提取和深层网络训练过程中有时表现出分类准确率低和梯度消失的问题,而大多数分类网络常使用全连接层搭配 Softmax 等激活函数实现多分类的概率输出,其线性分类能力一定程度上不如支持向量机、梯度提升决策树等非线性映射方法,因此不少学者将深度学习模型和机器学习方法相结合应用于相关领域,从而在组合模型中取得了优于单个模型的综合效果^[15-17]。

为了有效处理复杂多元的航空发动机故障数据,本文针对其训练过程时序逻辑不强、特征信号耦合程度高等问题,提出了一种基于时间卷积神经网络(Temporal Convolutional Network, TCN)和轻量级

梯度提升机 (Light Gradient Boosting Machine, LG-BM) 的航空发动机故障诊断方法: 基于注意力机制融合策略实现 TCN 对故障特征的有效提取, 结合贝叶斯优化方法实现 LGBM 对特征的快速分类。最后以某军用小涵道比涡扇发动机故障仿真数据为例进行故障诊断实验, 验证了框架的有效性。

1 基于 SE-TCN 模型的时序特征提取

1.1 TCN 模型

TCN 是基于 CNN 进行改进优化、融合因果卷积、空洞卷积和残差连接的时序数据处理模型, 相较于其他理论模型, 其在训练时序数据过程中设置了严格的历史因果关系, 能实现理论层面时序逻辑的严密和完整, 有效解决现有故障诊断算法存在的训练时序逻辑性不强的问题。

TCN 框架在序列建模任务中强调了时序预测的历史因果关系, 即假设给定输入 x_0, x_1, \dots, x_T , T 为时间序列, 以及期望的相应输出序列 y_0, y_1, \dots, y_T , 约束对 y_T 进行输出预测时, 仅能使用相同时间步以及更早的观察序列, 而非利用完整数据序列进行模型训练^[14]。建立模型函数 $f: x_T \rightarrow y_T$, 从而有

$$\hat{y}_0, \dots, \hat{y}_T = f(x_0, \dots, x_T) \quad (1)$$

式中: \hat{y}_T 表示输出序列的估计值。

一维全卷积网络 (1D FCN) 和因果卷积模块细化了上述模型约束的运算机制: 通过零填充的方式确保每一个隐层尺寸与输入尺寸相同 (认为第 1 个时间步输入的历史信息为零并进行计算); 且在当前时刻 T 下的输出仅来自于对当前层及历史层进行的卷积计算, 从而达到历史数据不遗漏、未来信息不泄露的记忆效果。模型^[18] 如图 1 所示。




图 1 1D FCN 模型结构图

Fig. 1 Structure graph of 1D FCN model

时间序列问题往往要求模型具备对长历史信息的记忆能力, 在有限算力的条件下, TCN 框架提出

结合空洞卷积的计算方式实现对远程时序特征的记忆回顾, 其结构和流程如图 2 和图 3 所示^[14,19]。




图 2 空洞因子 $D=1, 2, 4$ 且滤波器尺寸 $k=3$ 的空洞因果卷积

Fig. 2 A dilated casual convolution with dilated factor $D=1, 2, 4$ and filter size $k=3$

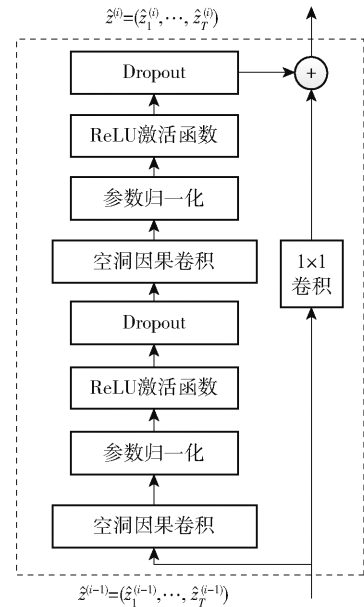


图 3 因果卷积流程

Fig. 3 Causal convolution process

在图 2 中, 空洞卷积通过引入空洞扩张因子 D 在每层卷积计算中跳过指定步长的大小, 进而得以在更大尺寸的滤波器上得到相同尺寸的输出以及更大的接触区域。当进行卷积计算时, 模型通常会随着网络深度的增加, 指数增加空洞扩张因子; 图 2 中任何一个输出都可以以类似 T 时刻数据的方式回溯至输入, 进而表明这种特殊的排列方式能确保卷积核有效关联计算到历史关系中的所有层级与特定输入, 使得网络每层的感受野呈指数级增长, 从而有效利用历史数据中的所有输入。空洞卷积的公式如式 (2) 所示:

$$G(F, X) = (F * X)_{x_t} = \sum_{k=1}^K f_k x_{t-(K-k)D} \quad (2)$$

式中: X 为输入时间序列, $X = \{x_0, x_1, \dots, x_i, \dots, x_T\}$; F 表示大小为 K 的卷积核, $F = \{f_1, f_2, \dots, f_k, \dots, f_K\}$, f_k 表示滤波器的数量。

在卷积尺寸和空洞扩张因子一定的情况下, TCN 通过增大网络深度进一步提高对时序任务的分类预测准确性。图 3 所示残差网络代替了层与层之间的简单连接, 并采用跳跃连接方式将底层特征引入高层进行特征增强并加快训练过程, 对于解决深度网络梯度消失、保持长历史信息具有较好的效果。

1.2 通道注意力机制

CNN 网络在逐层卷积计算过程中, 通过融合感受野中的空间 (H 和 W 维度) 和通道 (C 维度) 信息实现特征构建提取。2017 年提出的 SE-Net 通过显式地建模通道之间的相互依赖性、自适应地重新校准通道特征重要度, 实现了网络效果的增强。SE-Net 具体结构如图 4^[20] 所示。




图 4 SE-Net 结构图

Fig. 4 SE-Net structure graph

SE-Net 主要包括压缩 F_{sq} 和激发 F_{ex} 两个过程, 对于卷积操作 $F_{tr}: X \rightarrow U, X \in \mathbf{R}^{H' \times W' \times C'}$, $U \in \mathbf{R}^{H \times W \times C}$, H', W', C' 为变换后的对应值。若其卷积核为 $V = [v_1, v_2, \dots, v_C]$, 其中 v_C 表示第 C 个卷积核, 则对于输出 $U = [u_1, u_2, \dots, u_C]$, 有 $u_C = v_C * X = \sum_{s=1}^C v_C^s * x^s$, 其中 $*$ 表示卷积计算, x^s 为变量 x 的卷积计算, s 表示卷积核的通道数。

Squeeze 操作通过在特征图上执行全局平均池化的特征聚合策略, 得到当前通道上特征图的全局压缩特征量, 该过程用公式表示为

$$z_C = F_{sq}(u_C) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_C(i, j), z \in \mathbf{R}_C \quad (3)$$

式中: z_C 表示全局压缩特征量。

进一步对全局特征进行 Excitation 操作, 通过两层全连接的瓶颈层结构学习到不同通道间的非线性关系及权重, 并与原特征图相乘加权后作为最终特征, 输入到后续网络层中。具体公式为

$$s = F_{ex}(z_C, W) = \sigma(g(z_C, W)) = \sigma(W_2 \text{ReLU}(W_1 z_C)) \quad (4)$$

$$\tilde{x}_C = F_{scale}(u_C, s_C) = u_C \times s_C \quad (5)$$

式中: $W_1 \in \mathbf{R}^{\frac{C}{r} \times C}$, r 为缩放参数; $W_2 \in \mathbf{R}^{C \times \frac{C}{r}}$; ReLU 表示修正线性单元; g 表示以 sigmoid 非线性函数 σ 控制的门函数; \tilde{x}_C 为得到的最终特征; s_C 为计算得到的非线性权重。

将 SE-NET 插入 TCN 模型中, 能够让模型更加关注权重较大的通道特征、抑制权重小的特征, 从而实现特征提取质量的增强。

2 基于贝叶斯优化的 LGBM

LGBM 是微软基于梯度提升决策树改进提出的分布式决策模型, 其与常用的机器学习算法如 XG-Boost 等相比, 具有计算速度快、运行效率高、占用内存小等明显优势。

LGBM 延续了 Boosting 框架加法模型和前向分布算法的整体思路, 假定训练数据集 $D = \{(x_1, \tilde{y}_1), (x_2, \tilde{y}_2), \dots, (x_N, \tilde{y}_N)\}$, $x_i \in X \in \mathbf{R}$, $\tilde{y}_i \in Y \in \mathbf{R}$, 其中 X 为输入空间、 Y 为输出空间, 则模型可表示为以决策树为基函数的线性组合^[21]:

$$f_M(x) = \sum_{m=1}^M h_m(x; \Theta_m) \quad (6)$$

式中: M 为决策树的数量; $h_m(x; \Theta_m)$ 表示第 m 个决策树, Θ_m 为第 m 个决策树的参数, 参数值通常由经验风险极小化 $\hat{\Theta}_m = \arg \min_{\Theta_m} \sum_{i=1}^N L(\tilde{y}_i, f_m(x_i))$ 进一步确定, $L(\tilde{y}_i, f_m(x_i))$ 表示损失函数, \tilde{y}_i 为上述假定的训练集因变量。

为有效降低模型损失且考虑到不同任务常采用不同的损失函数, 通常选定损失函数负梯度在当前函数 $f(x) = f_{m-1}(x)$ 处的值近似代替残差, 公式为

$$r_{i,m} = - \left[\frac{\partial L(y_i, f(x_i))}{\partial f(x_i)} \right] \Bigg|_{f(x) = f_{m-1}(x)} \quad (7)$$

进而在第 m 棵决策树的节点区域, 根据下列公式计算使损失函数最小化的输出值

$$h_m(x_i; \hat{\Theta}_m) = \arg \min_C \sum_{x_i \in \mathbf{R}_{m,j}} L(y, f_{m-1}(x_i) + C) \quad (8)$$

模型进一步更新为

$$f_m(x) = f_{m-1}(x) + h_m(x_i; \hat{\Theta}_m) \quad (9)$$

最终将初始化决策树与每轮迭代的决策树进行相加, 可以得到学习器为

$$f_M(\mathbf{x}) = \sum_{m=1}^M f_m(\mathbf{x}) \quad (10)$$

模型在具体拟合决策树前,为大幅提高训练速度,采取基于梯度的采样进行样本筛选,并基于互斥特征进行特征捆绑,以减少样本的特征。在决策树拟合过程中,LGBM 将连续的浮点特征值离散为 k 个整数,构造宽度为 k 的直方图,从而可以遍历寻找最优的分割点,大大节省了存储空间,直方图差加速的计算方式也有效提升了训练速度;在节点分裂过程中,采用 leaf-wise 而非 level-wise 的叶子生长策略,通过对具有最大分裂增益的叶子进行分裂,减少

搜索和分裂时间,提高了精度^[21]。

在本文中,将 TCN 提取的航空发动机故障模式时序特征输入 LGBM 模型,利用该模型决策树的组合迭代寻找不同故障模式特征间的最佳分割点,从而有效加快故障分类和诊断速度,实现故障定位和维修工作。

3 基于 TCN-LGBM 的故障诊断框架

3.1 模型网络结构

本文提出的故障诊断模型算法模型结构如图 5 所示,其中每条输入数据包含 n 个特征量。




图 5 TCN-LGBM 模型结构图

Fig. 5 Structure graph of TCN-LGBM model

TCN-LGBM 主要包括输入层、空洞因果卷积层、归一化(Batch Normalization, BN)层、ReLU、残差连接模块、SE 模块、池化层和全连接层等^[22]。空洞因果卷积结合当前与历史信息实现特征融合构建,BN 层提高计算速度,ReLU 单元增加网络稀疏性、缓和过拟合,Dropout 按照一定比例将神经元从网络中丢弃从而降低过拟合风险;上述模块组成一个 TCN 基本单元,残差连接在两个上述单元之后避免可能出现的过拟合性,SE 模块则在残差模块之后提高特征提取的质量,全连接层将输出值送入分类器进行分类。将训练好的模型最后一层的特征输出引入 LGBM 分类器,进一步提高分类的速度和准确性。

3.2 故障诊断流程

本文故障诊断框架的具体流程如图 6 所示。

故障诊断框架的具体步骤为:

1) 故障数据采集。对发动机实际运行或测试中采集的多传感器组合数据进行监测记录,在缺失值填充及异常检测后输入模型;在进行故障特性研究时,也可以基于性能仿真软件进行故障模拟注入,得到不同故障下的性能仿真数据。

2) 多维时序信号归一化。性能监测数据蕴含

丰富的物理结构和故障特性信息,但样本数据量纲标准、激活函数等可能对模型训练造成影响。因此在进行时序数据特征提取前,通过线性函数归一化将数据映射到 $[0, 1]$ 区间内,有效避免因量纲等不同造成对不同通道特征权重的影响,其具体公式为

$$L' = \frac{L - L_{\min}}{L_{\max} - L_{\min}} \quad (11)$$

式中: L' 表示归一化后的数据集; L 表示时序数据集; L_{\max} 、 L_{\min} 分别表示各特征序列中的最大值和最小值。

3) 训练测试集划分与五折交叉验证。按 9:1 的比例划分训练测试集并对 SE-TCN 框架和 LGBM 模型进行训练,通过特征可视化验证特征提取的有效性,进行五折交叉验证从而提高模型的泛化性,将得到的模型最佳参数应用于测试集,对时序数据分类效果及模型拟合情况进行检验。

4) 故障特征提取。在尺寸修剪及零填充的作用下,因果卷积将输入序列映射到相同长度的输出序列,模型在残差连接下使用较深的网络增强感受野,并在空洞卷积计算中回顾历史信息进行特征融合,SE 模块的嵌入能够进一步提高通道特征编码的

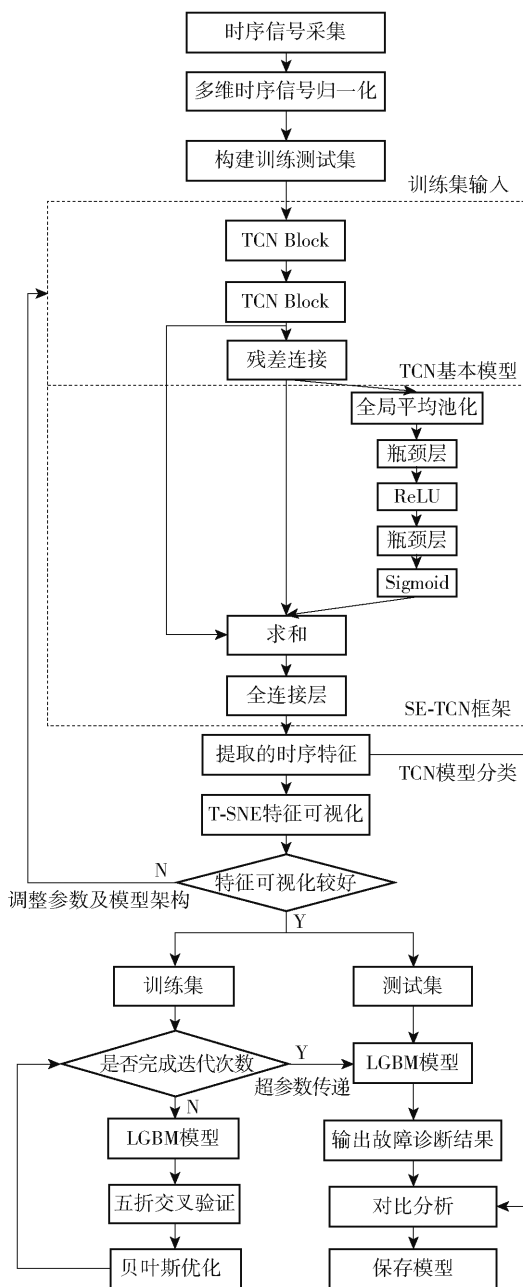


图 6 故障诊断流程

Fig. 6 Flow chart of fault diagnosis

质量,挖掘构建时序数据中的重要特性。

5) 基于贝叶斯优化的故障诊断。基于经验合理设置超参数,根据 TCN 提取的特征训练 LGBM 模型;基于前次运行结果确定超参数搜索范围,利用贝叶斯优化方法进行超参数自动调优,选择平均性能指标最优的模型参数作为模型最终参数。

4 实例分析

4.1 数据采集与预处理

对军用飞机尤其是舰载战斗机而言,对发动机布置传感器进行状态监测常受到安装空间和起飞重

量的限制,想要获得实际运行过程中的状态数据或试验台数据难度较大,并且往往受到保密制度的约束。因此进行发动机性能建模仿真,通过研究典型故障表现实现故障注入和模拟仿真,从而分析数据特征趋势和故障诊断策略,往往更具工程实际价值^[23]。

航空发动机属于高度复杂的气动热力系统,在运行过程中各部件参数耦合关联、故障模式叠加混合,较少存在确定的故障模式分类;且气路故障分析方法主要是基于测量的气路参数对整机或者部件级状态或性能进行推断识别,从而指导外场的部件维护和更换工作。本文结合部队相关经验,考虑到航空发动机的性能故障主要表现为推力下降、推力不稳、发动机排气过热等现象^[3],表现在具体参数上主要是气路部件的效率和流通能力的改变。因此本文基于常见气动参数衰退,对发动机关键部件进行单一故障和部件耦合故障模拟注入,模拟发动机的常见故障表现,为状态监测和预防维修提供决策支持。

本文以某军用小涵道比涡扇发动机为研究对象,基于欧盟第六框架计划中的燃气轮机性能分析工具 PROOSIS 软件进行航空发动机性能建模仿真。该软件是一款面向对象技术建立、具备良好通用性和灵活可拓展性的高保真多领域仿真平台,通过友好的交互式图形用户界面,可以快速实现发动机基准稳态模型搭建,并在有约束、系统集成的作用下实现参数优化和性能退化预测等功能。

某军用小涵道比涡扇发动机主要由二级轴流风扇、八级轴流高压压气机、一级高压涡轮 (High Pressure Turbine, HPT)、环形燃烧室、一级低压涡轮 (Low Pressure Turbine, LPT) 等部件组成,通过全权限数字电子控制器进行控制,建模过程中对发动机关键结构如进气道、风扇、压气机、燃烧室、HPT/LPT、混合室、尾喷管等进行模块定义拓展,最终发动机模型^[24-27]如图 7 所示。

在图 7 所示发动机仿真模型中,参考文献^[28-29]总结的气路故障类型判定规则及该型发动机的性能退化现象和参数偏差表现^[30-31],分别向 HPT、LPT、低压压气机 (Low Pressure Compressor, LPC) 和高压压气机 (High Pressure Compressor, HPC) 注入表 1 所示的退化故障组合 (PC 表示压气机,PT 表示涡轮),模拟发动机在高温高压强振动环境下可能出现的状态模式组合:1、2 状态模式中压气机效率的降低表明可能存在的叶片结垢或叶尖间

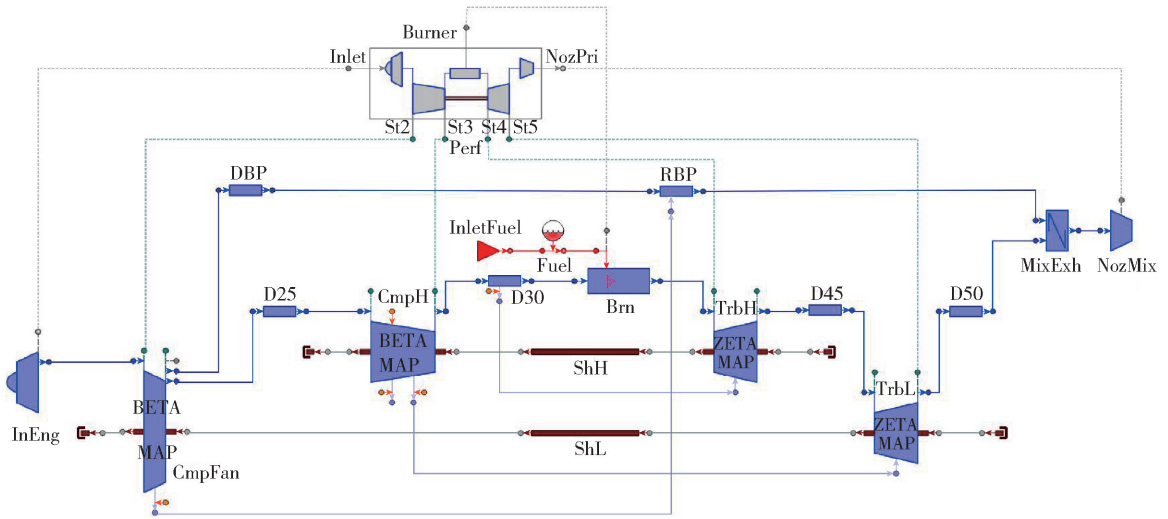


图 7 发动机性能仿真模型

Fig. 7 Aero-engine performance simulation model

表 1 航空发动机故障模式

Table 1 Aero-engine fault mode

故障编号	故障注入部位	故障形式	退化故障组合	潜在失效现象	仿真数据量/条
0		工作运行	无退化		2 000
1	HPC	单部件退化故障	HPC; E0. 92 W0. 92	结垢侵蚀(叶型改变、叶尖间隙增大等) 外来物打伤(凹坑裂纹、叶片变形断裂等) 腐蚀氧化(尖端腐蚀、掉块、结焦积碳等)	300
2	LPC		LPC; E0. 95 W0. 95		
3	PC	多部件耦合故障	LPC; E0. 95 W0. 95 HPC; E0. 92 W0. 92		
4	PC/PT		LPC; E0. 95 W0. 95 HPC; E0. 92 W0. 92 HPT; E0. 95 LPT; E0. 95		
5	PC/PT		LPC; E0. 95 W0. 95 HPC; E0. 92 W0. 92 HPT; E0. 95 W1. 02 LPT; E0. 95 W1. 02		

注:退化故障组合中“Ex. xx”表示效率退化为原来的百分比数,“Wx. xx”表示流量退化为原来的百分比数。

隙增加,3 状态模式中的涡轮效率降低则表征可能因杂质、腐蚀侵蚀造成的叶片变形和氧化;同时应当注意到,故障模式对部件性能及测量参数的影响多是耦合的,并随发动机物理结构和气路分布而在部件上存在不同程度的显性表现和特性影响,在实际仿真过程中,多部件状态下的故障状态识别更贴近实际情况。

模型运行后随机输出发动机整个飞行包线区域内工作点的飞行截面参数,主要包括进气口总温、进气口总压、环境压力、高压转子转速、低压转子转速、燃油流量、LPT 后温度、LPT 后压力、推力,为了避免在整个飞行包线和发动机状态下建造过于庞大的模型,本文考虑通过随机选取整个飞行包线区域内工作点的飞行截面参数进行自动分类学习,认为输出的数据能够代表对不同初始条件下的发动机状态模拟仿真。考虑到发动机输出数据主要是正常数据,因此增加正常运行模式数据参与模型学习训练。

4.2 故障特征提取

将归一化后的发动机故障数据训练集输入到 TCN 模型中进行特征提取,为了检验 TCN 在通道注意力增强下对历史信息回顾和当前信息挖掘的时序特征构建能力,将模型提取的高维特征进行 T-分布随机邻近嵌入(T-SNE)可视化降维,基于“高维空间中的相似点,映射在低维空间中也是邻近的”这一降维思想,通过分析不同故障特征在低维空间中聚类形状、排列位置上的差异化表现反映高维特征提取的效果,并增强后续模型以此分类的可解释性。TCN 模型和 T-SNE 降维参数如表 2 所示。对航空发动机数据的三维、二维特征降维结果如图 8 所示。

数据集每种类别的特征在图中用不同的颜色进行表示,图 8(a)表示将数据直接降至二维平面的结果,图 8(b)表示故障特征三维可视化的结果。从总体分布特征来看,图 8(b)中相同颜色数据点在空间集中散布,不同故障类别点群在空间密集接触,呈现“夹心饼干”状的数据群堆叠结构,侧面说明模拟注

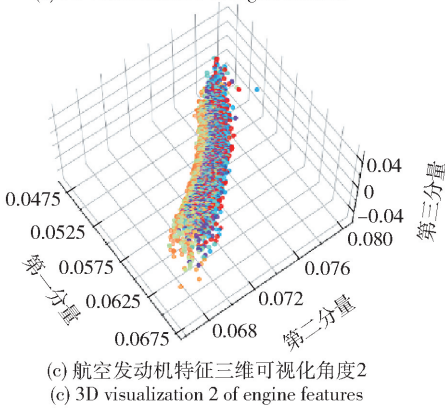

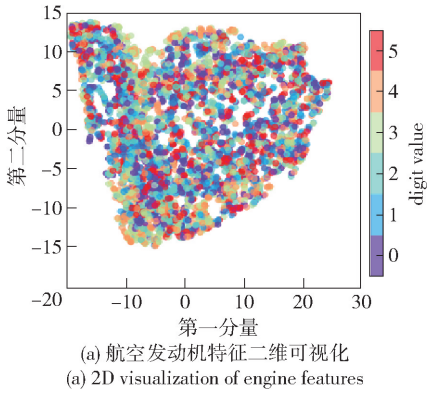


图 8 数据集特征降维可视化图

Fig. 8 Aero-engine feature visualization

表 2 TCN 框架及 T-SNE 降维参数

Table 2 TCN model and T-SNE parameters

TCN 模型	参数	T-SNE	参数
Batch-size	256	init	random
Epoch	300	random_state	33
Dropout	0.1	learning_rate	200
Hidden Layers	[64, 16, 16]	metric	cosine

入的故障模式不仅故障现象相似,在飞参特征数据上也存在较深的耦合关系,从而在空间中表现出总体较为规则、同类聚集中分布的特点;深入点群内部来看,状态模式基本按部件故障程度、故障耦合层次排布发展,正常状态模式则呈全空间包被散布,能够一定程度反映气路部件失效的故障逻辑。

图 8(a) 平面区域类别混杂、数据过密的分布则可以理解为将多层“夹心”沿堆叠方向压缩的结果;若沿与堆叠方向垂直的角度进行降维压缩,则表现为图 8(c) 中近似平行的类别特征降维分布(图 8(c) 中数据点均在同一平面上)。同时,由于降维过程中不可避免的信息损失及观察角度限制(二维、三维中均存在),图 8(b) 和图 8(c) 中同时存在不同程度的离散噪点和类别交杂现象,对特征可视化及降维解释产生一定影响。

4.3 故障诊断

为充分利用有限数据集内的特征信息,提高模型的泛化能力,将训练特征输入 LGBM 模型进行五折交叉验证,考虑到数据集本身的不平衡特点,采用 StratifiedKFold 分组分层抽样方法,尽量保证每个分组中各类别比例与原类别比例相同;利用贝叶斯优化方法在参数预设范围内快速迭代,找到使模型分类精度最高的参数组合,模型超参数如表 3 所示。

表 3 贝叶斯模型超参数

Table 3 Bayesian model hyperparameters

贝叶斯参数	数值	贝叶斯参数	数值
num_leaves	84	bagging_fraction	0.6
max_depth	40	bagging_freq	5
lambda_l1	0.1	min_data_in_leaf	30
lambda_l2	0.1	n_estimators	cosine

在该参数组合下,TCN-LGBM 模型经过 300 次迭代运行后,对仿真生成的 6 种故障模式分类结果如图 9 所示。

对于该多分类问题,其总的诊断准确率可以定义为

$$Acc = \frac{Class_i}{Label_i} \quad (12)$$

式中: $Class_i$ 表示所有类别数据被正确分类的数量; $Label_i$ 表示所有样本的数量。

从图 9 中可以看出,模型训练集准确率迅速提升并稳定在 98.79% 左右,损失值快速下降并收敛在 0.055 678 附近;测试集分类准确率呈现同样趋势并能达到 98.76%,其损失值则收敛到 0.058 901。训练测试集 loss 值相对较小且比较接近,准确度均保持在近似稳定水平,表明模型拟合适度,没有陷入过拟合状态,对给出的气路故障能够进行较好的分类识别。

为进一步评估分类模型的故障诊断性能,给出模型分类结果混淆矩阵如图 10 所示,结合前述准确

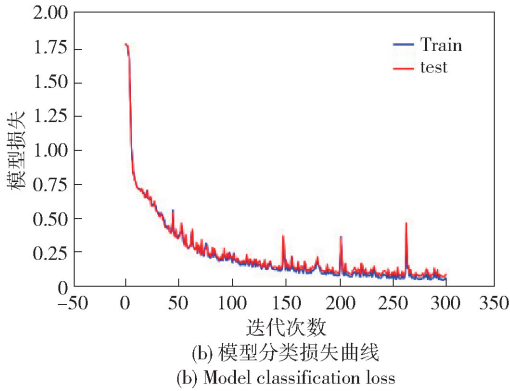
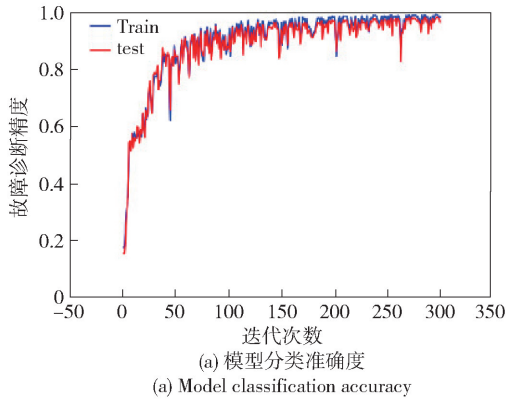


图 9 模型分类准确度与损失曲线图

Fig. 9 Classification accuracy and loss curve

度 *Acc* 并采用精确率 *Precision*、召回率 *Recall* 等多元指标进行综合评判。图 10 中横坐标表示该数据代表的真实故障标签,纵坐标表示对其标签的预测结果, *TP* 表示该类别数据被正确分类的数量, *FP* 表示分类结果与该数据真实类别不相同的数量, *FN* 表示该类别被错误分类的数量,相应的计算公式为

$$Precision = \frac{TP}{TP + FP} \quad (13)$$

$$Recall = \frac{TP}{TP + FN} \quad (14)$$

图 10 的结果显示,在对故障模式集进行识别时,类别 0、类别 3 和类别 5 的精确度分别为 97.08%、94.34%、96.15%;类别 2 被误分至训练数据占比较高类别中的比例为 3%,召回率为 97%;类别 4 被误分至故障表现相近类别中的比例为 6%,召回率为 94%;剩余类别指标的召回率和精确率均达到了 100%。从总体多分类角度来看,气路部件故障诊断准确度较高,识别准确;且在细化至每类样本数据进行多指标分析时保持了不低的水平,表明其提取的特征具备区分不同故障的差异化特点,较好地满足了航空发动机气路故障诊断的精度需求。

为对比说明本文方法的优越性,进一步将其与




图 10 模型混淆矩阵图

Fig. 10 Model confusion matrix

时序数据分类预测的常见方法进行对比。本文选择 SE-CNN^[32]、CNN-LGBM、RNN、BiLSTM^[33]、TCN baseline 和深度残差收缩网络 (Deep Residual Shrinkage Networks, DRSN)^[8] 等作为对照实验,考虑到单次运行结果的波动性和局部最优特点,多次运行进一步验证方法的重复性能和稳健性。图 11 所示为上述 6 种方法和本文方法在 20 次运行过程中取得的分类准确度对比结果。

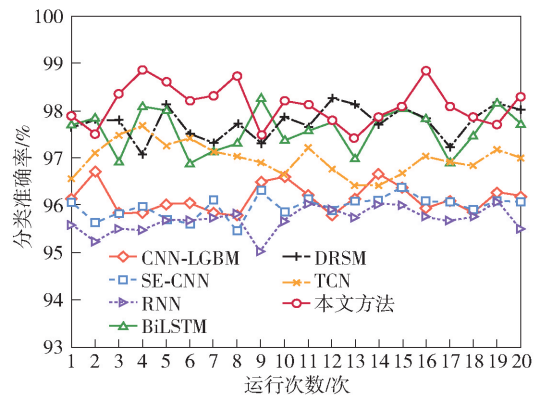


图 11 航空发动机故障诊断准确率曲线图

Fig. 11 Aero-engine fault diagnosis accuracy

从图 11 中可以看出:在 20 次迭代运行过程中,本文模型的平均诊断准确率为 98.106%,从平均分类精度和单次运行效果来看优于其他大多数方法;在迭代次数相同的情况下,本文方法相较于其他方法,其平均指标始终能维持较高的准确度(即重复性能),模型稳健性在可接受范围内,表明了本文方法的优越性。

5 结论

为在维修保障过程中有效识别航空发动机的工

作状态,对其产生的故障状况进行准确诊断隔离,本文提出一种基于 TCN-LGBM 的故障诊断框架模型。得出以下主要结论:

1) TCN 网络模型定义的因果卷积能较好地满足时序预测输出和数据训练过程中对逻辑严密性的要求,解决了潜在的未来信息泄露问题,且模型精度不低于其他主流诊断方法。

2) 相较于传统模型,深度学习模型与机器学习方法的有效结合是提高模型性能精度、解决特征非线性耦合的可行之道。在实现对故障模式时序特征提取和可视化的基础上,运用 LGBM 分类器对故障模式特征进行快速分类。结果表明,在不过拟合的情况下,对发动机气路部件故障模式分类准确度达到 98.106%,可认为较好地解决了本文故障模式的识别和诊断,诊断精度相较于其他主流算法效果较好。

3) 尽管本文方法对部件性能退化组合的故障模式实现了较好的状态辨识,但实际发动机可用的气路参数集合非常有限,进一步的精确定位和隔离诊断需要引入孔探等多种技术手段并结合外场修理经验,从而有效识别导致发动机性能退化、故障的主要原因,并能在总结运行环境、使用情况和目前状态的基础上为未来发动机状态监测提供先验状态,更好地实现发动机未来状态预测。

本文方法面向航空发动机等多元退化设备,为解决故障模式复杂、性能参数耦合的时序数据分类/设备故障诊断问题提供了有益参考。而在实际运行过程中,航空发动机故障模式复杂多样,需要进一步细化故障模式,扩充典型数据样本,并对基于深度学习的网络模型分类不确定度进行量化分析和稳定性修正,从而在对航空发动机等关键设备分析时得到更审慎稳妥的结果。

参考文献 (References)

- [1] 朱之丽,陈敏,唐海龙,等.航空燃气涡轮发动机工作原理及性能[M].上海:上海交通大学出版社,2018:257-261.
ZHU Z L, CHEN M, TANG H L, et al. Working principle and performance of aircraft gas turbine engines [M]. Shanghai: Shanghai Jiao Tong University Press, 2018:257-261. (in Chinese)
- [2] 周忠宝,马超群,周经伦.基于动态贝叶斯网络的动态故障树分析[J].系统工程理论与实践,2008,28(2):35-42.
ZHOU Z B, MA C Q, ZHOU J L. Dynamic fault tree analysis based on dynamic bayesian networks [J]. System Engineering-Theory & Practice, 2008, 28(2):35-42. (in Chinese)
- [3] 蔡鼎.融合先验知识的燃气轮机欠定气路故障诊断方法研究[D].哈尔滨:哈尔滨工业大学,2105:40-42.
CAI D. Method for underdetermined fault diagnosis with the prior knowledge of gas turbine [D]. Harbin: Harbin Institute of Technology, 2015:40-42. (in Chinese)
- [4] 金山.复杂系统可靠性建模与分析[M].北京:国防工业出版社,2015:5-17.
JIN S. Complex system reliability modeling and analysis [M]. Beijing: National Defense Industry Press, 2015:5-17. (in Chinese)
- [5] 杨洁,万平安,王景霖,等.基于多传感器融合卷积神经网络的航空发动机轴承故障诊断[J].中国电机工程学报,2022,42(13):4933-4941.
YANG J, WAN P A, WANG J L, et al. Aeroengine bearing fault diagnosis based on convolutional neural network for multi-sensor information fusion [J]. Proceedings of the CSEE, 2022, 42(13):4933-4941. (in Chinese)
- [6] 魏晓良,潮群,陶建峰,等.基于 LSTM 和 CNN 的高速柱塞泵故障诊断[J].航空学报,2021,42(3):435-445.
WEI X L, CHAO Q, TAO J F, et al. Cavitation fault diagnosis method for high-speed plunger pumps based on LSTM and CNN [J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(3):435-445. (in Chinese)
- [7] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] // Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer, 2018:3-19.
- [8] ZHAO M H, ZHONG S S, FU X Y, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16(7):4681-4690.
- [9] DING Y, MA L, MA J, et al. Intelligent fault diagnosis for rotating machinery using deep Q-network based health state classification [J]. Advanced Engineering Informatics, 2019, 42:100977.
- [10] 邓飞跃,丁浩,吕浩洋,等.一种基于轻量级神经网络的高铁轮对轴承故障诊断方法[J].工程科学学报,2021,43(11):1482-1490.
DENG F Y, DING H, LÜ H Y, et al. Fault diagnosis of high-speed train wheelset bearing based on a lightweight neural network [J]. Chinese Journal of Engineering, 2021, 43(11):1482-1490. (in Chinese)
- [11] 潘宏伟,张玉学.基于 SST 时频图纹理特征的供输弹系统故障诊断[J].振动与冲击,2020,39(6):132-137.
PAN H X, ZHANG Y X. Fault diagnosis of the ammunition supply system based on the texture features of SST time-frequency distribution image [J]. Journal of Vibration and Shock, 2020, 39(6):132-137. (in Chinese)
- [12] SHOKROLAHI S M, KARIMIZIARANI M. A deep network solution for intelligent fault detection in analog circuit [J]. Analog Integrated Circuits and Signal Processing, 2021, 107(3):597-604.
- [13] HOWARD A G, ZHU M L, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision Applications: arXiv:1704.04861 [R/OL]. Ithaca, NY, US:

- Cornell University. (2017-04-17) [2020-12-09]. <https://arxiv.org/abs/1704.04861>.
- [14] BAI S J, ZICO K, VLADLEN K. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling: arXiv; 1803. 01271 [R/OL]. Ithaca, NY, US; Cornell University. (2018-03-04). <https://arxiv.org/abs/1803.01271>.
- [15] 皮骏, 黄江博. 基于 IPSO-Elman 神经网络的航空发动机故障诊断[J]. 航空动力学报, 2017, 32(12):3031-3038.
PI J, HUANG J B. Aero-engine fault diagnosis based on IPSO-Elman neural network[J]. Journal of Aerospace Power, 2017, 32(12):3031-3038. (in Chinese)
- [16] 谭海旺, 杨启亮, 邢建春, 等. 基于 XGBoost-LSTM 组合模型的光伏发电功率预测[J]. 太阳能学报, 2022, 43(8):75-81.
TAN H W, YANG Q L, XING J C, et al. Photovoltaic output prediction based on combined XGBoost-LSTM model[J]. Acta Energeticae Solaris Sinica, 2022, 43(8):75-81. (in Chinese)
- [17] 马怀祥, 冯旭威, 李东升, 等. 基于 CNN 和 XGBoost 的滚动轴承故障诊断方法[J]. 中国工程机械学报, 2019, 19(3):254-259.
MA H X, FENG X W, LI D S, et al. Fault diagnosis method of rolling bearing based on CNN and XGBoost[J]. Chinese Journal of Construction Machinery, 2019, 19(3):254-259. (in Chinese)
- [18] AARON V D O, SANDER D, HEIGA Z. Wavenet: a generative model for raw audio; arXiv :1609. 03499 [R/OL]. Ithaca, NY, US; Cornell University, 2016; 1609. 03499. (2016-09-19). <https://arxiv.org/abs/1609.03499>.
- [19] HE Y D, ZHAO J B. Temporal convolutional networks for anomaly detection in time series [J]. Journal of Physics: Conference Series, 2013, 1213(4):042050.
- [20] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, US; IEEE, 2019: 7132-7141.
- [21] 华校专. AI 算法工程师手册[R/OL]. (2022-04-03) [2022-04-08]. <http://www.huaxiaozhuan.com/>.
HUA X Z. AI algorithms engineer handbook[R/OL]. (2022-04-03) [2022-04-08]. <http://www.huaxiaozhuan.com/>. (in Chinese)
- [22] 杜先君, 巩彬, 余萍, 等. 基于 CBAM-CNN 的模拟电路故障诊断[J]. 控制与决策, 2022, 37(10):2609-2618.
DU X J, GONG B, YU P, et al. Research on CBAM-CNN based analog circuit fault diagnosis[J]. Control and Decision, 2022, 37(10):2609-2618. (in Chinese)
- [23] 田彦云. 涡轴发动机建模与扭矩加载控制技术研究[D]. 南京:南京航空航天大学, 2016.
TIAN Y Y. Research on modeling and torque loading control technology of turbo-shaft [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2016. (in Chinese)
- [24] 张浩, 李密, 赵海刚. 基于试飞数据的涡轴发动机性能建模技术[J]. 推进技术, 2021, 42(10):2177-2186.
ZHANG H, LI M, ZHAO H G. Performance modeling technique of turboshaft engine based on flight experimental data[J]. Journal of Propulsion Technology, 2021, 42(10):2177-2186. (in Chinese)
- [25] 潘慕绚, 陈强龙, 周永权, 等. 涡扇发动机多动力学建模方法[J]. 航空学报, 2019, 40(5):99-110.
PAN M X, CHEN Q L, ZHOU Y Q, et al. Amulti-dynamics approach to turbofan engine modeling [J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(5):99-110. (in Chinese)
- [26] LU F, JU H F, HUANG J Q. An improved extended Kalman filter with inequality constraints for gas turbine engine health monitoring [J]. Aerospace Science and Technology, 2016, 58(1):36-47.
- [27] 楚娜娜, 张曙光, 高艳蕾, 等. 基于 Simscape 模型的航空发动机系统安全性分析方法[J]. 航空动力学报, 2021, 36(4):885-896.
CHU N N, ZHANG S G, GAO Y L, et al. Safety analysis method of aero-engine systems based on Simscape model[J]. Journal of Aerospace Power, 2021, 36(4):885-896. (in Chinese)
- [28] 刘星怡. 基于深度信念网络的航空发动机气路故障诊断方法研究[D]. 南京:南京航空航天大学, 2020.
LIU X Y. Research on gas path fault diagnosis method for aeroengine based on deep belief network[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2020. (in Chinese)
- [29] 葛怡. 航空发动机几种典型故障建模仿真及预测[D]. 西安:西安理工大学, 2020.
GE Y. Modeling, simulation and prediction of several typical faults of aeroengine [D]. Xi'an: Xi'an University of Technology, 2020. (in Chinese)
- [30] WEI T T, VAN BEEK A, HAO J R, et al. Bayesian calibration of performance degradation in a gas turbine-driven compressor unit for prognosis health management[J]. Journal of Engineering for Gas Turbines and Power, 2022, 144(5):51014.
- [31] ZHAO Y P, CHEN Y B. Extreme learning machine based transfer learning for aero engine fault diagnosis[J]. Aerospace Science and Technology, 2022, 121:107311.
- [32] 石重托, 姚伟, 黄彦浩, 等. 基于 SE-CNN 和仿真数据电力系统主导失稳模式智能识别[J/OL]. 中国电机工程学报. (2021-11-08). <https://kns.cnki.net/kcms/detail/11.2107.TM.20211105.1639.046.html>.
SHI Z T, YAO W, HUANG Y H, et al. Power system dominant instability model identification based on convolutional neural networks with squeeze and excitation block and simulation data [J]. Proceedings of the CSEE. (2021-11-08). <https://kns.cnki.net/kcms/detail/11.2107.TM.20211105.1639.046.html>. (in Chinese)
- [33] 张浩, 胡昌华, 杜党波, 等. 多状态影响下基于 Bi-LSTM 网络的锂电池剩余寿命预测方法[J]. 电子学报, 2022, 50(3):619-624.
ZHANG H, HU C H, DU D B, et al. Remaining useful life prediction method of lithium-Ion battery based on Bi-LSTM network under multi-state influence[J]. Acta Electronica Sinica, 2022, 50(3):619-624. (in Chinese)