

引用格式: 曹乐乐, 张鹏, 高泽宇, 等. 基于动态特征融合的船舶柴油机进排气系统故障诊断[J]. 中国舰船研究, 2022, 17(6): 103-110.

CAO L L, ZHANG P, GAO Z Y, et al. Fault diagnosis of marine diesel engine intake and exhaust system based on dynamic feature fusion[J]. Chinese Journal of Ship Research, 2022, 17(6): 103-110.

基于动态特征融合的船舶柴油机 进排气系统故障诊断



扫码阅读全文

曹乐乐, 张鹏, 高泽宇, 张跃文*, 孙培廷
大连海事大学轮机工程学院, 辽宁大连 116026

摘要: [目的] 船舶系统由多设备的复杂机构组成, 各组件参数具有动态性和非线性特点, 所以故障诊断过程复杂。为提高诊断效率, 提出一种动态特征融合方法。[方法] 利用分形理论、动态理论及核主元分析(KPCA)法对系统状态数据进行重构、映射及筛选, 得到主元特征数据矩阵, 求得平方预测误差(SPE)及相应的控制限, 构建出基于船舶柴油机进排气系统健康数据的离线监测模型, 利用该模型对系统进行故障诊断分析。为验证模型的有效性, 选取某船舶柴油机进排气系统的故障数据进行验证分析。[结果] 结果表明, 动态特征融合分析方法可有效实现对系统动态非线性状态数据的精确分析, 实现对系统故障的高效分析和诊断。与KPCA及支持向量机(SVM)方法相比, 所提方法具有更好的故障诊断性能。[结论] 该方法可实现船舶柴油机进排气系统故障的检测和诊断, 提升系统运行的可靠性和安全性。

关键词: 船舶柴油机; 进排气系统; 故障诊断; 核主元分析; 关联维数; 动态理论

中图分类号: U664.121; U674.42

文献标志码: A

DOI: 10.19693/j.issn.1673-3185.02443

Fault diagnosis of marine diesel engine intake and exhaust system based on dynamic feature fusion

CAO Lele, ZHANG Peng, GAO Zeyu, ZHANG Yuewen*, SUN Peiting

Marine Engineering College, Dalian Maritime University, Dalian 116026, China

Abstract: [Objective] A ship's system is a complex mechanism composed of multiple pieces of equipment. Due to the dynamic and non-linear characteristics of the parameters of each component, fault diagnosis is complicated. This paper proposes a dynamic feature fusion method for performing efficient fault diagnosis on the system. [Methods] Fractal theory, dynamic theory and the kernel principal component analysis (KPCA) method are used to reconstruct, map and filter the system state data, and obtain the principal component characteristic data matrix, square prediction error (SPE) and corresponding control limits. An offline monitoring model based on the health data of a marine diesel engine intake and exhaust system is then constructed and used to diagnose and analyze ship system faults. In order to verify the validity of the model, the fault data of the intake and exhaust system of a marine diesel engine is selected for verification and analysis. [Results] The results show that this method can effectively realize the accurate analysis of a system's dynamic nonlinear state data and efficient analysis and diagnosis of faults, with better fault diagnosis performance than the KPCA and support vector machine (SVM) method. [Conclusions] The method proposed in this paper can realize the detection and diagnosis of marine diesel engine intake and exhaust system failures, and improve the reliability and safety of system operation.

Key words: marine diesel engine; intake and exhaust system; fault diagnosis; kernel principal component analysis; correlation dimension; dynamic theory

收稿日期: 2021-07-07 修回日期: 2021-09-06 网络首发时间: 2022-11-29 16:15

基金项目: 工信部高技术船舶科研资助项目(MC-201712-C07); 国家重点研发计划资助项目(2018YFB1601502); 中央高校基本科研业务费专项资金资助项目(3132019006)

作者简介: 曹乐乐, 男, 1996年生, 硕士生。研究方向: 船舶智能运维。E-mail: cll1996@dlmu.edu.cn

张鹏, 男, 1983年生, 博士生, 讲师。研究方向: 船舶智能运维。E-mail: zhangpengjunji@dlmu.edu.cn

张跃文, 男, 1967年生, 硕士, 教授。研究方向: 船舶机械故障预测与健康管。E-mail: zhangyuewen@dlmu.edu.cn

*通信作者: 张跃文

0 引言

随着现代智能传感技术、物联网及大数据技术的不断发展,船舶智能化和自主化程度逐渐提高,船舶传感器可提供更加丰富的状态信息^[1],例如船舶柴油机排气温度,中央冷却淡水温度及增压器转速等,此类信息具有非线性、大惯性及动态性等特点。因此,如何利用监测数据及相关知识信息实现对船舶系统的故障诊断及管理,是当前智能运维亟需解决的重点问题。船舶系统感知变量多、工作模式多且故障影响因素复杂,通常缺少主导的失效特征,故为了对其进行故障诊断,往往需要考虑融合多个传感器的状态信息^[2-3]。为此,国内外学者选用了不同的特征参数融合方法对系统及设备进行故障诊断及健康管理。

例如,李玉红^[4]将主元分析(principal component analysis, PCA)方法应用到压缩机数据分析过程中,实现了对设备主要故障的准确诊断,保证了设备的安全运行。吴天昊等^[5]将核主元分析法(kernel PCA, KPCA)应用到核电厂具有多元非线性参数设备的监测中,实现了对设备状态的故障预警和诊断,但这两种方法对于动态数据的处理都有不足之处。此外,Zhang 等^[6]利用时滞偏移和 KPCA 相结合的方法,提高了对工业系统的故障检测精度,但对于迟滞时间的选择仍显不足。

本文将采用一种基于分形理论、动态理论及 KPCA 的动态特征融合分析方法^[7],对某远洋运输船舶在定速航行状态下的柴油机进排气系统进行分析,方法融合多维数据构建出监测控制限,实现对进排气系统工作状态的精确判断,解决系统动态非线性数据易造成故障诊断复杂化及精度低的问题。首先,为获取系统变量之间的动态相关性,利用分形理论和动态理论构建出最优时滞矩阵;其次,应用 KPCA 及关联维数对矩阵进行映射筛选处理,解决系统数据线性不可分的问题,同时降低分析数据的维度;然后,利用求得的主元特征矩阵及平方预测误差(squared prediction error, SPE)控制限,构建出离线检测模型;最后,利用模型对监测数据进行处理分析以实现进排气系统故障的检测与诊断。本文所用方法在提取系统变量之间的动态自相关特性的同时,还可解决非线性变量的分离问题,适用于多维参数系统或多参数设备的状态分析与诊断。

1 船舶柴油机进排气系统

进排气系统属于船舶柴油机 5 大系统之一,

是船舶柴油机进行换气、燃烧及正常运行的基础,其运行状态会直接影响柴油机的动力性、可靠性及排放性能等,在船舶运行过程中发挥着重要作用,也是机舱管理工作中需要格外注意的地方。为了保障船舶主机的安全性和可靠性,需要及时对进排气系统进行故障分析和诊断,确定系统整体工作状况^[8]。

当前,大部分船舶柴油机进排气系统主要是由废气涡轮增压器、空冷器、主机及排气总管等装置组成,基本构成如图 1 所示。

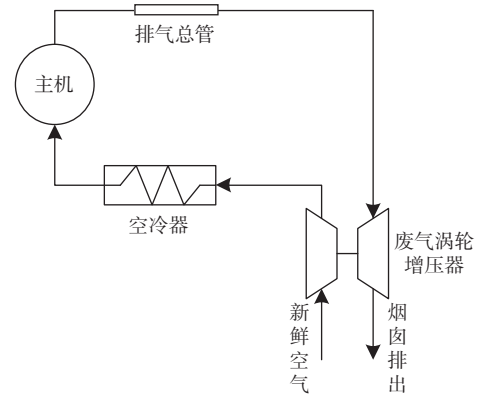


图 1 柴油机进排气系统图

Fig. 1 Diagram of diesel engine intake and exhaust system

由于柴油机进排气系统设备工作环境的复杂性和恶劣性,容易出现如排烟温度异常、柴油机气阀机构异常、空冷器失效及增压器组件异常等故障,导致柴油机运行异常,影响船舶的安稳运行。进排气系统为多设备构建成的复杂系统,存在如单缸排烟温度、气缸指示压力、排气总管温度、增压器转速、增压器进出口温度、空冷器温差、扫气温度及压力等多种监控参数,若仅对单一监测信息进行处理分析难以实现对整体系统运行状况的判断。为了实现对进排气系统状态的准确识别,应采用动态特征融合分析方法对多元设备的动态非线性数据进行分析。

2 故障检测框架构建

智能船舶柴油机进排气系统所监控的信息多为动态非线性状态参数,例如增压器转速和空冷器温差等信号。无论是 PCA 还是 KPCA 分析方法,都是基于系统不同时刻的数据相互独立的这一假设,对动态非线性数据的分析能力都存在一定的不足^[9]。在船舶系统实际运行过程中,不同组元数据之间存在着一定的相互关联性,且同一组元数据在不同时刻存在一定的序列相关性^[10]。为了降低数据间的相互影响,实现对船舶系统工作状态的精确分析和诊断,本文提出了一种基于

动态特征融合分析方法的综合优化监控框架。

2.1 动态矩阵构建

船舶柴油机进排气系统整体运行状态受到工况、环境、设备的使用及维修状况等多种因素影响, 系统监控信号如排烟温度等通常是动态变化数据, 直接对其进行处理建模, 无法反映样本数据的动态运行特点。为了获取系统数据的动态性, 以及提高系统故障诊断的准确性, 需对原始数据分析处理, 构建如下最优的时滞动态矩阵。

$$\tilde{X} \triangleq [X(t)X(t-\tau)\cdots X(t-l\tau)] \in \mathbf{R}^{(N-l)\times m(l+1)}$$

式中: $X(t)$ 为 t 时刻的 m 维观测数据; τ 为间隔时间; N 为监测器测量次数; l 为滞后时间因子。当 l 逐渐增大时, 会构建出时滞动态矩阵, 进而形成新的线性和非线性动力学关系。当 l 变化时, 满足如下关系:

$$r = m(l+1) - C_D \quad (1)$$

$$r_n = r - \sum_{i=0}^{l-1} (l-i+1)r_n(i) \quad (2)$$

式中: C_D 表示关联维数, 为分形理论的一种表现形式; r_n 表示循环函数, 初始的 $r_n(i)$ 为 $l=0$ 时计算所得的 r , l 的初始值为 1, 通过循环计算直至 $r_n \leq 0$ 时停止。将分析得到的合适 l 值作为 l_{opt} , 构造出 $\tilde{X}_{opt} \in \mathbf{R}^{N_D \times m(l_{opt}+1)}$, 其中 $N_D = N - l^{[7]}$ 。

关联维数 C_D 很好地刻画了系统数据的聚散程度, 与 r_n 结合可进一步实现对复杂非平稳数据进行特征的刻画^[11]。计算公式为

$$C_D(\varepsilon) = \frac{2}{N(N-1)} \sum_{i=1}^N \sum_{j=i+1}^N H(\varepsilon - \delta_{ij}) \quad (3)$$

式中: δ_{ij} 为数据矩阵内部行与行之间状态矢量的欧氏距离; i, j 为矩阵内部行数; ε 为距离参数, 其取值与 δ_{ij} 有关; H 为阶跃函数, 满足:

$$H(\varepsilon - \delta_{ij}) = \begin{cases} 1 & \text{if } \varepsilon - \delta_{ij} \geq 0 \\ 0 & \text{else } \varepsilon - \delta_{ij} < 0 \end{cases}$$

随着 ε 值逐渐变小, $C_D(\varepsilon)$ 与 ε 遵循 $\lim_{\varepsilon \rightarrow 0} C_D(\varepsilon) = \varepsilon^{C_D}$ 的关系, 对两边同时取 \lg 对数, 可得到如下关联维数。

$$C_D = \lim_{\varepsilon \rightarrow 0} \frac{\lg C(\varepsilon)}{\lg \varepsilon} \quad (4)$$

在实际分析过程中, ε 的取值达不到公式所定义的 $\varepsilon \rightarrow 0$ 界限。因此, 为了得到合适的关联维数, 使用计算所得的 δ_{ij} 和 ε 值得到 $\lg \varepsilon - \lg C(\varepsilon)$ 函数曲线, 并取函数曲线中线性较好区域内的直线斜率作为 C_D 的值, 以用于分析计算^[12]。

应用关联维数可筛选出合适的迟滞时间, 构

建出进排气系统的最优时滞动态矩阵, 对矩阵重构可有效提取系统变量之间的动态关系, 降低过程变量之间的序列相关性和互相关性对分析结果带来的影响, 以进一步提高故障诊断的精确性。

2.2 核主元分析

KPCA 方法是对 PCA 的一种推广, 利用该方法的核函数将进排气系统数据映射到高维特征空间内, 通过选择合适的核宽度, 使得原本是线性无关的数据在特征空间内转变成线性相关的数据, 从而有利于数据的处理和分析。对于映射后的数据, 可使用协方差矩阵 H 表示多维随机变量在特征空间内的概率密度^[13]。对 H 的特征值和特征向量进行求解的公式为

$$H p^k = \lambda^k p^k, \quad k = 1, \dots, N \quad (5)$$

式中: λ^k 为 H 的特征值; $p^k = \sum_{i=1}^N \alpha_i^k \Phi(x_i)$, 为特征向量, 其中 α_i^k 是 p^k 在映射空间中的相关加权系数, $\Phi(x_i)$ 为映射函数, 代入式 (5) 中, 可得

$$\frac{1}{N} \sum_{i=1}^N \Phi(x_i) \Phi(x_i)^T \sum_{i=1}^N \alpha_i^k \Phi(x_i) = \lambda^k \sum_{i=1}^N \alpha_i^k \Phi(x_i) \quad (6)$$

为便于计算, 此处引入一个径向基核函数, 即高斯核函数, 对上式进行化简, 得到

$$K \alpha^k = N \lambda^k \alpha^k, \quad \alpha^k = [\alpha_1^k, \dots, \alpha_N^k]^T \quad (7)$$

为了满足数据在重构空间内部的某一点居中这一假设, 需要对高斯核函数中心化, 利用中心核矩阵 \hat{K} 替代 K 进行相关计算, 则第 k 个数据在特征向量 p^k 上的投影为

$$t^k = \langle p^k, \Phi(x) \rangle = \frac{1}{\sqrt{\lambda^k}} \sum_{i=1}^N \alpha_i^k K(x_i, x) \quad (8)$$

式中: t^k 为映射数据; x 为原始数据。利用累计方差贡献率 (cumulative percent variance, CPV) 方法计算得到相应的主元数量 p_0 , 通过 p_0 构建出数据矩阵 $T = \{t^k\}_{k=1}^{p_0} \in \mathbf{R}^{N \times p_0}$ 。

非线性的进排气系统原始数据通过 KPCA 方法将其转变为特征空间内线性相关的映射数据, 这有利于对整体数据的线性分析和运算, 同时降低数据的处理难度, 节省计算时间。

2.3 动态特征融合

动态特征融合方法应用分形理论、动态理论及 KPCA 法对船舶柴油机进排气系统进行处理分析, 此方法主要分为 2 个部分: 离线建模和故障诊断。算法流程如图 2 所示。

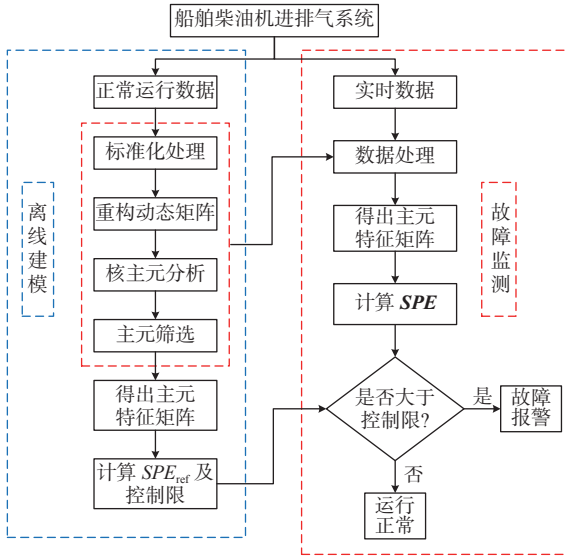


图 2 动态特征融合故障诊断流程图

Fig. 2 Fault diagnosis flowchart of dynamic feature fusion

1) 为消除进排气系统不同维度数据幅值差异,需对数据进行标准化处理,利用式(1)~式(4)对标准化数据进行分析,构造出最优动态矩阵 $\tilde{\mathbf{X}}_{\text{opt}}$ 。

2) 将得到的 $\tilde{\mathbf{X}}_{\text{opt}}$ 作为KPCA的输入数据,利用式(5)~式(8)对 $\tilde{\mathbf{X}}_{\text{opt}}$ 进行计算分析,得到映射数据 t^k 。利用数值范围对 t^k 特征值进行筛选,在不影响整体运算结果的同时去除一些极小值,以减少整体计算量,得到相应的特征值数量为 p ,从而构造出数据矩阵 $T_p = \{t_j^k\}_{k=1}^p \in \mathbf{R}^{N_0 \times p}$, $j = 1, 2, \dots, N_D$ 。

3) KPCA 确定主元个数 p_0 的方法多为累计方差、交叉验证及重构误差方差等方法,但这些方法在处理数据时,都依赖于数据的方差评估。当处理的数据维数较高时,利用方差选取主元很可能产生误导,因此,可利用分形理论选取映射数据主元^[4]。计算方式如下:

$$d_x = C_D(T_p) \quad (9)$$

$$d_\tau = C_D(\tau) \quad (10)$$

式中: d_x 为利用 T_p 数据求出的关联维数; d_τ 为利用 τ 数据求出的关联维数; τ 为主元判断数据, $\tau = T_p \mathbf{A}$,其中矩阵 \mathbf{A} 是协方差矩阵的特征向量组成的正交矩阵。主元个数 $\gamma = \max([d_x], [d_\tau])$, $[]$ 表示向上取整。此类选取方法在一定程度上可减少方差评估对主元特征参数选择的影响,提高特征数据提取的准确性。最终,得到主元特征矩阵 $T_\gamma = \{t_j^k\}_{k=1}^\gamma \in \mathbf{R}^{N_0 \times \gamma}$ 。

4) 利用 T_γ 计算出数据的 SPE_{ref} ,计算公式如下:

$$SPE_{\text{ref}} = \sum_{k=1}^p (t_j^k)^2 - \sum_{k=1}^\gamma (t_j^k)^2 \quad (11)$$

采用置信度(confidence level, CL)的方法对训练数据所得的 SPE_{ref} 进行分析,得到 SPE_{ref} 数据的

控制限。

5) SPE 统计量与原始数据点一一对应,一般认为在控制限上方的统计量便为异常数据点。在进行故障诊断时,利用离线建模所求取的相关参数对实时数据进行分析,计算出 SPE 数据,然后将控制限与实时数据的 SPE 数据进行对比分析,实现对进排气系统工作状况的分析诊断^[15]。

利用漏检率(missing detection rate, MDR)和误警率(false alarm rate, FAR)对故障检测效果进行评判,二者计算公式如下:

$$MDR = \frac{\text{漏报为正常的故障数目}}{\text{故障总数目}} \times 100\% \quad (12)$$

$$FAR = \frac{\text{误报成故障的正常样本数目}}{\text{正常总数目}} \times 100\% \quad (13)$$

3 应用分析

3.1 数据选取

对船舶柴油机进排气系统运行状态的感知和确定,需要选取相应的监测数据进行分析判断,利用经验方法对参数进行选取。参数类别如表 1 所示。

表 1 船舶柴油机进排气系统的参数类别

Table 1 Parameter categories of marine diesel engine intake and exhaust systems

序号	监测参数
1	单缸排烟温度/°C
2	气缸指示压力/MPa
3	主机功率/kW
4	增压器废气进口温度/°C
5	增压器废气出口温度/°C
6	空冷器温差/°C
7	扫气压力/MPa
8	扫气温度/°C
9	增压器转速/(r·min ⁻¹)

选取某远洋运输船舶柴油机 6 号气缸的 10 及 12 月份的进排气系统数据,分别作为方法应用分析的训练样本和故障样本。每组样本大小为 400 h(时间测量间隔为 1 h),监测数据类型如表 1 所示。此船舶主机为 6 缸二冲程柴油机,单个废气涡轮增压器运行,在两份数据选取的时间段内,船舶均为定速航行阶段,主机高压油泵油门刻度在 58 格附近,选取数据如图 3 和图 4 所示。

3.2 模型建立

1) 对选取的进排气系统数据进行标准化处

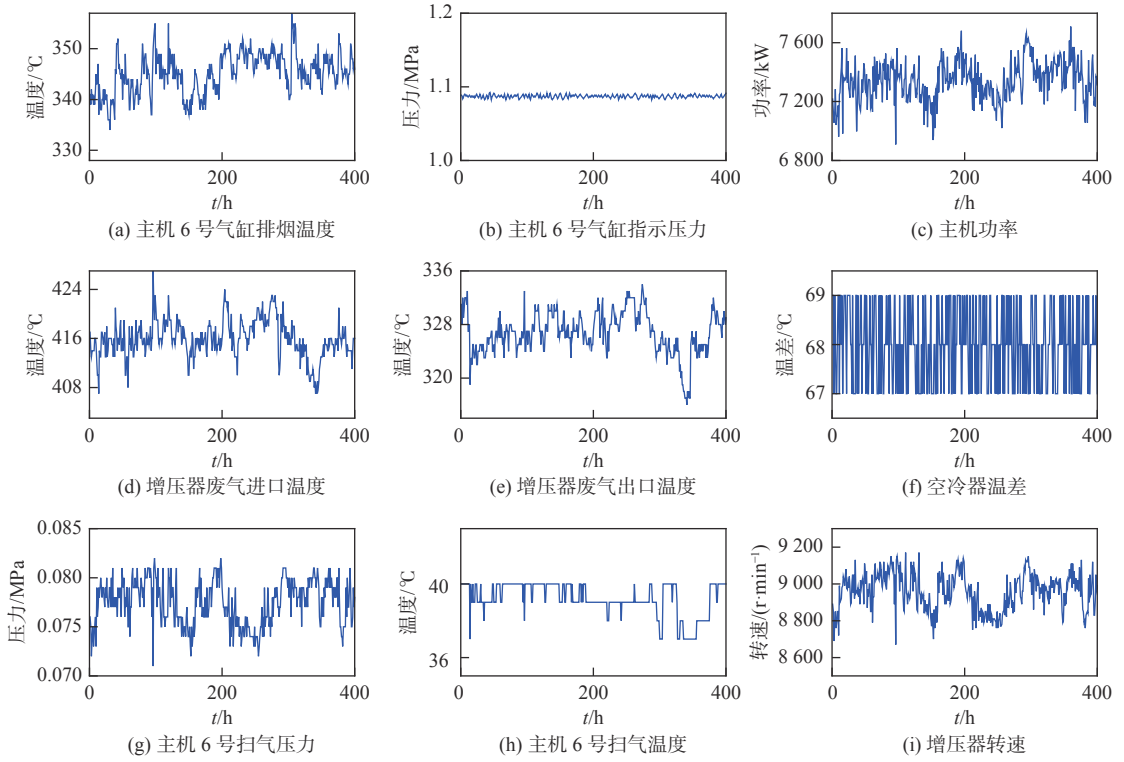


图 3 训练数据集

Fig. 3 Training data set

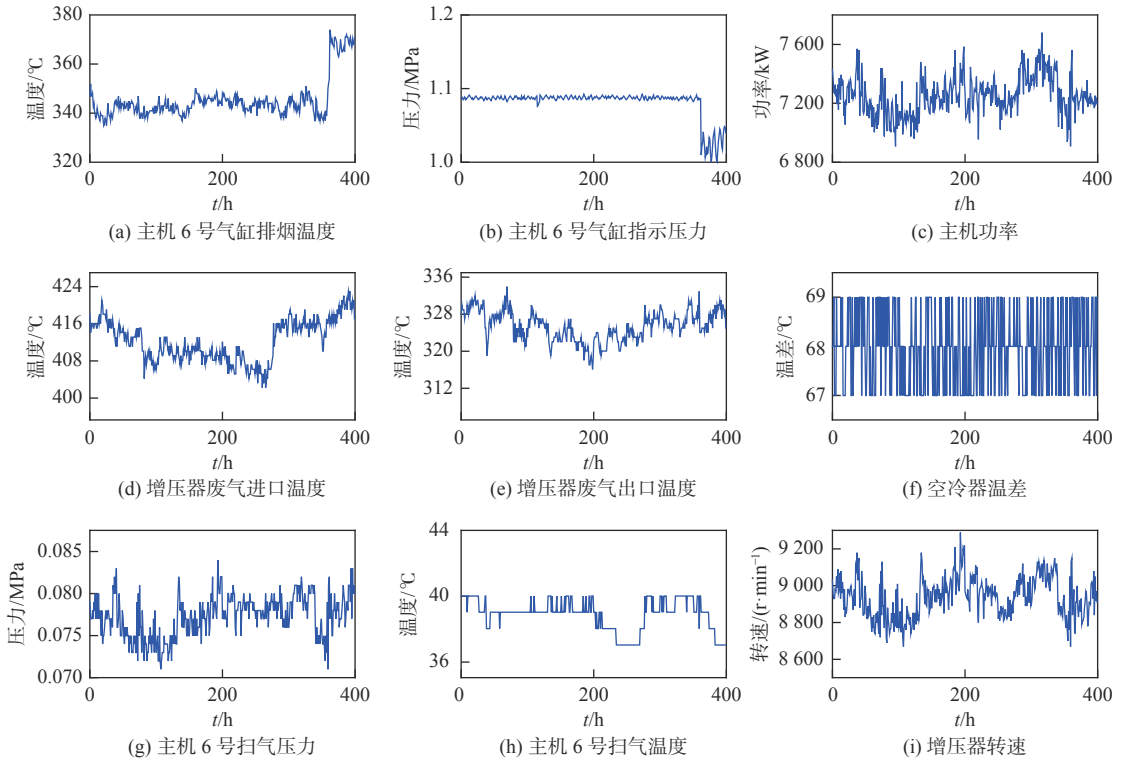


图 4 故障数据集

Fig. 4 Failure data set

理, 以降低对各维度幅值差异的影响, 应用式(3)和式(4)对数据做进一步分析, 得到不同迟滞时间对应的 $\lg \varepsilon - \lg C(\varepsilon)$ 函数曲线, 如图 5 所示。

选取图 5 中红色直线的斜率作为不同迟滞时间下的关联维数 C_D , 利用式(1)和式(2)对求得的

不同 C_D 值进行计算分析, 以获取系统的动态特性, 结果如表 2 所示。

从图 5 中可发现, 当 $l \geq 2$ 时, 关联维数曲线的线性部分趋近于平行, 红色直线倾斜角度变化幅度降低。从表 2 中可知, 当 $l = 2$ 时, 循环函数




图 5 训练数据关联维数图

Fig. 5 Correlation dimension map of training data

表 2 训练数据的分形分析数据

Table 2 Fractal analysis data of training data

l	$m(l+1)$	C_D	r	r_n
0	9	5.2186	4.7814	4.7814
1	18	6.9634	13.0366	3.4738
2	27	8.0087	21.9913	0.6995
3	36	8.7147	31.2853	0.3393
4	45	9.1466	40.8534	0.2741
5	54	9.5526	50.4474	0.0259
6	63	9.9643	60.0357	-0.0057

$r_n = 0.6995$, 此时的数据矩阵与原始数据处于弱动态关系, 且 C_D 线性部分的选择和计算依赖于人员的自主判断, 存在一定的误差, 同时高斯核函数的应用也会对数据的动态时序产生一定的影响, 因此选择 $l_{opt} = 2$ 作为此数据样本最优的迟滞时间^[7,16], 构建出船舶柴油机进排气系统的最优时

滞数据矩阵 $\tilde{\mathbf{X}}_{opt}$ 。

2) 利用试错法选取高斯核函数的核宽度 $\sigma = 30$, 对矩阵 $\tilde{\mathbf{X}}_{opt}$ 进行映射分析, 利用 $\lambda^p \geq 10^{-5}$ $p = 1, 2, \dots, N_D$ 对特征数据进行筛选, 去掉一些较小值, 得到 $p = 274$, 构建数据矩阵 \mathbf{T}_p 。

3) 为得到数据的主元数, 利用式(3)~式(4)及式(9)~式(10)对所求的 \mathbf{T}_p 和 τ 进行计算分析, 得到相应的 $\lg \varepsilon - \lg C(\varepsilon)$ 函数曲线, 如图 6 所示。




图 6 主元分析图

Fig. 6 Principal component analysis diagram

通过对图 6 线性区域中红色直线斜率计算可得出 $d_x = 5.4206$ 和 $d_\tau = 5.8378$, 求得相应映射空间内的主元数 $\gamma = 6$, 进而构造出主元特征矩阵 \mathbf{T}_γ 。

4) 应用式(11)对所得矩阵 \mathbf{T}_γ 进行计算得出 SPE_{ref} 评测数据, 根据经验选取置信度为 95% 的标准对 SPE_{ref} 数据进行分析, 得到相对应的控制限。同时, 利用 KPCA 方法对进排气系统重构数据矩阵及原始数据进行分析处理, 得到对应的 SPE_{ref} 控制限, 结果如图 7 所示。




图 7 训练数据控制限图

Fig. 7 Control limit diagram of training data

图 7 中的统计量为所求的 SPE_{ref} 数据, 统计量与原始数据相关, 红色虚线为 95% 置信度下的 SPE_{ref} 控制限。利用得到的控制限和相关数据建立离线模型, 用于系统的实时数据诊断分析。

3.3 故障诊断

选取的柴油机进排气系统 12 月份数据为故障数据, 经轮机员对故障不断排查和筛选, 发现故障位置为主机 6 号气缸排气阀处。在拆检分析后得知, 故障为排气阀上部压缩气体压力降低所导致的气阀滞后关闭问题。为此, 采用建立的离

线模型对上述月份的数据进行分析处理, 得到相应的特征矩阵, 并使用相应公式计算出重构数据在映射空间内的主元数 $\gamma_0 = 7$, 构造出主元特征矩阵 \mathbf{T}_{γ_0} 。然后, 求出此矩阵的 SPE 数据, 将该数据与图 7(a) 的控制限进行比较, 结果如图 8(a) 所示。同时, 应用 KPCA 方法分析系统重构矩阵数据及原始数据, 结果分别如图 8(b) 和图 8(c) 所示。

由图 8 分析的结果可知, 在故障工况中, 3 种分析方法的统计量均在 $t=361$ h 时超过控制限, 出现故障报警, 且根据船舶所提供的相关信息得知, 当 $t=361$ h 时, 主机 6 号气缸排气阀出现故障,

进排气系统内部出现异常。3 种分析方法均可检测出故障时间点, 各自的 *MDR* 皆为 0。当系统未

发生故障时, 对 3 种方法的诊断效果进行分析, 结果如图 9 所示。




图 8 故障数据分析图

Fig. 8 Failure data analysis diagram




图 9 SPE 部分分析图

Fig. 9 Partial analysis diagram of *SPE*

根据图 9 中的 *SPE* 数据值和式 (13), 分别对图 9(a)~图 9(c) 相应分析方法的 *FAR* 值进行计算, 结果依次为 7.3%, 10.9% 和 17.5%。从图 9(a) 和图 9(b) 分析结果可知, 相对于 CPV 方法, 关联维数对映射数据主元的筛选具有一定的优势, 可减少故障检测波动; 从图 9(b) 和图 9(c) 分析结果可知, KPCA 对系统重构后的数据进行分析可有效提高数据诊断的精确性, 降低误报警次数; 从图 9(a) 和图 9(c) 分析结果可知, 动态特征融合分析方法相对于 KPCA 方法, 可有效降低系统故障诊断过程中的误警率, 显著提升系统运行的可靠性和安全性。

为验证本文所用方法与其他传统方法的区别, 选择与故障诊断中应用广泛的支持向量机 (SVM)^[17] 方法进行对比。图 10 所示为利用 SVM 方法对进排气系统数据进行建模与故障分析得到的结果。图中, 类别标签 1 与 2 分别表示进排气系统的正常与故障运行状况




图 10 SVM 故障诊断图

Fig. 10 SVM fault diagnosis diagram

利用式 (12) 和式 (13) 可计算得出 SVM 方法的 *MDR* 和 *FAR* 分别为 10% 及 11.39%。通过与 SVM 方法对比可知, 本文采用的动态特征融合方法具有更高的检测精度, 故障诊断能力更优异。

4 结 语

本文采用动态特征融合分析方法构建了基于船舶柴油机进排气系统健康数据的离线监测模型, 利用此模型对系统故障数据进行了验证分析。结果表明, 利用动态融合分析方法可有效实现故障诊断, 相较于 KPCA 与 SVM 方法, 动态融合分析方法有效降低了误警率与漏检率, 减少了分析时的误报警次数, 进一步提高了系统设备运行的稳定性和可靠性。本文所用方法可对动态数据进行分析, 因此可将其对船舶各系统的在线诊断分析作为未来的研究目标。在建模过程中, 方法部分参数的筛选依赖于人员判断, 因此需要选择合适的数据作为训练集, 确保参数及控制限选取的合理性。

参考文献:

[1] 严新平, 王树武, 马枫. 智能货运船舶研究现状与发展思考 [J]. *中国舰船研究*, 2021, 16(1): 1-6.
YAN X P, WANG S W, MA F. Review and prospect for intelligent cargo ships[J]. *Chinese Journal of Ship Research*, 2021, 16(1): 1-6 (in Chinese).

[2] 操江能, 杨闽松. 船舶柴油机故障诊断技术探析 [J]. *内燃机与配件*, 2021(12): 142-143.
CAO J N, YANG M S. Research on the fault diagnosis technology of marine diesel engines[J]. *Internal Combustion Engines & Parts*, 2021(12): 142-143 (in Chinese).

[3] 张黎明, 蔡琦, 赵新文, 等. 基于信息融合的核管道缺陷检测研究 [J]. *中国舰船研究*, 2010, 5(6): 75-77, 83.
ZHANG L M, CAI Q, ZHAO X W, et al. Defect

- detection of nuclear piping system by information fusion technology[J]. *Chinese Journal of Ship Research*, 2010, 5(6): 75–77, 83 (in Chinese).
- [4] 李玉红. 基于主元分析法的煤矿空气压缩机故障诊断 [J]. *水力采煤与管道运输*, 2019(4): 150–152.
LI Y H. Fault diagnosis of coal mine air compressor based on principal component analysis[J]. *Hydraulic Coal Mining & Pipeline Transportation*, 2019(4): 150–152 (in Chinese).
- [5] 吴天昊, 刘韬, 施海宁, 等. 基于核主元分析法的核电厂设备状态监测技术研究 [J]. *核动力工程*, 2020, 41(5): 132–137.
WU T H, LIU T, SHI H N, et al. Research on condition monitoring technology for nuclear power plant equipment based on kernel principal component analysis[J]. *Nuclear Power Engineering*, 2020, 41(5): 132–137 (in Chinese).
- [6] ZHANG Q, LI P, LANG X, et al. Improved dynamic kernel principal component analysis for fault detection[J]. *Measurement*, 2020, 158: 107738.
- [7] BOUNOUA W, BAKDI A. Fault detection and diagnosis of nonlinear dynamical processes through correlation dimension and fractal analysis based dynamic kernel PCA [J]. *Chemical Engineering Science*, 2021, 229: 116099.
- [8] 周伟健, 江国和. 船舶柴油机进排气系统故障仿真软件设计与实现 [J]. *机电设备*, 2018, 35(1): 37–40.
ZHOU W J, JIANG G H. Design and implementation of marine diesel engine intake and exhaust system fault simulation software[J]. *Mechanical and Electrical Equipment*, 2018, 35(1): 37–40 (in Chinese).
- [9] 梁少军, 张世荣, 郑幸, 等. 基于 DKPCA 的固定翼无人机多工况在线故障诊断 [J]. *西北工业大学学报*, 2020, 38(3): 619–626.
LIANG S J, ZHANG S R, ZHENG X, et al. Online fault detection of fixed-wing UAV based on DKPCA algorithm with multiple operation conditions considered [J]. *Journal of Northwestern Polytechnical University*, 2020, 38(3): 619–626 (in Chinese).
- [10] 崔建国, 刘瑶, 郑蔚, 等. DPCA 和 GRNN 在燃气轮机故障诊断的方法 [J]. *火力与指挥控制*, 2017, 42(11): 186–190.
CUI J G, LIU Y, ZHENG W, et al. DPCA and GRNN in gas turbine fault diagnosis method of research[J]. *Fire Control & Command Control*, 2017, 42(11): 186–190 (in Chinese).
- [11] 刘伟强. 分形理论在故障诊断中的应用研究 [D]. 长沙: 国防科技大学, 2018.
LIU W Q. Research on application of fractal theory in fault diagnosis[D]. Changsha: National University of Defense Technology, 2018 (in Chinese).
- [12] 庞茂, 吴瑞明, 谢明祥. 关联维数快速算法及其在机械故障诊断中的应用 [J]. *振动与冲击*, 2010, 29(12): 106–109.
PANG M, WU R M, XIE M X. Improved correlation dimension algorithm with its application to mechanical fault diagnosis[J]. *Journal of Vibration and Shock*, 2010, 29(12): 106–109 (in Chinese).
- [13] 邓晓刚, 田学民. 一种基于 KPCA 的非线性故障诊断方法 [J]. *山东大学学报(工学版)*, 2005, 35(3): 103–106.
DENG X G, TIAN X M. Nonlinear process fault diagnosis method using kernel principal component analysis [J]. *Journal of Shandong University (Engineering Science)*, 2005, 35(3): 103–106 (in Chinese).
- [14] ZIEGEL E R. A step-by-step approach to using the SAS system for univariate and multivariate statistics[J]. *Technometrics*, 1995, 37(4): 471.
- [15] 翟坤, 杜文霞, 吕锋, 等. 一种改进的动态核主元分析故障检测方法 [J]. *化工学报*, 2019, 70(2): 716–722.
ZHAI K, DU W X, LV F, et al. Fault detect method based on improved dynamic kernel principal component analysis[J]. *CIESC Journal*, 2019, 70(2): 716–722 (in Chinese).
- [16] WACHS A, LEWIN D R. Improved PCA methods for process disturbance and failure identification[J]. *AIChE Journal*, 1999, 45(8): 1688–1700.
- [17] 胡璇, 李春, 叶柯华. 灰狼算法优化支持向量机在风力机齿轮箱故障诊断中的应用 [J]. *机械强度*, 2021, 43(5): 1026–1034.
HU X, LI C, YE K H. Application of GWO-SVM in wind turbine gearbox fault diagnosis[J]. *Journal of Mechanical Strength*, 2021, 43(5): 1026–1034 (in Chinese).