

基于时间序列异常检测的航空发动机故障诊断

王茵茹

(中国航发控制系统研究所, 无锡 214063)

摘要: 航空发动机的故障诊断存在数据偏斜问题,即故障样本数量远少于正常样本数量,且故障样本无法反映整个运行工况,导致常规的分类模型泛化能力较差。针对上述问题,提出一种基于改进的深度支持向量数据描述的时间序列异常检测模型。使用长短期记忆递归神经网络(LSTM)映射样本的输入和输出,与实际采集输出构成时序异常向量,再通过融入变分自编码器(VAE)的深度支持向量数据描述(DeepSVDD)实现航空发动机时序数据的异常检测;在某型航空发动机地面试车台进行实验验证,与孤立森林(IF)、TranAD(Transformer-based Anomaly Detection Model)及GANomaly等对比方法进行对比。结果表明:采用本文所提模型计算得到特征曲线下面积(AUC)值达到0.9878,具有最好的异常检测性能,能够有效地应用于航空发动机的各项异常检测及故障诊断任务中。

关键词: 异常检测;故障诊断;支持向量数据描述;时间序列;航空发动机

中图分类号: V263.6

文献标识码: A

Aero-engine fault diagnosis based on time series anomaly detection

WANG Yinru

(AECC Aero Engine Control System Institute, Wuxi 214063, China)

Abstract: The fault diagnosis of aero-engines is confronted with a data skew issue, where the number of fault samples was significantly fewer than normal samples, and the fault samples couldn't adequately represent the entire operating conditions, resulting in poor generalization ability of conventional classification models. To overcome this issue, an improved deep support vector data description-based time series anomaly detection model is proposed. The long short-term memory recurrent neural network (LSTM) is employed to map the inputs and outputs of samples, forming temporal anomaly vectors with actual collected outputs. The deep support vector data description (SVDD) incorporating variational autoencoder (VAE) is utilized to achieve anomaly detection for aero-engine time series data. The experimental verification is performed with a certain type of aero-engine ground test platform, and the model is compared to with isolation forest (IF), transformer-based anomaly detection model (TranAD), and GANomaly. The results show that the curve (AUC) value calculated with the proposed model can reach to 0.9878, has superior anomaly detection performance. The proposed model can effectively be applied to various anomaly detection and fault diagnosis tasks in aero-engine systems.

Key words: anomaly detection; fault diagnosis; support vector data description; time series; aero-engine

收稿日期: 2024-03-16; 修回日期: 2024-05-18

通信作者: 王茵茹(1982—), 女, 硕士, 工程师。E-mail: 576829199@qq.com

引用格式: 王茵茹. 基于时间序列异常检测的航空发动机故障诊断[J]. 航空工程进展.

WANG Yinru. Aero-engine fault diagnosis based on time series anomaly detection[J]. Advances in Aeronautical Science and Engineering. (in Chinese)

0 引言

航空发动机是在高温、高压、高速旋转的环境中持续工作的复杂热力机械^[1],航空发动机作为航空飞行器的关键组成部分,在航空飞行器运行过程中发挥重要作用^[2]。随着航空工业的发展以及对航空发动机性能的苛刻追求,对航空发动机故障诊断的需求日益增加。因此,对航空发动机的运行状态和健康程度进行实时精准监控,并对其可能出现的故障进行精确的诊断和预测,对航空发动机及飞行器的运行安全至关重要。

对于航空发动机故障诊断,研究人员基于大量专家分析及实验数据形成了比较成熟的基于物理机理的模型驱动故障诊断方法。然而,传统的模型驱动故障诊断需要进行特征工程,依赖人工进行特征提取,且泛化能力较差。因此,深度学习和数据驱动的故障诊断建模方法逐渐被应用在航空发动机故障诊断任务中^{[3]-[5]}。

崔建国等人^[6]提出了一种改进的灰狼算法优化核极限学习机(Improved Grey Wolf Optimizer Kernel Extreme Learning Machine,简称 IGWO-KELM),对航空发动机滑油系统的故障诊断精度达到了96%。赵洪利等^[7]提出了一种基于融合卷积Transformer的航空发动机故障诊断方法,在航空发动机故障诊断任务中达到了98.986%的准确率;伍济钢等^[8]提出一种局部池化改进的通道注意力机制,提升了航空发动机转子系统故障诊断的泛化性能和抗噪性能;Zhao等^[9]提出一种基于极限学习机的迁移学习方法(Two-Stage-Transfer-Learning Extreme Learning Machine,简称 TSTL-ELM)用于航空发动机故障诊断,并实现优异的故障诊断性能。

目前数据驱动的航空发动机故障诊断主要是根据航空发动机各部件的传感器时间序列信号,通过机器学习和深度学习方法,完成特征提取和趋势预测,当实际检测信号偏离训练好的模型输出信号,则预警故障并执行视情维修。考虑到航空发动机部件级故障诊断的需求及极高的精度要求,对各部件单独建立深度学习模型,则可以将多分类问题转化为单分类问题,考虑到航空发动机正常运行数据往往远远多于故障数据,即存在数据偏斜问题,进一步地,可以将航空发动机部件级故障诊断建模问题转化为时间序列异常检测

问题。

时间序列异常检测是指在时间序列数据中识别和定位与正常模式显著不同的异常或异常模式的过程。在航空发动机的时间序列异常检测应用中,根据异常模式发现方法可以分为基于预测的方法和基于分类的方法^[10-11]。

基于预测的时间序列异常检测方法是通过预测值与实际值的误差值大小来判断异常。黄续芳等^[12]提出一种基于双向门控循环单元(Bidirectional Gated Recurrent Unit,简称 Bi-GRU)的深度学习液压管路故障诊断方法,用于航空发动机外部液压管路故障诊断;马帅等^[13]提出一种特征注意力增强型长短时记忆网络(Feature Attention Enhanced Long Short-Term Memory Network,简称 FAE-LSTM)用于航空发动机气路参数预测,并实现了高精度的气路退化异常检测;赵万里等^[14]提出一种基于自回归滑动平均(Autoregressive Moving Average,简称 ARMA)算法的航空发动机异常检测模型,并在实时故障诊断器中完成了实时性验证;刘振刚等^[15]基于试飞数据,提出一种变尺度窗口切片的数据增强方法,构建基于双向长短时记忆网络(Bidirectional Long Short-Term Memory Network,简称 Bi-LSTM)的异常检测模型,并验证其在工程应用中的可行性。Ren等^[16]基于LSTM神经网络构建了航空发动机剩余使用寿命估计的算法,达到最佳性能。基于预测的方法大多应用于周期较长且时间序列趋势性较强的航空发动机预测建模,通过检测偏离趋势的时间序列识别异常。Wang等^[17]基于时间序列分解建模和相似性比较构建了一种航空发动机剩余使用寿命预测方法,并能够检测航空发动机运行异常,均方根误差(Mean Square Error,简称 MSE)达到528。

基于分类的方法是通过分类机器学习和深度学习模型有监督地学习正常和异常样本的数据表征和分布,实现异常分类。Lin等^[18]提出一种基于特征放大的航空发动机故障诊断新方法,实验结果表明,高维映射后的样本特征具有良好的正交性,可以提高故障诊断的准确性;刘海瑞等^[19]提出一种基于自适应粒子群算法优化(Adaptive Particle Swarm Optimization,简称 APSO)的最小二乘支持向量机(APSO Least Squares Support Vector

Machine, 简称 APSO-LSSVM) 对航空发动机轴承进行故障诊断及寿命预测; 周卓峰等^[20]结合特征提取与深度信念网络实现了在噪声环境下的航空发动机滚动轴承故障诊断; 孙昊等^[21]提出了基于混合核慢特征分析和密度聚类的慢特征密度聚类算法, 实现了基于民航发动机气路参数原始值的异常检测; Jin 等^[22]提出了一种深度椭圆支持向量数据描述卷积神经网络 (Deep Support Vector Data Description Convolutional Neural Networks, 简称 DeepSVDD-CNN) 用于航空发动机压气机失速预警, 取得了优异表现。基于分类的方法得益于分类模型的引入, 具有较好的分类性能和异常检测表现, 但容易丢失时间维度的信息。

对于航空发动机时间序列异常检测建模及故障诊断任务, 目前通常存在如下挑战: 1) 对异常点的检测精度要求极高; 2) 长时间工作情况下, 需要考虑航空发动机性能退化的长期趋势; 3) 需要尽可能避免人工设定阈值, 使用数据重构方法构建异常指标判断异常。

针对现有研究中存在的问题, 考虑将基于预测和基于分类的时间序列异常检测方法结合以实现航空发动机的数据重构, 并引入无监督的分类模型, 通过模型的异常分数对异常点进行检测。在时间序列预测领域, 长短期记忆递归神经网络 (Long Short-Term Memory Network, 简称 LSTM) 是目前应用最广泛、最有效的方法之一^[23], 在非线性动态系统辨识中有很好的表现^[24-25]。深度支持向量数据描述 (Deep Support

Vector Data Description, 简称 DeepSVDD)^[26]是一种基于深度神经网络的异常检测模型, 自提出以来就被广泛应用于工业异常检测领域, 取得了优异的表现^[27-29]。变分自编码器 (Variational Auto-Encoder, 简称 VAE) 是一种编码器-解码器结构的前馈神经网络, 被广泛应用于异常检测任务中的特征重构或数据增强^[30]。

基于以上思考, 本文提出一种变分自编码深度支持向量数据描述 (VAE-SVDD) 异常检测模型, 在某型航空发动机地面试车台进行实验验证, 与孤立森林 (IF)、TranAD (Transformer-based Anomaly Detection Model) 及 GANomaly 等对比方法进行对比。

1 问题分析

本文的试验对象是某型涡扇发动机半物理试验台。该试验台可通过控制脉冲宽度调制 (Pulse Width Modulation Wave, 简称 PWM) 模拟涡扇发动机飞行过程, 以实现涡扇发动机控制策略的优化和机械液压附件性能评估验证等一系列地面试车试验。

涡扇发动机的部件结构如图 1 所示。空气进入进气道后, 被分为旁路和主路。主路气流依次经过风扇、低压压气机、高压压气机, 在燃烧室内被点燃, 再依次经过高压涡轮和低压涡轮, 分别通过高压轴和低压轴带动两级压气机, 最后高温高压气体经由喷管流出涡扇发动机, 使航空发动机产生推力。

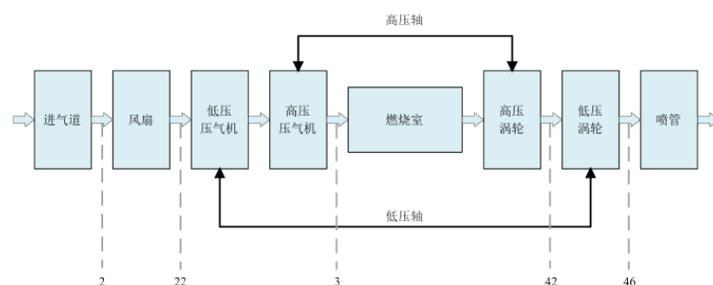


图1 涡扇发动机部件图

Fig. 1 Component diagram of turbofan engine

涡扇发动机地面试车台架结构如图 2 所示。控制器通过控制软件输出 PWM, 机械液压附件控制液压开合度以输出对应的燃油流量供给涡扇发动机运行, 在采集模块中采集对应的主流量

(Wfmhe)。涡扇发动机工作过程中通过传感器采集对应电机转速 (N_e), 高压轴转速 (N_{2g}), 压气机出口压力 (P_3), 出口温度 (T_z) 等各项动态参数, 通过电传系统和信号模拟装置将电信号转换为数字

信号反馈于控制器和控制软件,实现地面试车过程的闭环控制。

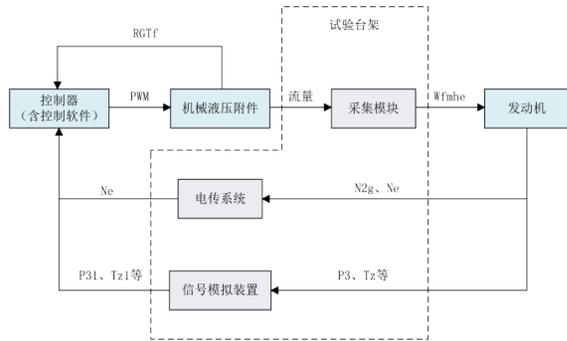


图2 涡扇发动机试验台部件图

Fig. 2 Component diagram of turbfan engine test bench

半物理试验台在运行过程中存在液压部件老化、电控故障、采集模块断连或假信号、控制器故障等多种部件级的故障,需要高精度的故障诊断模型提醒试验人员开展视情维修,以提高试验效率。

首先将在半物理试验台上采集离线数据用于数据驱动模型的训练和测试,训练完成的模型将在半物理试验台运行过程中开展在线故障诊断任务中以评估本文模型的实际性能。

训练模型所使用的数据集在三种不同的发动机工况下采集,分别为:地面启动和稳态加减速,65%最大转速限制,100%最大转速限制。传感器采集试验台各部件的输入输出信号,构建离散的时间序列数据。将采集的不同工况下的数据合并,构建训练数据集。取某一工况下65%最大转速限制的信号记录为例展示信号结构,如图3所示。

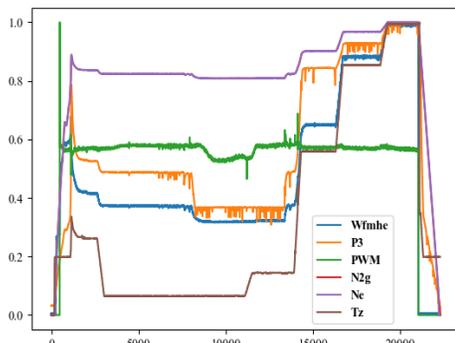


图3 65%最大转速限制的信号图

Fig. 3 Signal graph for 65% maximum speed limit

本文将对该试验台架中的机械液压附件、电传系统和采集模块分别进行故障诊断建模,数据集各项参数如表1所示。

表1 发动机试验台数据集
Table 1 Engine test bench dataset

部件	机械液压附件	电传系统	采集模块
总维度	2	3	2
输入维度	1	2	1
输入特征	PWM	N2g, Ne	流量
输出特征	流量	Ne	Wfmhe
采样频率/Hz	40	40	40
总时间/s	57 968	57 968	57 968

在实际工作过程中,试验台各部件故障发生概率较低,数据驱动建模方法会存在训练数据偏斜的问题,即正常样本充足而故障状态的样本极度稀缺,考虑将该台架部件故障诊断任务转化为时间序列的异常检测问题。

基于试验台正常工作情况下所采集的时间序列数据集,首先经过时间窗口分割构造时间序列样本点等一系列数据预处理,再通过本文所提算法构建异常检测模型。预处理后数据各项参数如表2所示。

表2 预处理后数据集参数
Table 2 Preprocessed dataset parameters

参数	数值
时间窗口长度(采样点)	100
时间窗口步长(采样点)	10
样本点时长/s	2.5
异常检测频率/s ⁻¹	0.25
总样本点数	231 862
正常样本点数	208 762
异常样本点数	23 100
训练测试集划分	7:3
测试集异常比率/%	24.93

至此,原问题转化为时间序列异常检测建模问题。即输入多维特征 $X_m = (x_{1:N}^1, \dots, x_{1:N}^L) \in \mathbb{R}^{N \times L}$, 模型输出预测输出的一维特征: $X_{out} = (x^1, \dots, x^L) \in \mathbb{R}^{1 \times L}$, 通过对比真实值 $X_{true} = (x^1, \dots, x^L) \in \mathbb{R}^{1 \times L}$ 与预测输出的偏差判断样本点异常分数,从而实现部件级的故障诊断。

2 基于双变分自编码器的深度支持向量数据描述(LSTM-VAE-SVDD)

2.1 长短期记忆递归神经网络 LSTM

LSTM是一种后馈型神经网络。相较于循环神经网络(Recurrent Neural Network, 简称RNN), LSTM通过构建遗忘门、输入门和输出门决定需要保留和遗忘的历史信息, 避免了时间序列训练过程中出现的梯度消失和梯度爆炸的问题^[12-13]。LSTM网络单元结构如图4所示。

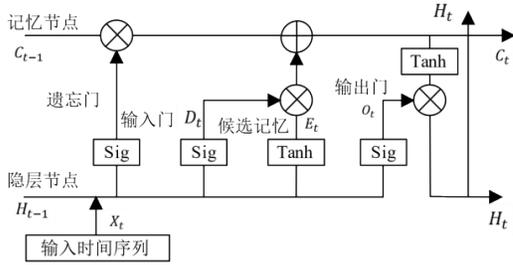


图4 LSTM网络单元结构图

Fig. 4 LSTM network unit structure diagram

对于每个LSTM网络单元, 首先读取前一单元输出信息 H_{t-1} 和 C_{t-1} , 得到一个门信息决定本单元信息是否存储, 通过 Sigmoid 函数更新输入门向量 D_t , 通过 Tanh 函数生成候选记忆向量 E_t , 最后通过另一个 Sigmoid 函数更新输出信息 O_t 和下一单元的数值 H_t , 各向量计算公式如下:

$$F_t = \sigma(W_{f1}X_t + W_{f2}H_{t-1} + B_f) \quad (1)$$

$$D_t = \sigma(W_{d1}X_t + W_{d2}H_{t-1} + B_D) \quad (2)$$

$$E_t = \tanh(W_{e1}X_t + W_{e2}H_{t-1} + B_E) \quad (3)$$

$$C_t = D_t \times E_t + C_{t-1} \times F_t \quad (4)$$

$$O_t = \sigma(W_{o1}X_t + W_{o2}H_{t-1} + B_O) \quad (5)$$

$$H_t = O_t \times \tanh(C_t) \quad (6)$$

式中: W 和 B 分别为各向量的权重和偏置; X_t 为输入序列; H_{t-1} 为前一单元的输出。

本文使用 LSTM 网络模型用于训练各部件输入序列至输出序列间的映射。

2.2 基于变分自编码器的深度支持向量数据描述 VAE-SVDD

2.2.1 支持向量数据描述 SVDD

SVDD 是一种被广泛使用的异常检测算法,

其主要思想是将输入空间的所有正常样本 $X \subseteq R^d$ 通过映射 $\varphi(\cdot)$ 映射至特征空间 $F \subseteq R^b$ 的超球体中, 该超球体的圆心为 $c \subseteq F$, 半径为 R 。对于测试样本, 计算该样本与球心的距离, 将样本与球心的距离作为异常分数, 从而实现异常检测功能^[27-28]。SVDD 结构如图5所示。

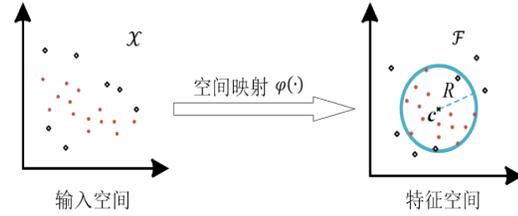


图5 SVDD 结构图

Fig. 5 SVDD structure diagram

对于一个正常样本训练数据集 $X = \{x_1, \dots, x_n\} \subseteq R^d$, SVDD 的原问题可以描述为

$$\min_{R, c, \xi} R^2 + \gamma \sum_{i=1}^n \xi_i$$

$$s.t. \|\varphi(x_i - c)\| \leq R^2 + \xi_i \quad (i = 1, 2, \dots, n) \quad (7)$$

$$\xi_i \geq 0, \quad i = 1, 2, \dots, n$$

式中: $\|\cdot\|$ 为欧几里得范数; ξ 为松弛变量, 允许训练集中部分异常点在超球体之外; γ 为平衡参数, 用于平衡球体的体积和离群点的数量。

传统的 SVDD 方法常常被视为一个二次规划问题, 通过引入拉格朗日乘子将原问题转化为对偶问题求解。然而, SVDD 问题最终求解结果可以被表示为一个映射 $\varphi(\cdot)$, 一个超球体球心 c 和超球体半径 R 。使用深度神经网络权重 $\varphi(\cdot; W)$: $\rightarrow F$ 表示空间映射 $\varphi(\cdot)$, 可以将式(7)转化为一个深度神经网络优化问题 DeepSVDD, 目标函数可以表示为

$$\min_w \frac{1}{n} \sum_{i=1}^n \|\varphi(x_i; W) - c\|^2 \quad (8)$$

通过这样的简化, DeepSVDD 不再收到超球体半径 R 的影响, 而是尽可能将所有正常样本点通过 $\varphi(\cdot)$ 映射到尽可能小的高维空间球体中, 神经网络优化的参数将只有网络权重 W 和球心 c 。

本文中, SVDD 部分用于通过检测输出序列与真实序列的时间序列偏离度的异常分数来实现异常检测。

2.2.2 变分自编码器 VAE

VAE是一种基于贝叶斯变分推断理论的深度神经网络,可作为一种隐变量生成模型用于特征表征和降维^[30]。VAE可分为编码器和解码器两部分,其中编码器得到输入序列 $x \subseteq \mathbf{R}^d$ 的均值 μ 和方差 σ ,通过变分推断获取隐变量概率分布并采样得到隐变量 $z \subseteq \mathbf{R}^m$,其中辅助参数 ϵ 将隐变量的生成过程简化为映射函数 $z = g_\phi(\epsilon, x)$ 。解码器还原数据的近似后验概率分布并采样生成输出序列 $x' \subseteq \mathbf{R}^d$ 。VAE的结构如图6所示。

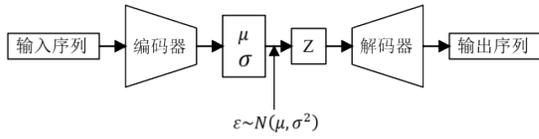


图6 VAE的结构图

Fig. 6 VAE structure diagram

$$L(\theta, \phi) = \operatorname{argmin} D_{KL}[q_\phi(z|x)P_\theta(z|x)] = \operatorname{argmax} \left(E_{q_\phi(z|x)}[\ln P_\theta(x|z)] - D_{KL}[q_\phi(z|x)P_\theta(z)] \right) \quad (10)$$

式中： $D_{KL}[\cdot]$ 为两分布之间的KL散度； $E_q[\cdot]$ 为分布 q 下的数学期望。

本文考虑使用VAE网络作为DeepSVDD的特征重构映射 $\varphi(\cdot)$ 。

2.2.3 VAE-SVDD模型

本文提出一种基于VAE改进的DeepSVDD结构用于时间序列的异常检测,将该框架命名为VAE-SVDD。VAE-SVDD模型首先通过VAE的编码器作为特征提取网络将输入空间的所有正常样本映射到特征空间,用于学习和构建特征空间超球体。VAE的解码器将特征空间重新映射回输入空间,对输入序列进行重构,通过输出的重构序列与输入序列的损失函数学习编码器与解码器的参数。训练后的模型取编码器和超球体部分,通过计算测试样本在特征空间与超球体球心 c 的距离评估测试序列的异常。VAE-SVDD的结构如图7所示。

$$\min_{c, w} \frac{\alpha}{n} \sum_{i=1}^n \left[D_{KL}(q_\phi(z|x_i) \| p_\theta(z)) - \frac{1}{L} \sum_{i=1}^L \log p_\theta(x_i|z_i) \right] + \frac{1}{n} \sum_{i=1}^n \| q_\phi(z|x_i) - c \|^2 \quad (11)$$

式中： ϕ 为VAE编码器的参数； θ 为VAE解码器的参数； α 为权重参数,用于调整VAE和SVDD对整体模型影响的权重, α 值越大,则模型更偏向于对样本空间的重构, α 值越小,则模型更倾向于异常

VAE的优化目标为求取输入序列的最大似然函数,建立如下公式:

$$\ln P_\theta(x) = \ln P_\theta(x, z) - \ln P_\theta(z|x) = \int_z q_\phi(z|x) \ln \frac{P_\theta(x, z)}{q_\phi(z|x)} - \int_z q_\phi(z|x) \ln \frac{P_\theta(z|x)}{q_\phi(z|x)} \quad (9)$$

式中： P_θ 为分布包含参数 θ ； q_ϕ 为分布包含参数 ϕ 。公式的前一项为证据下界项(Evidence Lower Bound,简称ELBO),为对数似然函数的证据下界,后一项为Kullback-Leibler散度项(KL散度)恒大于0。最大化似然函数问题即最大化ELBO项。

VAE在推断模型中引入已知的参照分布 $q_\phi(z|x)$ 来代替真实分布。为使参照分布与真实分布尽量相似,使用KL散度来度量两分布之间的差异并在优化过程中使其最小化来求解参数 θ 和 ϕ 。将式(9)中的积分项由期望替代后,得到VAE的优化目标为

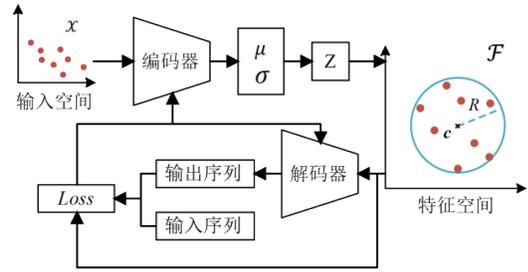


图7 VAE-SVDD训练流程图

Fig. 7 VAE-SVDD training process

模型的优化目标是 minimized 所有正常样本在特征空间中与超球体球心 c 的评价距离,同时最大可能保留输入序列的重建能力,对于一个训练数据集 $X = \{x_1, \dots, x_n\} \subseteq \mathbf{R}^d$,将VAE-SVDD的目标函数定义为

检测的敏感度。

对于一个测试样本序列 $x_i \subseteq \mathbf{R}^d$,VAE-SVDD模型的异常分数可以表示为

$$s(x) = \left\| \varphi((x_i - c); \phi^*) \right\|^2 \quad (12)$$

式中: ϕ^* 为训练后的 VAE 编码器参数; c 为训练后模型的球心; $s(x)$ 为测试样本的异常分数, 当 $s(x) \geq R$ 时, 测试样本序列被标注为异常样本。

VAE-SVDD 模型作为一个生成模型, 不只是像 VAE 一样直接对隐变量进行建模, 而是通过隐变量 z 的分布, 尽可能地表示所有正常样本的相似特征, 从而实现对所有正常样本的建模。相较于一般的 DeepSVDD, 所提模型能够从原始数据中提取更重要、更敏感的特征实现时间序列的异常检测功能。

2.3 LSTM-VAE-SVDD 航空发动机时间序列异常检测模型

LSTM-VAE-SVDD 异常检测模型主要由训练模块和执行模块两部分组成, 其结构如图 8 所示。

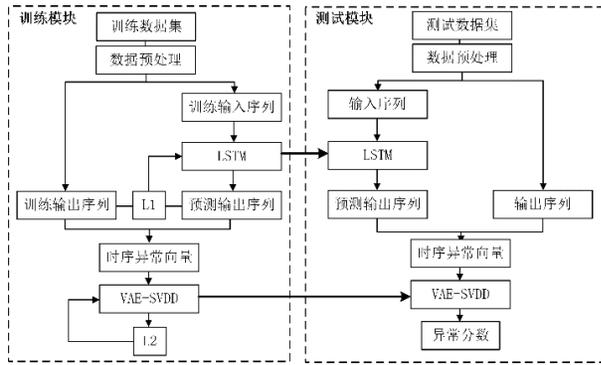


图 8 LSTM-VAE-SVDD 异常检测模型流程图

Fig. 8 LSTM-VAE-SVDD anomaly detection model flowchart

训练数据集由正常的时间序列样本组成, 各部件的多维样本序列在经过数据降噪、平滑及数据清洗等预处理工作后, 首先被划分为输入序列和输出序列, 分别对应该部件的输入信号和输出信号。对输入信号和输出信号进行时间窗口分割进行数据重构, 重构后的数据作为 LSTM 模型的输入和输出数据集。

通过 LSTM 模型构建各部件的时间序列模型, 基于部件输入序列输出对应的输出序列, 该过程中, 损失函数 L_1 取均方误差损失 (MSE), 计算如下:

$$L_1 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (13)$$

式中: $y = (y_1, \dots, y_n) \subseteq \mathbf{R}^n$ 为训练输出序列; $\hat{y} = (\hat{y}_1, \dots, \hat{y}_n) \subseteq \mathbf{R}^n$ 为预测输出序列。

通过优化器根据损失函数 L_1 逐步更新 LSTM 模型中的网络参数, 直至模型收敛, 完成 LSTM 时间序列预测模型构建。

LSTM 完成训练后, 将 LSTM 模型的预测输出序列与训练集的真实输出序列向量合并为一个时序差异向量, 构建正常样本的时序差异数据集, 训练得到正常工作的异常检测模型 VAE-SVDD, 损失函数 L_2 计算如式 (10)。通过优化器根据损失函数 L_2 逐步更新 VAE-SVDD 模型中的 VAE 网络参数, 直至模型收敛, 完成构建 VAE-SVDD 异常检测模型。

将训练好的 LSTM 模型和 VAE-SVDD 模型用于在线异常检测, 各部件的输入序列经过 LSTM 模型后输出对应的预测输出序列, 与实际输出序列合并为时序异常向量, 通过训练后的 VAE-SVDD 模型获取该时刻的样本异常分数, 若预测输出序列与实际输出序列差异较大, 说明部件该时刻偏离正常工作情况, 模型反映为较大的异常分数, 并给出异常诊断报警信号。

LSTM-VAE-SVDD 模型是一种两步时间序列异常检测模型。首先通过数据预处理和 LSTM 模型对航空发动机时间序列模型进行数据重构和预测。相较于直接使用异常检测模型或使用时间序列重构误差法的异常检测, 增加一个 LSTM 模型可以对数据实现更优的特征提取, 为后续的异常检测模型提取更重要的分类特征。VAE-SVDD 异常检测模型是一种无监督的异常检测深度网络, 对于存在数据偏斜的航空发动机故障诊断数据, VAE-SVDD 模型可以通过学习大量的正常工作样本实现对少量异常样本的高精度分类。

3 实验与结果分析

本文实验使用 Python3.7 版本作为基础编程语言, 使用 PyTorch-2.0、cuda-11.8 实现和测试, 全部实验在一台使用 Windows 11、Intel Core i7-12650H、NVIDIA GeForce RTX 4060、16 GB 内存的计算机上运行。

3.1 基准模型

本文选择 5 个最近两年被广泛应用且效果最

优的异常检测模型方案作为基准模型^{[22][31]},以验证本文所提方案的性能优势。基准模型的参数均使用原文中的最优参数。

孤立森林是一种基于决策树的算法^[32],从给定的特征集合,递归地分割样本点,直到所有数据点被孤立。根据平均路径长度来区分正常和异常数据点:较短的路径表示异常,较长的路径表示正常的观测。

OmniAnomaly^[33]是一个结合了门控循环单元(Gated Recurrent Unit,简称GRU)和VAE的随机循环神经网络模型,通过学习多元时间序列的正常模式,并使用重构概率判定异常。

GANomaly是一种编码器—解码器—编码器流程的对抗自动编码器^[34-35],捕获潜在向量空间内的训练样本分布,通过异常分数判断异常。

FGDAE(Full Graph Dynamic Autoencoder)是一种针对机械复杂工况专门设计的异常检测自编码器模型^[36],通过全连接图(Full Connected Graph,简称G)获取全局结构信息,使用图自适应编码器(Graph Adaptive Autoencoder,简称GAAE)模型适应多种工况在不平衡数据训练模型的情况下能够进行高精度的异常检测。

TranAD(Transformer-based Anomaly Detection Model)是一个基于Transformer网络的异常检测模型^[37],使用基于注意力的序列编码器,在了解数据中更广泛的时间趋势的情况下,迅速进行推理,通过异常分数判断异常。

基准模型训练过程中,将各部件的输入输出特征合并为多维时间序列矩阵,作为模型的训练集。除孤立森林方法外,其余四种深度异常检测基准模型均使用MSE作为损失函数,计算如式(13)所示训练轮次为300轮,根据实验对各模型选取合适的梯度下降学习率。使用章节1中得到的3个航空发动机试验台的训练集上进行异常检测模型训练,得到对应航空发动机部件级故障诊断模型,用于后续试验台实际评估测试。

3.2 实验指标

通过精确率 P 、召回率 R 和 F_1 分数对比评估所提模型的时间序列异常检测性能。

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

$$F_1 = \frac{2 * P * R}{P + R} \quad (16)$$

式中: TP 为被正确检测的异常样本点数; FP 为被误判为异常的正常样本点数; FN 为被误判为正常的异常样本点数。 P 可以反映模型对正常时间序列的检测稳定性, R 反映异常时间序列被检测的概率,即对异常点检测的敏感性, F_1 分数综合反映模型的整体性能。

另外,本文引入接受者操作特征曲线下面积(Area Under Curve,简称AUC)以进一步评估模型的预测能力,AUC值越高,说明模型的异常检测性能越好。

3.3 LSTM-VAE-SVDD调参

为获得适用于航空发动机建模的最佳参数,结合工程经验与尝试对LSTM-VAE-SVDD模型进行调参工作,调参工作基于机械液压附件数据集开展。所提LSTM-VAE-SVDD模型主要超参数包括LSTM隐藏层数量 L_{LSTM} 、VAE-SVDD的隐藏层数量 L_{VAE} 及宽容参数 μ 。取AUC值最高的参数组合为所需。调参记录如表3所示,当 L_{LSTM} 取4, L_{VAE} 取8, μ 值取0.8时,AUC值最高为0.9785,初步选定该组合为LSTM-VAE-SVDD模型的参数。

表3 LSTM-VAE-SVDD调参记录
Table 3 LSTM-VAE-SVDD parameters selected record

超参数	L_{LSTM}	L_{VAE}	μ	特征曲线下面积
1	4	4	0.5	0.8463
2	4	8	0.5	0.9667
3	8	4	0.5	0.9014
4	8	8	0.5	0.9432
5	4	4	0.8	0.9632
6	4	8	0.8	0.9785
7	8	4	0.8	0.8361
8	8	8	0.8	0.9452

3.4 半物理试验台模型评估与分析

将训练得到的模型部署在航空发动机半物理试验台上,在实际工程中开展实际异常检测测试,评估共6个对比模型的精确率、召回率、 F_1 分数和特征曲线下面积值,结果如表4所示。

表4 各模型在不同部件异常检测上的实验结果
Table 4 Experimental results of different models on anomaly detection of different components

部件	机械液压附件				电传系统				采集模块			
	P	R	特征曲线下面积	F_1	P	R	特征曲线下面积	F_1	P	R	特征曲线下面积	F_1
IF	0.754 8	0.623 5	0.893 2	0.682 9	0.748 7	0.862 3	0.884 5	0.801 5	0.980 3	0.802 6	0.978 6	0.882 6
OmniAnomaly	0.897 8	0.756 6	0.912 5	0.821 1	0.735 2	0.765 2	0.896 7	0.749 9	0.978 2	0.862 3	0.985 4	0.916 6
GANomaly	0.884 1	0.457 8	0.876 6	0.603 2	0.799 5	0.874 6	0.902 2	0.835 4	0.998 5	0.798 5	0.990 2	0.887 4
FGDAE	0.901 5	0.745 8	0.899 5	0.803 3	0.842 1	0.963 1	0.961 1	0.859 4	0.984 5	0.831 7	0.964 3	0.841 5
TranAD	0.923 5	0.884 6	0.924 7	0.903 6	0.865 3	0.945 2	0.952 6	0.903 5	0.999 2	0.845 2	0.998 4	0.915 8
LSTM-VAE-SVDD	0.953 3	0.896 3	0.978 5	0.923 9	0.854 9	0.989 9	0.985 9	0.917 5	0.998 0	0.865 7	0.998 9	0.927 2

将表4中的实验结果按照部件分别绘制柱状图,以便直观地比较各模型在不同部件异常检测任务中的性能指标,如图9~图11所示。

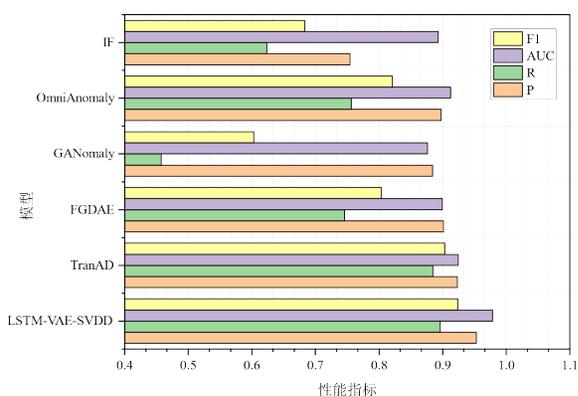


图9 机械液压附件异常检测结果柱状图
Fig. 9 Bar chart of abnormal detection results for mechanical hydraulic attachments

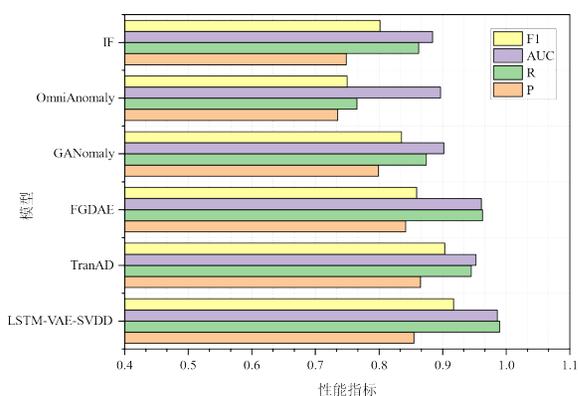


图10 电传系统异常检测结果柱状图
Fig. 10 Bar chart of abnormal detection results for telex system

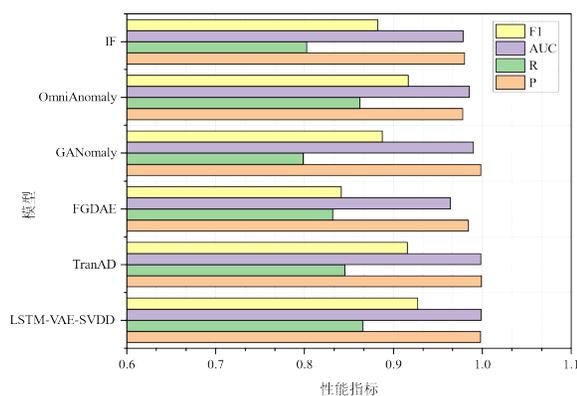


图11 采集模块异常检测结果柱状图
Fig. 11 Bar chart of abnormal detection results for the collection module

从图9~图11可以看出:

1) 精确率与召回率分析。在6种对比模型中,TranAD在2个部件上取得了最高的精确率,但在这两个部件上其召回率远低于所提方法,可以表明,TranAD在精确率上有超过所提方法的表现,其原因是将异常样本拟合为正常,这与本文实现异常检测的目的相违背。所提方法在一个部件上取得最高的精确率,在所有部件上均取得了最高的召回率,且平均精确率和召回率均为最高,可以认为,所提方法在对比方法中,具有最好的识别异常样本的能力。

2) F_1 分数与特征曲线下面积对比。所提方法在3个异常检测任务上均达到了最高的 F_1 分数和AUC值,其平均AUC值(0.987 8)高出第二的TranAD(0.958 6)2.92%,平均 F_1 分数(0.922 8)高出第二的TranAD(0.907 6)1.67%。可以得出在整个航空发动机试验台异常检测任务中,所提

模型比其他基准模型都有更高的异常检测综合性能。

3) 收敛性对比。4种深度学习方法在机械液压附件数据集上的损失函数绘制如图12~图15所示,本文所提方法损失函数如图16所示。

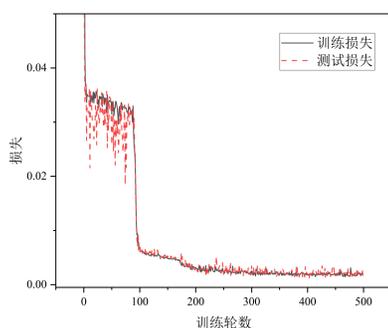


图12 OmniAnomaly损失图
Fig. 12 OmniAnomaly loss diagram

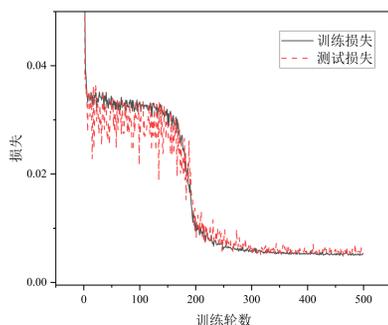


图13 GANomaly损失图
Fig. 13 GANomaly loss diagram

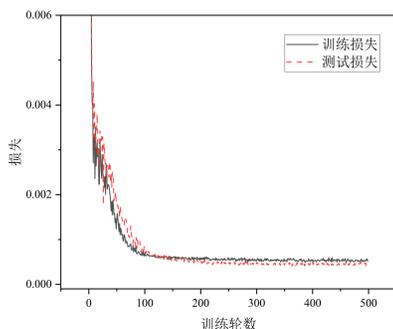


图14 FGDAE损失图
Fig. 14 FGDAE loss diagram

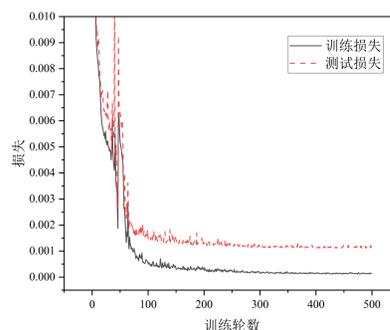


图15 TranAD损失图
Fig. 15 TranAD loss diagram

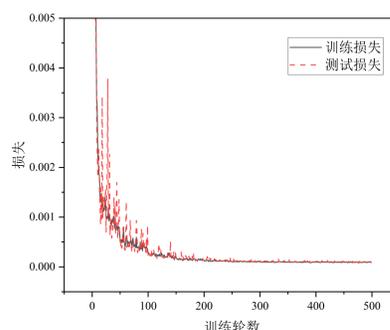


图16 LSTM-VAE-SVDD损失图
Fig. 16 LSTM-VAE-SVDD loss diagram

OmniAnomaly、FGDAE和GANomaly模型在200轮以上趋于收敛,而TranAD和所提模型在100轮次左右即基本收敛,且可收敛到更低的损失值,具有更好的收敛性。另外,所提模型相较于TranAD模型可以获得更低的测试损失,即训练得到的模型更拟合于测试集。

3.5 消融实验

为研究模型各模块的功能和效果,在所提模型的基础上删除一些主要模块,评估模型的性能变化。

LSTM:删除模型中的VAE-SVDD模块,仅使用LSTM模型预测输出时间序列,直接通过预测输出和实际输出序列的MSE损失作为异常分数。

VAE:删除模型中的LSTM和SVDD模块,输入输出特征合并为多维时间序列矩阵,作为模型的训练集,使用MSE损失作为异常分数。

LSTM-VAE:删除模型中的SVDD模块,使用LSTM模型预测输出时间序列,合并预测输出

序列和真实输出序列作为时序差异向量,通过VAE模型的正态分布作为异常分数。

LSTM-DeepSVDD: 删除 VAE-SVDD 模型中的 VAE, 使用多层感知机取代 VAE。

在航空发动机试验台 3 个部件级数据集上评估消融实验各对比方法的平均精确率、召回率、F1 分数和 AUC 值, 结果如表 5 所示。

表 5 LSTM-VAE-SVDD 模型的消融实验结果
Table 5 Ablation experimental results of LSTM-VAE-SVDD model

模型	P	R	特征曲线下面积	F ₁
LSTM	0.684 2	0.702 1	0.886 3	0.693 0
VAE	0.745 1	0.657 4	0.854 8	0.698 5
LSTM-VAE	0.896 5	0.751 3	0.950 2	0.817 5
LSTM-DeepSVDD	0.921 4	0.898 6	0.976 3	0.909 9
LSTM-VAE-SVDD	0.935 4	0.917 3	0.987 8	0.922 8

将表 5 的结果绘制为柱状图, 更直观地比较各对比方法的性能指标, 如图 17 所示。

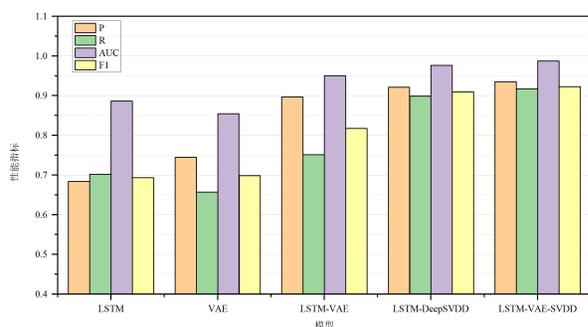


图 17 消融实验性能指标柱状图

Fig. 17 Bar chart of performance indicators for ablation experiments

从图 17 可以看出: LSTM 和 VAE 模型的各方面指标均低于融合模型, 说明了本文所提的首先根据输入序列预测输出序列, 再与实际序列构建时序异常向量的时间序列异常检测流程对航空发动机部件级异常检测的适应性。LSTM-VAE 算法虽在精确率上与所提模型相差不多, 但其召回率远低于所提模型, 说明 SVDD 在模型中极大提升了对异常样本检测的敏感性。LSTM-DeepSVDD 模型的精确率、AUC 和 F1 分数均有明显下降, 说明在 DeepSVDD 中引入 VAE 可以极大程度提升 DeepSVDD 的异常检测综合性能。

综上, 本文所提 LSTM-VAE-SVDD 模型在航空发动机部件级故障的异常检测任务中, 具有较强的适应性能, 且具有优越的异常检测表现, 可以作为一种航空发动机部件级异常检测流程投入应用。

4 结 论

1) 基于异常检测算法 DeepSVDD, 结合 VAE 和 LSTM, 构建了 LSTM-VAE-SVDD 的航空发动机时间序列异常检测模型。

2) 在某型航空发动机半物理试验中评估所提模型的故障诊断表现, 所提模型可以有更高的诊断精度。

3) 所提模型可以在更少的训练时间下得到高精度的模型。

综上, 本模型可以作为一种全新的航空发动机部件级异常检测模型, 也可作为时间序列异常检测的通用框架, 应用在航空航天及旋转机械故障诊断的其他任务中。

本文仅讨论了模型的异常检测性能, 没有考虑模型机载的可行性。未来的研究中将重点考虑模型的轻量化, 在保证模型精度的同时优化模型的深度和计算速度, 提高模型的实时性, 将模型的应用对象从半物理仿真试验台拓展到航空发动机地面试车试验台, 进一步再拓展至实际机载, 为构建实时机载的航空发动机部件级故障诊断系统提供可能。

参考文献

- [1] 张振良, 何荣荣, 张鉴靓. 基于云模型 SDG 的航空发动机多工况故障诊断方法[J]. 航空发动机, 2022, 48(6): 42-48.
ZHANG Zhenliang, HE Rongrong, ZHANG Jianliang. Multi-condition fault diagnosis method of aeroengine based cloud model SDG [J]. Aeroengine, 2022, 48(6): 42-48. (in Chinese)
- [2] 甘晓华, 李伟. 现役航空发动机使用寿命确定和控制方法[J]. 航空工程进展, 2010, 1(2): 103-106.
GAN Xiaohua, LI Wei. A summary of military aero-engine life determination methods [J]. Advances in Aeronautical Science and Engineering, 2010, 1(2): 103-106. (in Chinese)
- [3] 胡明辉, 高金吉, 江志农, 等. 航空发动机振动监测与故障诊断技术研究进展[J]. 航空学报, 2024, 45(4): 7-35.
HU Minghui, GAO Jinji, JIANG Zhinong, et al. Research

- progress on vibration monitoring and fault diagnosis for aero-engine[J]. *Acta Aeronautica et Astronautica Sinica*, 2024, 45(4): 7-35. (in Chinese)
- [4] 严如强, 许文纲, 王志颖, 等. 航空发动机燃油控制系统故障诊断技术研究进展与挑战[J]. *机械工程学报*, 2024, 60(4): 3-31.
YAN Ruqiang, XU Wengang, WANG Zhiying, et al. Research status and challenges on fault diagnosis methodology for fuel control system of aero-engine[J]. *Journal of Mechanical Engineering*, 2024, 60(4): 3-31. (in Chinese)
- [5] 刘剑, 任和. 航空发动机滑油系统故障诊断技术研究进展[J]. *应用技术学报*, 2023, 23(4): 349-357.
LIU Jian, REN He. Progress of fault diagnostics of aero-engine lubricating oil system[J]. *Journal of Technology*, 2023, 23(4): 349-357. (in Chinese)
- [6] 崔建国, 李勇, 王景霖, 等. 航空发动机的 IGWO-KELM 故障诊断方法[J]. *机械设计与制造*, 2023(12): 36-40.
CUI Jianguo, LI Yong, WANG Jinglin, et al. IGWO-KELM fault diagnosis method of aero-engine[J]. *Machinery Design and Manufacture*, 2023(12): 36-40. (in Chinese)
- [7] 赵洪利, 杨佳强. 基于融合卷积 Transformer 的航空发动机故障诊断[J/OL]. *北京航空航天大学学报*: 1-14[2024-03-10]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0206>. ZHAO Hongli, YANG Jiaqiang, Aero-engine fault diagnosis based on fusion convolutional transformer[J/OL]. *Journal of Beijing University of Aeronautics and Astronautics*: 1-14. <https://doi.org/10.13700/j.bh.1001-5965.2023.0206>. (in Chinese)
- [8] 伍济钢, 文港, 杨康. 改进注意力机制的航空发动机试验转子系统智能故障诊断[J]. *振动与冲击*, 2024, 43(4): 261-269.
WU Jigang, WEN Gang, YANG Kang, Improved attention mechanism for intelligent fault diagnosis of experimental rotor systems in aero engines[J]. *Journal of Vibration and Shock*, 2024, 43(4): 261-269. (in Chinese)
- [9] 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.
- [10] 胡珉, 白雪, 徐伟, 等. 多维时间序列异常检测算法综述[J]. *计算机应用*, 2020, 40(6): 1553-1564.
HU Min, BAI Xue, XU Wei, et al. Review of anomaly detection algorithms for multidimensional time series[J]. *Journal of Computer Applications*, 2020, 40(6): 1553-1564. (in Chinese)
- [11] LIU Y, LIU Z, ZUO H, et al. A DLSTM-network-based approach for mechanical remaining useful life prediction[J]. *Sensors*, 2022, 22(15): 5680.
- [12] 黄续芳, 赵平, 冯铃, 等. 基于 Bi-GRU 模型的航空发动机外部液压管路故障诊断研究[J]. *机床与液压*, 2023, 51(11): 224-232.
HUANG Xufang, ZHAO Ping, FENG Ling, et al. Research on fault diagnosis of external hydraulic pipeline of aero-engine based on Bi-GRU model[J]. *Machine Tool & Hydraulics*, 2023, 51(11): 224-232. (in Chinese)
- [13] 马帅, 吴亚锋, 郑华, 等. 基于改进 LSTM 的航空发动机气路参数预测方法[J]. *测控技术*, 2024, 43(2): 1-10.
MA Shuai, WU Yafeng, ZHENG Hua, et al. Aircraft engine gas path parameter prediction based on improved LSTM[J]. *Measurement & Control Technology*, 2024, 43(2): 1-10. (in Chinese)
- [14] 赵万里, 郭迎清, 杨菁, 等. 基于 ARMA 的航空发动机传感器故障诊断及实时验证[J]. *航空计算技术*, 2022, 52(1): 16-20.
ZHAO Wanli, GUO Yingqing, YANG Jing, et al. Aero-engine sensor fault diagnosis and real-time verification based on ARMA model[J]. *Aeronautical Computing Technique*, 2022, 52(1): 16-20. (in Chinese)
- [15] 刘振刚. 基于试飞数据的航空发动机典型故障诊断技术[J]. *自动化应用*, 2023, 64(10): 179-181.
LIU Zhengang. Typical aeroengine fault diagnosis technology based on flight test data[J]. *Automation Application*, 2023, 64(10): 179-181. (in Chinese)
- [16] REN L H, YE Z F, ZHAO Y P. Long short-term memory neural network with scoring loss function for aero-engine remaining useful life estimation[J]. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 2023, 237(3): 547-560.
- [17] WANG M, WANG H, CUI L, et al. Remaining useful life prediction for aero-engines based on time-series decomposition modeling and similarity comparisons[J]. *Aerospace*, 2022, 9(10): 609.
- [18] LIN L, HE W, FU S, et al. Novel aeroengine fault diagnosis method based on feature amplification[J]. *Engineering Applications of Artificial Intelligence*, 2023, 122: 106093.
- [19] 刘海瑞, 武宪威, 李鹏, 等. 基于 APSO-LSSVM 的航空发动机轴承故障诊断及寿命预测[J]. *测控技术*, 2024, 43(1): 70-76.
LIU Hairui, WU Xianwei, LI Peng, et al. Fault diagnosis and life prediction of aeroengine bearings based on APSO-LSSVM[J]. *Measurement & Control Technology*, 2024, 43(1): 70-76. (in Chinese)
- [20] 周卓峰, 刘伟, 喻鸣. 基于特征提取的航空发动机滚动轴承故障诊断[J]. *内燃机与配件*, 2023(8): 43-45.
ZHOU Zhuofeng, LIU Wei, YU Ming. Fault diagnosis of aero-engine rolling bearing based on feature extraction[J]. *Internal Combustion Engine & Parts*, 2023(8): 43-45. (in Chinese)
- [21] 孙昊, 付旭云, 钟诗胜. 基于慢特征密度聚类的气路异常检测方法[J]. *航空动力学报*, 2021, 36(10): 2218-2229.
SUN Hao, FU Xuyun, ZHONG Sshisheng. Slow feature

- density clustering-based gas path anomaly detection method [J]. 2021, 36(10): 2218-2229. (in Chinese)
- [22] JIN H J, ZHAO Y P, WANG Z Q. A rotating stall warning method for aero-engine compressor based on DeepES-VDD-CNN[J]. *Aerospace Science and Technology*, 2023, 139: 108411.
- [23] YU Y, SI X, HU C, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. *Neural computation*, 2019, 31(7): 1235-1270.
- [24] JIANG Y, HOU X R, WANG X G, et al. Identification modeling and prediction of ship maneuvering motion based on LSTM deep neural network [J]. *Journal of Marine Science and Technology*, 2022, 27(1): 125-137.
- [25] LIU Y Q, GONG C Y, YANG L, et al. DSTP-RNN: a dual stage two-phase attention-based recurrent neural network for long-term and multivariate time series prediction [J]. *Expert Systems with Applications*, 2020, 143: 113082.
- [26] RUFF L, VANDERMEULEN R, GÖERNITZ N, et al. Deep one-class classification [C] // 35th International Conference on Machine Learning. US: IEEE, 2018: 6981-6996.
- [27] 康颖, 赵治华, 吴灏, 等. 基于Deep SVDD的通信信号异常检测方法 [J]. *系统工程与电子技术*, 2022, 44(7): 2319-2328.
KANG Ying, ZHAO Zhihua, WU Hao, et al. Deep SVDD-based anomaly detection method for communication signals. *Systems Engineering and Electronics*, 2022, 44(7): 2319-2328. (in Chinese)
- [28] ZHOU Y, LIANG X, ZHANG W, et al. VAE-based deep SVDD for anomaly detection [J]. *Neurocomputing*, 2021, 453: 131-140.
- [29] ZHANG Z, DENG X. Anomaly detection using improved deep SVDD model with data structure preservation [J]. *Pattern Recognition Letters*, 2021, 148: 1-6.
- [30] KINGMA D P, WELING M. Auto-encoding variational bayes [C] // 2nd International Conference on Learning Representations. US: IEEE, 2014: 1-8.
- [31] HAN S, HU X, HUANG H, et al. Adbench: anomaly detection benchmark [J]. *Advances in Neural Information Processing Systems*, 2022, 35: 32142-32159.
- [32] LESOUPLE J, BAUDOIN C, SPIGAI M, et al. Generalized isolation forest for anomaly detection [J]. *Pattern Recognition Letters*, 2021, 149: 109-119.
- [33] SU Y, ZHAO Y, NIU C, et al. Robust anomaly detection for multivariate time series through stochastic recurrent neural network [C] // The 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. US: IEE, 2019: 2828-2837.
- [34] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Ganomaly: semi-supervised anomaly detection via adversarial training [C] // 14th Asian Conference on Computer Vision. Perth, Australia: Springer International Publishing, 2019: 622-637.
- [35] LIU G, NIU Y, ZHAO W, et al. Data anomaly detection for structural health monitoring using a combination network of GANomaly and CNN [J]. *Smart Structure System*, 2022, 29(1): 53-62.
- [36] YAN S, SHAO H, MIN Z, et al. FGDAE: a new machinery anomaly detection method towards complex operating conditions [J]. *Reliability Engineering & System Safety*, 2023, 236: 109319.
- [37] TULI S, CASALE G, JENNINGS N R. Tranad: deep transformer networks for anomaly detection in multivariate time series data [EB/OL]. [2024-03-16]. <https://arxiv.org/pdf/2201.07284.pdf>.

(编辑:丛艳娟)