

# 基于 TPE-Informer 的列车风源系统故障预警研究 \*

翟鸿儒<sup>1</sup> 姚爱琴<sup>1</sup> 孙运强<sup>1</sup> 赵文强<sup>2</sup> 石喜玲<sup>2</sup>

(1. 中北大学信息与通信工程学院 太原 030051; 2. 中北大学电气与控制工程学院 太原 030051)

**摘要:**针对轨道交通列车的风源系统在每日高强度和负荷的运行环境下容易发生故障的问题,结合空气压缩机作为系统的核心部件受多种因素影响呈间歇性运行进而导致监测数据在时间维度上分布不均,现有基于连续运行数据的故障预警方法难以适用的情况,研究了一种适应列车风源系统的故障预警框架。首先结合不同类型数据的特点提取多维时序特征,并使用Informer模型学习正常数据特征,同时应用基于树结构的贝叶斯优化算法(TPE)优化模型参数。然后通过分析模型预测值与实际测量值的残差,提出了一种预警指标计算方法。在公开的列车风源故障数据集 MetroPT3 上的仿真实验结果表明,该预警框架最早于故障前 220 个周期发出预警,且最晚于前 22 个周期发出预警,并对误报具有良好的鲁棒性。

**关键词:**风源系统;空气压缩机;深度学习;故障预警

中图分类号: TH45; TN06 文献标识码:A 国家标准学科分类代码: 510.40

## Research on fault prognosis for air supply system based on TPE-Informer

Zhai Hongru<sup>1</sup> Yao Aiqin<sup>1</sup> Sun Yunqiang<sup>1</sup> Zhao Wenqiang<sup>2</sup> Shi Xiling<sup>2</sup>

(1. School of Information and Communication Engineering, North University of China, Taiyuan 030051, China;

2. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China)

**Abstract:** Addressing the susceptibility of rail transit air supply system to faults under high-intensity and high-load daily operations, this study presents a fault warning framework tailored to the intermittent operation of the core component, the air compressor. The framework is designed to handle the uneven temporal distribution of monitoring data due to various influencing factors. Multidimensional temporal features are extracted from different types of data, and the Informer model is utilized to learn the characteristics of normal operation, with the TPE algorithm optimizing model parameters. A method for calculating a warning index is proposed based on the analysis of residuals between predicted and actual measurements. Simulation experiments on the MetroPT3 Air Supply fault dataset confirm the framework's can issue warning signals as early as 220 cycles prior to a fault and as late as 22 cycles before the fault occurs, and exhibiting its robustness against false alarms.

**Keywords:** air supply system; air compressor; deep learning; fault prognosis

## 0 引言

轨道交通系统以其高效的运输能力、经济的运营成本、准时的运行特性和低事故率,在我国经济发展中发挥着重要作用。然而,随着运营规模的扩大和运行速度的提升,列车故障可能会带来严重的安全风险和财产损失。传统的事后维修方法已不适应现代需求,而预防性维护(preventive maintenance, PM)虽降低了故障概率,却增加了维护成本。

当前,预测性维护(predictive maintenance, PdM)正在逐渐成为运维策略的主流,其研究重点从故障检测逐渐转向故障预警。通过实时数据分析,利用物联网、传感器和机器学习等技术,PdM 能提前识别潜在故障征兆,及时预警故障减少意外损失,这在轨道交通领域尤为重要。

轨道交通列车由多个关键系统组成,其中风源系统为悬挂和制动等气动部件提供动力,是核心系统之一。李景州等<sup>[1]</sup>分析了风源系统的局部组件故障并结合工程经验

收稿日期:2024-07-09

\* 基金项目:青岛市科技成果转化专项园区培育计划(2311400010HX)、山西省自然科学基金(20210302123062)项目资助

给出故障处理办法。韦忠潮等<sup>[2]</sup>分析了系统压强开关故障问题并提出解决措施。丁景贤等<sup>[3]</sup>设计了风源等效故障模型,基于等效故障注入试验研究了5种典型故障模式在不同故障程度下的影响规律并分析了故障原因。Zuo等<sup>[4]</sup>同样通过建立气动制动系统的数学模型和仿真,优化了系统性能。刘治国等<sup>[5]</sup>设计了风源实时监测系统,根据监测数据掌握设备运行状态和压缩空气品质。Pinto等<sup>[6]</sup>同样设计了一个实时监测系统,通过分析风源系统的运行模式和历史故障报告,实现车辆活动和故障的实时监控。项宇航等<sup>[7]</sup>通过优化风源系统电气控制方案,提出相关故障自动检测逻辑。Meira等<sup>[8]</sup>结合半空间树方法和K近邻算法,开发了一个无监督故障检测模型。

现阶段针对风源系统故障问题的防范、预警与解决通常由人工操作完成,故障监测与诊断的及时性、准确性无法得到有效保证,常会导致不同程度的经济损失,而应用深度学习的故障预警研究目前更多集中于风电机组和滚动轴承等方面。周伟等<sup>[9]</sup>、刘河生等<sup>[10]</sup>、王鹏飞等<sup>[11]</sup>和马良玉等<sup>[12]</sup>通过改进的机器学习模型来建立健康指标与运行状态的映射关系,Choudhary等<sup>[13]</sup>利用被动热成像和卷积神经网络(CNN)结合迁移学习,Sun等<sup>[14]</sup>结合非线性全局局部保留投影和度量学习,Fu等<sup>[15]</sup>使用机器学习和数据图形化,张家安等<sup>[16]</sup>提出的基于多头注意力机制的多尺度卷积网络结合CNN和长短期记忆(LSTM)方法,以及Zhou等<sup>[17]</sup>的集合经验模态分解—主成分分析—自适应模糊神经网络(EEMD-PCA-ANFIS)模型,均致力于提高风电机组齿轮箱的故障预警能力。卢浩龙等<sup>[18]</sup>、袁镇华等<sup>[19]</sup>和Zhu等<sup>[20]</sup>采用Transformer、贝塔分布滤波降噪、双向LSTM(BiLSTM)和蜜獾算法(HBA)等技术,提高了滚动轴承故障预警的准确性和预警时间。

上述故障预警研究在风电机组齿轮和多种滚动轴承数据上取得了良好的效果,但其数据特点是相应设备持续运行直至故障且主要关注自身生命周期内数据变化,忽略系统内组件间的相互影响及外部控制因素。然而,在实际列车运行中,这些方法难以适应空压机呈间歇性运行的风源系统监测数据,导致预警效果不佳。

针对这一问题,本文研究了一种基于树结构的贝叶斯优化算法(tree-structured parzen estimator, TPE)-Informer的列车风源系统故障预警框架。该框架首先针对列车风源系统的测量数据特点,采用相应的特征提取方法,提取系统正常运行时的数据特征。然后,将这些正常数据的多维特征输入到Informer模型中进行训练,使模型学习设备正常特征模式。同时,利用TPE优化模型超参数,高效调整与特征数据相匹配的超参数组合。通过分析模型预测结果与真实数据的残差分布,提出了一种故障预警指标的计算方法。最后,使用含故障征兆信息的数据对模型进行验证。本文选用波尔图列车风源故障数据集MetroPT3进行仿真分析,验证了所提模型的预警有效性和误报鲁棒性。

## 1 列车风源系统数据分析

### 1.1 数据特点

列车风源系统由空气压缩机、空气干燥塔、油水分离器、总风缸、调压器和止回阀等关键组件构成,其中核心部件空气压缩机作为间歇性运行设备。与工作在稳定状态下的连续运行设备不同,其运行状态受系统负荷变化、关联部件工况和外部控制信号的变化影响,导致风源系统监测数据出现周期性波动,统计特性随时间变化。其中,外部控制信息(如临时检修、夜间停运等)具有较强的主观性与偶发性,可能导致数据出现突变或缺失<sup>[21]</sup>。针对上述数据特点,如果直接套用连续运行设备的数据处理及故障研究方法,而不解析间歇运行设备数据的特性,则故障预警效果显然是不理想的。

### 1.2 数据特征提取

基于数据驱动的故障研究所采集的运行数据一般包含3类,时间戳信息、模拟信号和数字信号。

时间戳数据记录了监测数据变化的具体时间点,用于同步和分析数据信息,格式为一般为国际标准的ISO 8601格式:YYYY-MM-DDTHH:mm:ss,sssZ。其中,YYYY代表四位数年份,MM代表月份,DD代表天数,T作为日期和时间的分隔符,HH代表小时,mm代表分钟,ss代表秒,Z代表时区(例如2024-04-24T15:30:00Z)。后续可以根据具体的任务需求,方便地提取时间维度信息进行特征编码,如第几季度、第几周、工作日、节假日、早中晚等。

模拟信号记录了系统实时运行中相关模拟变化量的变化情况信息,如温度、压强、流量、电压、电流等。由于受到外部控制以及系统载荷的变化影响,空压机每个运行周期的运行时长和数据变化规律存在差异,而为了方便后续数据的分析,需要对数据规范化处理。常见的数据规范化处理包括截断、重采样、池化等。这些处理方法都需要先验知识来确定处理的尺度信息,且容易发生信息丢失的问题。本文采用积分的方式来融合单周期运行时长和数据变化波动信息。定积分公式为:

$$\lim_{n \rightarrow \infty} \sum_{i=1}^n f \left[ a + \frac{i}{n}(b-a) \right] \frac{b-a}{n} = \int_a^b f(x) dx \quad (1)$$

式中:被积函数  $f(x)$  为待计算的模拟信号,积分区间  $[a, b]$  表示了单周期内运行时长信息。通过积分计算可以有效地将运行时间和数据变化两个关键信息有效地融合在积分面积中,降低数据量的同时减少计算量,有助于提高后续预警系统的实时性。风源系统的空压机数据包含了丰富的动作信息,如图1所示。

图1中,TP3为风缸压强值,明显看出其呈周期性波动。故可将每个压机运行周期的数据分为充气负载段与空闲段,分别计算每个时间段的各个模拟量的融合特征。

数字数据主要分为控制信号和状态指示。控制信号记录了各部件的启停指令。由于模拟量的积分区间划分

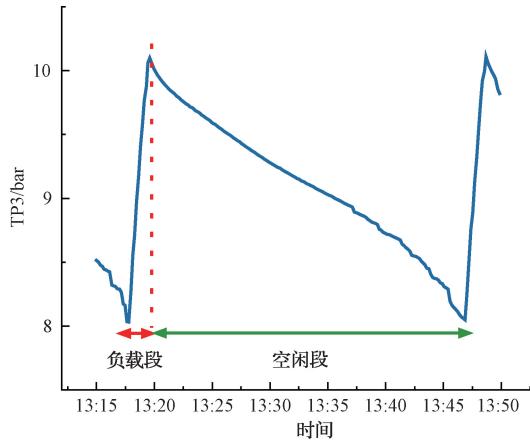


图 1 单周期内的模拟数据

Fig. 1 Simulation data in a single cycle

是以控制动作信号为分界,因此在每个运行周期内的单个分段中,控制信号一般为固定的某个数字量而无其他信息。因此本文采取计算各部件启停时长比值  $R_i$  来表征控制信息,如下:

$$R_i = \frac{(T_i^{Run})}{(T_i^{Idle})} \quad (2)$$

式式:  $R_i$  表示第  $i$  个部件的启停时长比;  $T_i^{Run}$  表示运行时长;  $T_i^{Idle}$  同理为空闲时长。

状态指示记录了设备的工作状态,如故障重置、维护活动、待机、局部状态异常等。一般在每个运行周期数据中处于非激活状态,故本文统计每个周期中状态指示激活量的个数。

## 2 故障预警框架的建立

### 2.1 Informer 模型

目前处理时间序列任务常用的神经网络模型主要有 RNN、LSTM、Transformer 和 Informer,它们都基于编码器—解码器架构来处理序列到序列的任务。编码器将可变长度的源序列转换为固定形状的状态向量,解码器再将这些状态向量映射回目标序列进行预测。RNN 和 LSTM 在处理长序列时容易遗忘信息,且可能遇到梯度消失或爆炸问题。Transformer 通过注意力机制提高远程依赖关系的捕捉能力,但计算量大,对硬件要求高。Informer<sup>[22]</sup>是 Transformer 的改进版,其模型结构如图 2 所示,通过多尺度编解码器、稀疏自注意力机制和生成式解码器,提高了效率和预测速度,同时减少了计算复杂度。

编码器的输入  $X_{feed\_en}^t$  主要有特征向量、位置信息、时间信息 3 部分构成,计算公式如下:

$$X_{feed\_en}^t = \alpha u_i^t + P_{(L_x^{(t-1)+i})} + \sum_p [S_{(L_x^{(t-1)+i})}]_p \quad (3)$$

式中:  $\alpha u_i^t$  为时序数据通过一维卷积映射的高维特征向量;  $L_x$  表示输入序列的长度;  $\sum_p [S_{(L_x^{(t-1)+i})}]_p$  为全局时间截编码信息;  $P_{(L_x^{(t-1)+i})}$  为位置编码综合信息。采用了

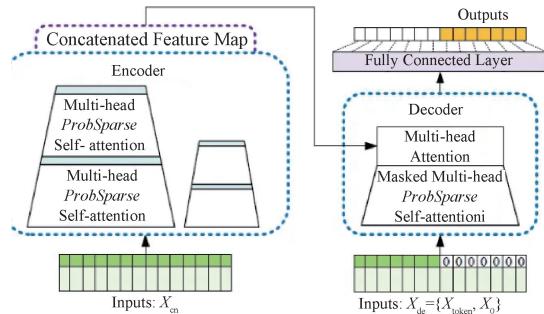


图 2 Informer 模型结构

Fig. 2 Informer model structure

固定位置编码,位置嵌入矩阵  $P$  的第  $i$  行、第  $2j$  列和  $2j+1$  列上元素的计算公式如下:

$$P_{i,2j} = \sin\left(\frac{i}{10000^{2j/d}}\right) \quad (4)$$

$$P_{i,2j+1} = \cos\left(\frac{i}{10000^{2j/d}}\right) \quad (5)$$

第  $i$  行代表词元在序列中的位置,第  $2j$  列和  $2j+1$  列代表位置编码的不同维度,映射特征的维度  $d$ 。输入  $X_{feed\_en}^t$  通过的  $h$  组不同的线性变换后获得活跃查询向量  $Q$ 、键向量  $K$ 、值向量  $V$ , 分别代表了输入序列中重要的学习信息以及数据之间相关关系。然后通过稀疏自注意力,计算公式如下:

$$Attention = (Q, K, V) = \text{softmax}\left(\frac{\bar{Q}K^T}{\sqrt{D_K}}\right) \cdot V \quad (6)$$

式中:  $Q$  通过概率稀疏获得的矩阵  $\bar{Q}$ ;  $D_k$  是  $Q$  和  $K$  的维度;  $\text{softmax}(\cdot)$  为归一化激活函数。最后将这  $h$  个注意力汇聚的输出拼接一起实现多头稀疏自注意力机制,并经由蒸馏层缩小网络参数,赋予主导特征更高的权重并在下一层生成集中特征图,降低了内存占用。

解码器的输入包括编码器生成的中间特征序列和一些 0 值(代表待预测的数据)。它利用这些特征进行注意力运算,调整输出数据的维度,并使用掩码(Mask)防止时间上的预测错误,最终输出预测结果。

### 2.2 基于 TPE 的模型参数优化

Informer 模型由于参数众多,如预测长度、掩码长度、注意力头数等,对性能有显著影响。传统的网格搜索和随机搜索在调参时成本高且耗时长。本文采用 TPE 自适应调整寻参范围,对输入超参数  $x$  和输出优化目标  $y$  的条件概率分布  $p(x|y)$  和边缘概率分布  $p(y)$  分别建模,通过贝叶斯公式计算后验概率分布  $p(y|x)$ 。首先使用两个密度函数来定义条件概率分布  $p(x|y)$ ,如下:

$$p(x|y) = \begin{cases} l(x), & y < y^* \\ g(x), & y \geq y^* \end{cases} \quad (7)$$

式中:  $l(x)$  是根据观测空间  $\{x^{(i)}\}$  来建立的概率分布,该观测空间对应的损失  $y = f(x^{(i)})$  小于某个阈值  $y^*$ , 使用

剩下的观测点来建立  $g(x)$ 。

选择期望改进(expected improvement, EI)作为采集函数来确定在何处采集下一个样本点, 使用贝叶斯公式进行转换如下:

$$EI_{y^*}(x) = \int_{-\infty}^{y^*} (y^* - y) \frac{p(x|y)p(y)}{p(x)} dy \quad (8)$$

令  $\gamma = p(y < y^*)$  表示  $y$  的分位数, 用于划分  $l(x)$  和  $g(x)$ , 范围在 0~1 之间。上述公式的分母可以构造为:

$$p(x) = \gamma l(x) + (1 - \gamma)g(x) \quad (9)$$

分子可以构造为:

$$\gamma y^* l(x) - l(x) \int_{-\infty}^{y^*} y p(y) dy \quad (10)$$

最后, EI 简化为:

$$EI_{y^*}(x) \propto (\gamma + \frac{g(x)}{l(x)}(1 - \gamma))^{-1} \quad (11)$$

在后续每次迭代中, 返回具有最大 EI 的候选  $x^* = \arg \max EI_{y^*}(x)$ 。

### 2.3 基于 TPE-Informer 故障预警框架

列车空压系统的复杂性导致数据具有长期依赖和季节性等特征, 传统时序模型在处理这类数据时可能面临记忆丢失、高训练成本和梯度消失的问题。为了提高预测的准确性和效率, 本文提出了基于 TPE-Informer 模型的列车风源系统故障预测框架。这个框架分为离线训练和在线预测两个部分, 目的是让模型学习设备正常运行时的数据趋势, 并通过比较正常数据与异常数据的残差来实现故障预警, 预警框架示意图如图 3 所示。

离线训练部分首先对设备正常运行周期的健康数据进行特征融合和提取, 接着将特征输入到 Informer 模型离线训练, 使模型学习数据长期模式, 同时使用 TPE 算法优化模型超参数。在线预警阶段, 将包含故障信息的数据逐周期提取特征, 并送入 Informer 模型进行前向预测。通过比较预测值与实际值的残差, 并结合预警指标进行动态计算, 实现故障的在线预警。

#### 1) 残差分析

在计算预测与实际测量数据之间残差后, 考虑到设备老化和维修历史会影响残差数据的分布, 而对这些因素建模需要大量历史数据、专业知识和高昂成本, 且对不同设备泛化能力较差。此外不同于几乎无征兆的突发故障, 渐变故障发生前的数据会有较明显的异常波动, 这为故障预警提供了依据。

本文首先通过四分位距(interquartile range, IQR)来识别残差序列的离群异常值。IQR 通过排序数据并计算四分位数 Q1、Q2 和 Q3 之间的差距来衡量数据的变异性。IQR 值为 Q3 与 Q1 的差, 位于  $Q3 + KIQR$  或  $Q1 - KIQR$  之外的数据被视为离群异常值, 其中系数  $K$  的经验值为 1.5 和 3, 分别对应离群和极度离群。这种方法不需要对残差数据的分布做任何假设, 可以自适应地识别异常值。

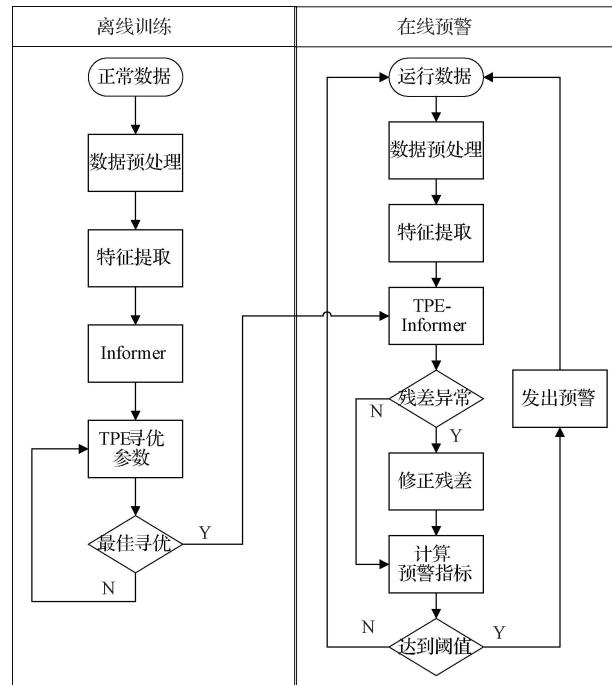


图 3 故障预警框架

Fig. 3 Fault prognosis framework

然而, 连续存在多个异常值时, IQR 准确率可能受影响。因此本文加入残差修正机制, 如果当前周期的残差是异常值, 则顺延前一个周期的残差作为当前周期的修正残差, 并以此进行下个周期的 IQR 分析。

同时, 检测到当前周期的残差异常时, 本文使用  $Z$  分数( $Z$ -score)量化其异常程度。通过将原始残差转换为标准正态分布的  $Z$  分数, 消除量级和残差分布变化的影响, 使得残差数据具有可比性。 $Z$  分数的计算公式如下:

$$Z = \frac{\tilde{X} - E[X]}{\sigma(X)/\sqrt{n}} \quad (12)$$

式中:  $\tilde{X} = 1/n \sum_{i=1}^n X_i$ ,  $X_i$  是原始残差数据的值,  $\sigma$  是标准差。通过计算异常残差点的  $Z$  分数, 将离群程度量化为偏离了正常残差波动均值几个  $\sigma$ , 方便后续预警指标计算。

#### 2) 预警指标的计算

目前许多故障预警研究中, 预警指标的计算和阈值设定通常基于经验, 例如残差超过某个阈值的次数或百分比。这种方法没有充分考虑残差的统计特性, 导致其泛化能力有限。考虑到列车风源系统运行数据受多种因素影响, 即使是健康状态, 残差偶尔也会有小幅波动。但随着故障征兆的加深, 残差的异常波动会变得更频繁和严重。所以本文综合考虑两种情况的数据特点, 提出了一种预警指标  $Pred$  计算方法如下:

$$Pred = \begin{cases} Pred^* + Z, & Z \neq 0 \\ Pred^* - 0.24, & Z = 0 \end{cases} \quad (13)$$

式中:  $Pred^*$  为前一周期的预警指标;  $Z$  为当前周期的残差  $Z$  分数。由于  $Z$  分数本质上是在用统计标准差来分析残差偏离程度,而实际工程应用中,也有同样基于统计标准差来分析数据异常与否的方法,如统计过程控制(statistical process control, SPC)。单变量 SPC 使用统计过程控制图(图 4)对单变量实时监控和评估,一般基于  $3\sigma$  规则去判定异常(约 0.3% 的概率),以便及时发现并消除系统性异常,保持过程稳定。图 4 的上下控制线(UCL 和 LCL)基于历史和实时数据设定,分为 3 个区域(A、B、C),每个区域界限对应一个标准差  $\sigma$ ,若图 4 中的点超出控制线或排列非随机,则表明存在异常。

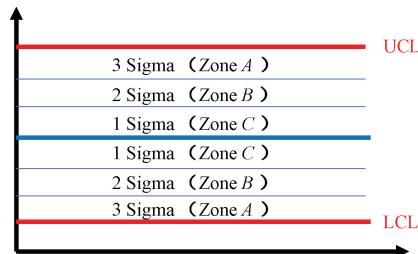


图 4 统计过程控制

Fig. 4 Statistical process control chart

预警指标  $Pred$  计算式中的 0.24 即参考了 SPC 中常用的  $3\sigma$  判异规则之一:最少统计 25 个数据,在连续 3 个数据中有两个数据在 A 区内(取极端情况为刚好两个  $\sigma = 3$ ),通过概率换算得到数据 0.24。对应实际预警情形的解释为考察过去 25 个周期,将“残差的  $Z$  分数连续两次超过  $2\sigma$ ”认为是正常波动的极端临界点,以这个为可接受极限来换算指标下降参数,预警指标  $Pred$  会随着周期的推进会有个逐渐下降的过程。当异常数据频繁出现时,累积量会快速上升,当超过  $3\sigma$  时报警。当异常数据偶尔出现时,累积量会随着正常周期的推移逐渐下降,降低了误报概率。

### 3 仿真分析

#### 3.1 数据处理与特征提取

为了验证前述预警框架的有效性,本文采用波尔图列车风源故障数据集 MetroPT3 进行仿真实验<sup>[23]</sup>。多变量时间序列数据的时间跨度从 2020 年 2~8 月,机载嵌入式设备以 10 Hz 的频率记录数据(共计采样点 10 W),包括 15 个特性量(7 个模拟信号和 8 个数字信号)如表 1 所示(1 bar=100 kPa=0.1 MPa),工业设备事件(如时间行为和故障事件)的监测和记录均从传感器生成。

表 1 数据集特征描述  
Table 1 Dataset characteristics

信号	描述	信号	描述
TP2	★ 压机输出压强/bar	DV electric	出口阀
TP3	★ 气动面板压强/bar	TOWERS	★ 干燥塔
H1	压机卸载压降/bar	MPG	压机启停
DV pressure	★ 干燥塔压降/bar	LPS	★ 低压警示
Reservoirs	储气室压强/bar	Pressure Switch	★ 干燥塔切换
Motor Current	★ 压机电流/A	Oil Level	★ 压缩机油位
Oil Temperature	★ 压机油温/°C	Caudal Impulse	★ 气流脉冲
COMP	★ 压机进气		

本文首先对数据集做了特性冗余分析,各特征的相关性热图如图 5 所示。可以看出数据集的特征量存在冗余变量,根据数据集说明书的变量描述以及工程经验进行特征筛选,最终选出 11 个特征,对应表 1 中带★的特征。

图 6 所示为 2 月 5 日 0:00~24:00 的部分数据曲线,由于风源系统受负载变化等因素影响,数据波动的频率和周期间隔在时间上分布不均,而 1.2 节所提的分段积分可以提高融合特征对上述因素引起数据波动的鲁棒性。此外,晚上设备停运后会人为关闭系统,导致数据中出现残缺周期(比如有时压机刚启动就没有了后续数据),影响后续统计分析。因此,本文排除了这些残缺周期数据。

从图 6 可以看出,核心数据是气动面板压强 TP3,会随着压机的间歇性做功以及系统负载消耗(如气动悬挂、

制动、冷却等等)而呈现周期性的起伏波动,同时 TP3 的上升下降又会反过来影响压机的启停指令。本文首先按照 TP3 的周期波动性将数据切分为逐个周期段,并依据压机的启停状态将每个周期数据细分为压缩段和空闲段。然后对每个压缩段和空闲段的各种特征变量分别采用 1.2 节的特征提取方法进行特征提取。

该数据集的故障信息如表 2 所示。鉴于数据集时间跨度较大(包含了两个季度),应考虑数据分布存在季节性波动,并且该数据集并未给出维修记录,而不同程度的维修会影响后续数据的变化趋势及分布。本文目的在于故障预警,重点关注系统功能失效前的故障征兆信息,故按照表 2 中各故障的起止时间将数据集分为 17 个非故障数据段。为了让模型学习到数据的长时期分布规律,将每个

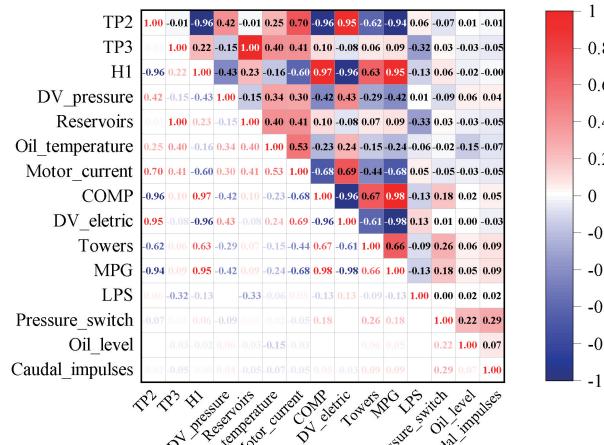


图 5 特征相关性热图

Fig. 5 Feature correlation heat map

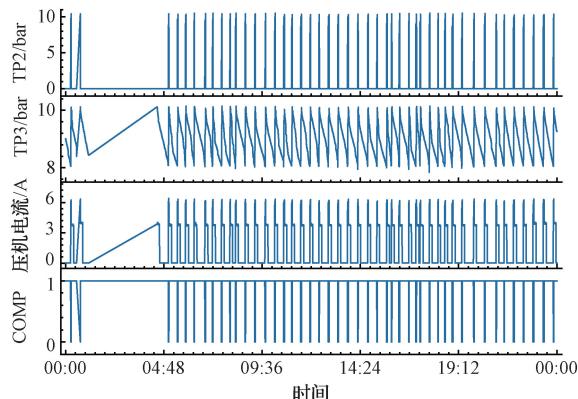


图 6 24 h 运行数据(部分变量)

Fig. 6 24 h running data (some variables)

非故障数据段按照 2/1 切分为建模数据与预警数据,其中建模数据采用 6/2/2 划分模型的训练集,验证集,测试集。

由于 TP3 数据在每个周期的压缩段都同时包含了压机做功信息和系统负载信息,在系统功能故障失效前存在较为明显的征兆波动,如图 7 所示。故本文将 TP3 的压缩段积分曲线作为数据集的特征标签进行无监督学习。

### 3.2 模型预测与残差分析

将 3.1 节建模数据送入到 Informer 模型中进行离线训练,并针对本文的数据特点采用 TPE 方法对模型的超参数进行迭代寻优,迭代次数设置为 200 次。表 3 为超参数寻优结果。

最优超参数组合对应模型的最低验证均方误差损失(MSEloss)为 0.3234,训练运行时间为 178.51 s,该模型的预测结果如图 8 所示。红色线为模型的预测值,黑色线为真实数据。

表 2 故障信息

Table 2 Fault information

故障序号	起始时间	结束时间	故障类型
1	2020/03/06 21:42	2020/03/06 23:00	漏气
2	2020/03/12 00:10	2020/03/12 17:59	漏气
3	2020/03/27 07:12	2020/04/01 14:00	漏气
4	2020/04/12 11:50	2020/04/12 23:35	漏气
5	2020/04/17 09:25	2020/04/21 02:00	压机故障
6	2020/04/29 03:20	2020/04/29 22:20	漏气
7	2020/05/13 13:40	2020/05/14 01:15	漏气
8	2020/05/19 22:20	2020/05/20 19:50	漏气
9	2020/05/26 09:20	2020/05/28 03:16	压机故障
10	2020/05/29 23:15	2020/05/30 06:10	漏气
11	2020/06/05 09:48	2020/06/08 14:00	漏气
12	2020/06/12 02:05	2020/06/12 17:50	压机故障
13	2020/06/22 13:05	2020/06/25 05:08	漏气
14	2020/07/08 17:30	2020/07/08 23:40	漏气
15	2020/07/15 14:25	2020/07/15 18:50	漏气
16	2020/07/21 13:48	2020/07/22 13:05	压机故障

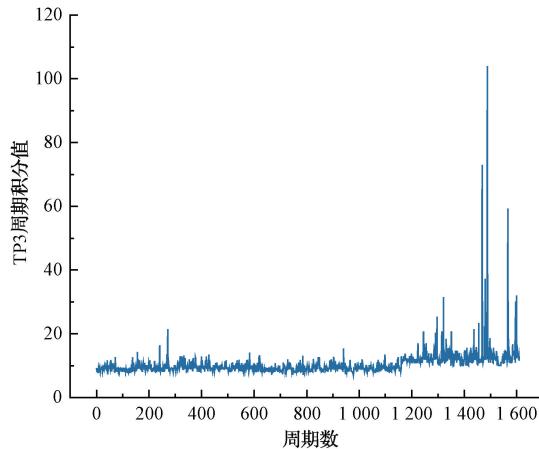


图 7 故障前 TP3 压缩段积分曲线

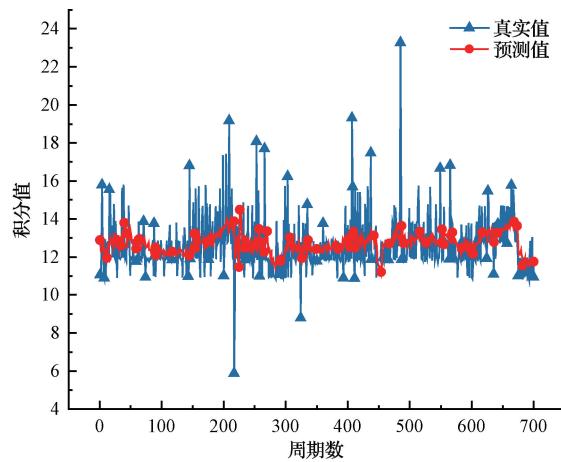
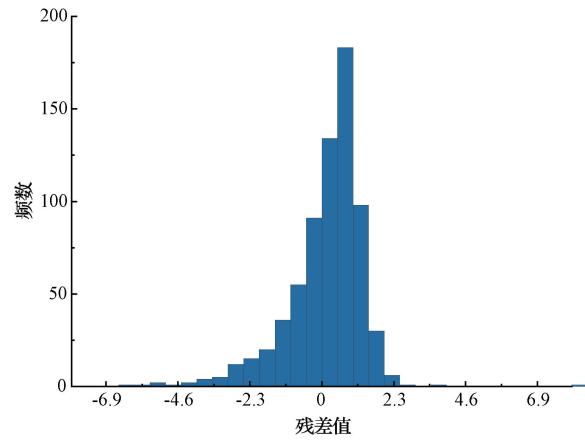
Fig. 7 Integral curve of TP3 compression segment before failure

从图 8 可以看出,模型较好地学习并预测到了目标变量的波动中心与趋势变化。对图 8 的预测结果与真实数据做残差分析,得到残差分布如图 9 所示,可以看出预测值与真实值的残差近似呈高斯分布,符合正常运行数据的随机波动情况,同时也印证了对残差的分布分析。

此外,本文还选用均方误差(MSE)、均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)4 个评价指标来对比 TPE-Transformer、TPE-LSTM、TPE-GRU 模型的预测结果,以验证 TPE-Informer

表3 超参数寻优结果  
Table 3 Fault information

参数	寻优范围	最优结果	参数	寻优范围	最优结果
seq_len	(40, 120)	104	d_layers	(1, 3)	1
label_len	(6, 12)	8	d_ff	(512, 1 024, 2 048)	2 048
pred_len	(1, 6)	3	factor	(1, 9)	6
d_model	(128, 256, 512)	512	dropout	(0.0, 1.0)	0.05
n_heads	(5, 10)	5	learning_rate	( $1 \times 10^{-5}$ , $1 \times 10^{-1}$ )	0.000 5
e_layers	(1, 3)	1	batch_size	(16, 32, 64, 128)	32

图8 模型预测结果  
Fig. 8 Model prediction result图9 残差分布  
Fig. 9 Residual distribution表4 不同模型预测结果  
Table 4 Different model predictions

预测模型	MSE	RMSE	MAE	MAPE	耗时/s
TPE-Informer	0.323 4	0.568 6	0.391 7	1.251 0	178.01
TPE-Transformer	0.340 5	0.583 5	0.422 5	1.577 6	284.54
TPE-LSTM	0.739 9	0.860 2	0.629 0	0.958 5	63.83
TPE-GRU	0.692 4	0.832 1	0.596 1	0.951 6	57.19

模型的预测性能。各指标的计算公式如下：

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (14)$$

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (15)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (16)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (17)$$

对比结果如表4所示,可以看出TPE-Transformer模型的预测精度与TPE-Informer相差不大,但训练耗时多出约60%。LSTM和GRU模型虽然耗时更短,但损失较大,对长序列的记忆能力有限。

### 3.3 故障预警结果

在离线训练好模型后,将3.1节的预警数据送入模型中进行在线预警测试,并在每个故障结束后重置预警指标。图10所示为1号故障的预警数据图。预警指标中,竖虚线为模型发出的预警信号。可以看到在设备故障失效前161个周期时,模型有效地发出预警信息。

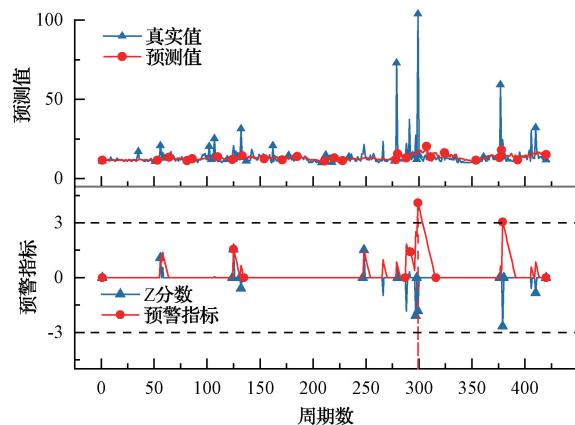


图10 1号故障预警图

Fig. 10 Fault warning diagram No. 1

其他预警结果如表5所示,包含4种不同模型在故障前发出预警的周期。结果表明,本文提出的TPE-Informer模型能有效地在故障前发出预警,预警时间最早可达故障前220个周期,最晚为22个周期。TPE-Transformer

与 TPE-Informer 的预警结果大致相同。然而,对于一些故障前异常波动较小且分散的故障(如 4、7、12、14、16 号),由于 TPE-LSTM 和 TPE-GRU 模型的记忆能力较短,对这些小幅度异常波动的敏感度较低,导致部分预警存在滞后。

表 5 故障预警结果  
Table 5 Fault warning result

故障序号	TPE-Informer	TPE-Transformer	TPE-LSTM	TPE-GRU
1	161	160	160	160
2	22	22	22	22
3	55	54	54	53
4	77	78	45	45
5	37	37	37	37
6	48	47	45	47
7	145	145	114	114
8	30	31	30	31
9	23	23	23	23
10	134	134	134	135
11	68	68	68	68
12	110	112	41	41
13	47	47	47	47
14	150	150	69	71
15	15	15	15	15
16	220	220	191	193

为验证本文所提模型是否存在误报情况,本文采用最后一个非故障数据段输入到训练好的故障预警模型进行误报验证。验证结果如图 11 所示,与图 10 相同,可以看出,该段数据可能存在一些不确定性干扰,残差存在一些小幅度的波动,但系统并未发出误报预警,验证了本文所提预警框架的误报鲁棒性。

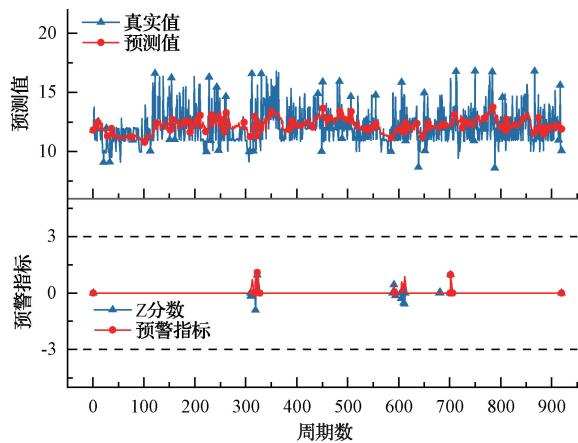


图 11 误报验证

Fig. 11 False positive verification

#### 4 结 论

为实现对列车风源系统的故障预警,本文分析了风源系统及其空压机的间歇性运行数据特点,提出了一种故障预警框架,并采用 MetroPT3 数据集进行了仿真实验,得出如下结论。

1) 本文采用了基于 TPE-Informer 的预测模型,针对不同类型数据特点并结合数据周期性规律,使用积分、比率和统计等方法提取多维时序特征。通过 Informer 模型学习正常运行数据的规律和模式,并用 TPE 算法自适应优化模型超参数。该模型在数据集上具有较高的预测精度(MSE 为 0.323 4)和运行效率(178.51 s)。

2) 本文提出了一种新的故障预警指标计算方法,它通过比较模型预测的正常数据与实际测量数据的残差,使用 IQR 和 Z 分数来量化和标准化残差的异常程度,根据 SPC 的异常判断规则来计算指标的变化。仿真结果显示,该方法在检测到连续大幅异常波动时能迅速响应并发出预警,具有高灵敏度,并且对 16 个故障案例成功预警。此外,该模型在正常数据段显示了良好的误报鲁棒性。

3) 本文深入分析了列车风源系统的数据特点和共性,在所提的故障预警框架中多采用针对数据共性的自适应建模方法,如多种数据特征提取,模型参数优化,预测残差及故障指标的归一化分析等,降低了对专业知识的依赖,提高了模型对不同风源系统的泛化能力。

#### 参 考 文 献

- [1] 李景州,赵广乐. GCY520 内燃车制动风源系统故障分析及处理[J]. 科技创新与应用, 2021(7): 130-132.  
LI J ZH, ZHAO G L. Fault analysis and treatment of GCY520 internal combustion vehicle brake air source system[J]. Technology Innovation and Application, 2021(7): 130-132.
- [2] 韦忠潮,卜美玲. 地铁车辆风源系统压强开关故障分析及对策[J]. 轨道交通装备与技术, 2023(4): 51-56.  
WEI ZH CH, BU M L. Fault analysis and countermeasures of pressure switch in metro vehicle air source system [J]. Rail Transportation Equipment and Technology, 2023(4): 51-56.
- [3] 丁景贤,左建勇,任利惠. 基于等效故障注入试验的列车风源系统故障影响规律与分析[J]. 仪器仪表学报, 2023, 44(5): 44-52.  
DING J X, ZUO J Y, REN L H. Fault influence law and analysis of train air supply systems based on equivalent fault injection test [J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 44-52.
- [4] ZUO J, LUO Z, CHEN Z. Position control

optimization of aerodynamic brake device for high-speed trains [J]. Chinese Journal of Mechanical Engineering, 2014, 27(2): 287-295.

[5] 刘治国, 杨青雨, 王树海, 等. 列车用智能化风源系统技术研究[J]. 大连交通大学学报, 2021, 42(5): 41-45.

LIU ZH G, YANG Q Y, WANG SH H, et al. Study of intelligent air supply unit [J]. Journal of Dalian Jiaotong University, 2021, 42(5): 41-45.

[6] PINTO P M DA S O. Design of a data acquisition system data for predictive maintenance of an onboard production unit of compressed air [D]. PQDT — Global. Portugal: Universidade do Porto (Portugal), 2019.

[7] 项宇航, 丛培鹏, 尹智勇. 城轨列车风源系统故障的自动检测方案[J]. 铁道列车车辆, 2019, 39(S1): 71-73,79.

JIANG Y H, CONG P P, YIN ZH Y. Air supply system failure auto-detection proposal of urban rail vehicle [J]. Railway Locomotive & Car, 2019, 39(S1): 71-73,79.

[8] MEIRA J, VELOSO B, BOLON-CANEDO V, et al. Data-driven predictive maintenance framework for railway systems [J]. Intelligent Data Analysis, 2023, 27(4): 1087-1102.

[9] 周伟, 魏鑫, 李西兴. 改进MFO-LSTM网络的风电机组齿轮箱故障预警研究[J]. 机床与液压, 2024, 52(4): 185-194.

ZHOU W, WEI X, LI X X. Research on wind turbine gearbox fault early warning based on improved MFO-LSTM network [J]. Machine Tool & Hydraulics, 2024, 52(4): 185-194.

[10] 刘河生, 徐浩, 李宁, 等. 风电机组齿轮箱故障预警算法研究及应用[J]. 热力发电, 2024, 53(4): 36-42.

LIU H SH, XU H, LI N, et al. Research and application of wind turbine gearbox fault warning algorithm [J]. Thermal Power Generation, 2024, 53(4): 36-42.

[11] 王朋飞, 刘长良, 徐健, 等. 基于图注意力和时间卷积网络的风电齿轮箱故障预警方法[J]. 电子测量与仪器学报, 2023, 37(8): 204-213.

WANG P F, LIU CH L, XU J, et al. Wind turbine gearbox fault warning method based on graph attention and temporal convolutional network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 204-213.

[12] 马良玉, 耿妍竹, 梁书源, 等. 基于Stacking多模型融合的风电机组齿轮箱油池温度异常预警[J]. 中国电机工程学报, 2023, 43(S1): 242-251.

MA L Y, GENG Y ZH, LIANG SH Y, et al. Anomaly warning of wind turbine gearbox oil pool temperature based on stacking fusion of multiple models [J]. Proceedings of the CSEE, 2023, 43(S1): 242-251.

[13] CHOUDHARY A, MIAN T, FATIMA S, et al. Passive thermography based bearing fault diagnosis using transfer learning with varying working conditions[J]. IEEE Sensors Journal, 2023, 23(5): 4628-4637.

[14] SUN G, WANG Y, WANG Z, et al. Research on early fault warning methods for key transmission components of wind turbines [J]. Measurement Science and Technology, 2021, 32(11): 115002.

[15] FU Y, WANG S, JIA F, et al. Two-stage cascaded high-precision early warning of wind turbine faults based on machine learning and data graphization[J]. Journal of Electrical Engineering & Technology, 2024, 19(3): 1919-1931.

[16] 张家安, 邓强, 马增强, 等. 基于IMHSA-MSCNN-BiLSTM的风机轴承故障诊断[J]. 电子测量技术, 2024, 47(7): 170-176.

ZHANG J AN, DENG Q, MA Z Q, et al. Fault diagnosis of fan bearings based on IMHSA-MSCNN-BiLSTM [J]. Electronic Measurement Technology, 2024, 47(7): 170-176.

[17] ZHOU F, WANG Y, JIANG S, et al. Research on an early warning method for bearing health diagnosis based on EEMD-PCA-ANFIS [J]. Electrical Engineering, 2023, 105(4): 2493-2507.

[18] 卢浩龙, 朱彦敏. 基于多尺度图Transformer的滚动轴承故障诊断[J]. 国外电子测量技术, 2023, 42(12): 186-194.

LU H L, ZHU Y M. Fault diagnosis of rolling bearing based on multi-scale graph Transformer [J]. Foreign Electronic Measurement Technology, 2023, 42(12): 186-194.

[19] 袁镇华, 茅大钧, 李玉珍. 基于注意力机制与XBOA-Bi-LSTM的离心式压缩机故障预警方法[J]. 机电工程, 2024, 41(3): 400-408.

YUAN ZH H, MAO D J, LI Y ZH. Centrifugal compressor fault warning method based on attention mechanism and XBOA-Bi-LSTM [J]. Journal of Mechanical&Electrical Engineering, 2024, 41 (3): 400-408.

[20] ZHU G, HUANG Q, ZHANG Z. A condition-monitoring method for rolling bearings based on dynamic asynchronous peak-factor ratios [J].

Sensors, 2023, 23(21): 8939.

[21] 赵春晖, 余万科, 高福荣. 非平稳间歇过程数据解析与状态监控——回顾与展望[J]. 自动化学报, 2020, 46(10): 2072-2091.  
ZHAO CH H, YU W K, GAO F R. Data analytics and condition monitoring methods for nonstationary batch processes—Current status and future [J]. Acta Automatica Sinica, 2020, 46(10): 2072-2091.

[22] ZHOU H, ZHANG S, PENG J, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting [J]. ArXiv preprint arXiv: 2012.07436, 2020.

[23] DAVARI N, VELOSO B, RIBEIRO R P, et al. Predictive maintenance based on anomaly detection using deep learning for air production unit in the railway industry [C]. 2021 IEEE 8th International Conference on Data Science and Advanced Analytics (DSAA). IEEE, 2021.

## 作者简介

翟鸿儒, 硕士研究生, 主要研究方向为信号与信息处理。

E-mail: z5121198@163.com

姚爱琴(通信作者), 副教授, 硕士生导师, 主要研究方向为现代通信技术、信息探测与信号处理。

E-mail: yaoaiqin@nuc.edu.cn

孙运强, 教授, 博士生导师, 主要研究方向为信息探测与信号处理、无线通信技术。

E-mail: syq@nuc.edu.cn

赵文强, 硕士研究生, 主要研究方向为智能控制与自动化。

E-mail: 351407024@qq.com

石喜玲, 副教授, 硕士生导师, 主要研究方向为数据融合与智能控制。

E-mail: shixl@nuc.edu.cn