

# 基于 DCCA-DAE 模型的传感器故障检测\*

黄凯<sup>1</sup>, 王薇<sup>2</sup>, 朱永生<sup>1</sup>, 任智军<sup>1</sup>, 林昱涛<sup>1</sup>

(1. 西安交通大学现代设计及转子轴承系统教育部重点实验室 西安, 710049)

(2. 西安航天动力试验技术研究所 西安, 710065)

**摘要** 传感器作为复杂装备监测系统的关键组成部分,若发生故障会引起误报警,极大影响复杂机械系统状态监测的可靠性。针对该难题,笔者从系统角度出发,提出一种基于去趋势互相关分析(detrended cross-correlation analysis,简称DCCA)和双尺度自编码器(dual auto encoder,简称DAE)的传感器故障检测方法,记作DCCA-DAE。首先,采用DCCA方法建立耦合网络,将数据从欧氏空间扩展到拓扑空间,实现对系统多源多态监测数据蕴含信息的全面表征;其次,构建基于DAE的异常检测方法,消除工况变化对传感器监测序列产生的影响,实现工况复杂变化下的系统传感器故障准确检测;最后,利用某电厂汽轮机组历史数据,验证所提方法的综合性能。结果表明,DCCA-DAE模型特征提取能力强,检测精度显著优于传统支持向量描述和自编码器等方法,在工业场景中传感器故障检测领域具有良好的应用前景。

**关键词** 传感器故障检测;去趋势互相关;耦合关系网络;自编码器

**中图分类号** TH165.3;TK26

## 引言

传感器作为复杂机械装备监测系统的最前端,若发生故障会造成原始监测信号的损坏而产生误报警,极大降低了复杂机械系统状态监测的可靠性。因此,深入研究传感器的故障检测方法,对保证大型设备及复杂装备的连续可靠运行十分重要。

目前,相关学者已提出并讨论了多种传感器故障检测技术。其中,基于物理模型的方法已被证明是有效且普遍采用的方法<sup>[1]</sup>。然而,复杂设备中传感器数量较多,且测点分布范围较广,往往难以建立全面的物理模型。随着人工智能的发展,基于机器学习的传感器故障检测方法如支持向量机方法<sup>[2]</sup>、人工神经网络模型<sup>[3]</sup>、改进主成分分析算法<sup>[4]</sup>等逐渐受到广泛关注。然而,由于这些方法依赖特征工程,因此只能实现较为有限的检测性能。

近年来,随着分布式控制系统(distributed control system,简称DCS)等现代监测系统的部署,大型设备的传感器监测数据呈现出多源多态、海量的特点<sup>[5]</sup>。凭借强大的特征自动提取能力,基于数据驱动的深度学习方法已成为传感器故障检测领域的

新兴研究方向<sup>[6]</sup>。Liu等<sup>[7]</sup>采用一维卷积神经网络和聚类分析来检测和诊断空调传感器故障。Choi等<sup>[8]</sup>提出了一种基于一致性指数的长短时记忆网络,应用于核电站紧急情况下的传感器故障检测。当前研究通过引入深度学习模型,极大提升了复杂系统中传感器故障检测和诊断的准确率,但仍普遍存在对多源多态、海量监测数据特征提取能力不足,以及未考虑复杂工况下多传感器存在耦合关联变化的问题。实际上,工况复杂变化的系统传感器监测数据受工况影响较大,会对故障检测产生干扰,导致检测准确性降低。

为解决上述问题,实现复杂多变工况下大型设备及复杂装备传感器故障的准确检测,笔者提出一种基于DCCA和DAE的传感器故障检测方法,记作DCCA-DAE。首先,采用DCCA建立耦合网络,将数据从欧氏空间扩展到拓扑空间,实现对系统多源多态监测数据蕴含特征的全面表征。在此基础上,构建一个DAE的异常检测模型,消除工况变化对传感器监测序列产生的影响,实现工况复杂变化条件下的系统传感器故障准确检测。最后,在汽轮机DCS数据集上验证所提方法的有效性。

\* 国家重点研发计划资助项目(2019YFB2004303)

收稿日期:2022-10-23;修回日期:2022-12-17

# 1 理论基础

## 1.1 DCCA

在复杂机械装备监测系统中,监测数据具有明显非线性、非平稳性以及长程相关性等特性,同时不同监测序列间表现出相关性。DCCA是在去趋势协方差基础上的推广,旨在研究非平稳性时间序列之间的幂律交叉相关性<sup>[9]</sup>。因此,可采用DCCA方法量化监测序列间的长程交叉相关性,定量表征两两监测变量间的耦合关系。DCCA方法具体实现过程如下。

1) 分别计算2个等长度为 $N$ 的长程交叉相关时间序列 $\{y_i\}$ 和 $\{y'_i\}$ 的集成序列 $\{R_k\}$ 和 $\{R'_k\}$ ,即

$$\begin{cases} R_k = \sum_{i=1}^k y_i & (k = 1, 2, \dots, N) \\ R'_k = \sum_{i=1}^k y'_i & (k = 1, 2, \dots, N) \end{cases} \quad (1)$$

2) 将 $\{R_k\}$ 和 $\{R'_k\}$ 划分为 $N-n$ 个相互交叉重叠的区域,图1为集成序列划分过程,每个区域中均含有 $n+1$ 个样本,且每个区域内样本下标均以 $i$ 开始,以 $i+n$ 结束。

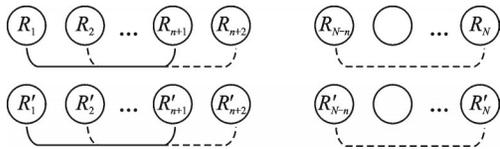


图1 集成序列划分过程

Fig.1 Integration sequence segmentation

3) 定义集成序列的局部趋势 $\tilde{R}_k$ 和 $\tilde{R}'_k$ ,即对所划分区域中的 $n+1$ 个样本数据进行最小二乘线性拟合得到的序列。

4) 定义两集成序列间的去趋势游走,即每个区域内集成序列数据与局部趋势之间的差值为

$$\begin{cases} |\tilde{R}_k - R_k| & (k = i, i+1, \dots, i+n) \\ |\tilde{R}'_k - R'_k| & (k = i, i+1, \dots, i+n) \end{cases} \quad (2)$$

5) 计算每个区域对应的协方差为

$$f_{DCCA}^2(n, i) = \frac{1}{N-n} \sum_{k=i}^{i+n} (R_k - \tilde{R}_k)(R'_k - \tilde{R}'_k) \quad (3)$$

6) 计算所有区域对应的去趋势协方差为

$$F_{DCCA}^2(n) = \frac{1}{N-n} \sum_{i=1}^{N-n} f_{DCCA}^2(n, i) \quad (4)$$

7) 重复上述分析流程,得到在不同标度 $s$ 时对应的波动函数,当2个序列具有明显的长相关性时,去趋势协方差函数与标度 $n$ 满足的条件为

$$F_{DCCA}(n) \sim n^h \quad (5)$$

其中: $h$ 为DCCA标度指数,用以表征两序列间耦合特征,即衡量两序列间的耦合强度。

## 1.2 自编码器

DAE是笔者所提方法的重要组成部分,其原理与自编码器(auto encoder,简称AE)一致。AE是一种无监督的深度学习算法,其结构示意图如图2所示。

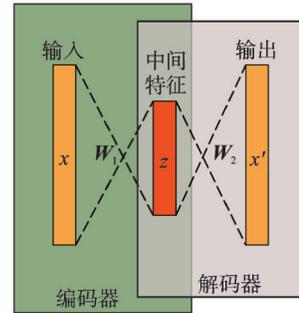


图2 AE结构示意图

Fig.2 The architecture of AE

设 $x$ 为其中1个数据样本。将 $x$ 作为AE的输入数据,经过编码阶段得到中间特征数据,记为 $z$ 。 $z$ 经过解码计算得到输出信息 $x'$ 。AE的目标是使得输出结果等于输入值,即 $x \approx x'$ ,编码阶段将输入 $x$ 进行编码得到 $z$ ,其计算公式为

$$z = \sigma(W_1 x + b_1) \quad (6)$$

其中: $\sigma(\cdot)$ 为激活函数,具体为ReLU函数; $W_1$ 与 $b_1$ 分别为需要学习的编码器权重和偏差。

解码部分将编码后的 $z$ 进行解码得到 $x'$ ,即

$$x' = \sigma(W_2 z + b_2) \quad (7)$$

在训练过程中,AE采用误差反向传播算法,不断对编码器及解码器的参数进行优化调整,使重构误差最小化。重构误差的表达式为

$$E = \sum_{x \in X} J(x, x') \quad (8)$$

其中: $J$ 为重构误差函数,一般选择均方误差函数。

AE为无监督算法,当输入数据发生较大变化时,AE重构误差随之增大。因此,基于海量正常传感器数据训练AE,可实现传感器故障的有效检测。

# 2 DCCA-DAE模型构建

## 2.1 基于DCCA的耦合关系网络建模

DCCA通过取有限窗口长度的时间序列,分析两变量之间的耦合度。复杂装备系统中多源监测序列一般不存在明确的信号周期,因而可计算混沌序

列的平均周期代替时间序列的变化周期。首先对时间序列进行傅里叶变换,即

$$F(k) = \sum_{n=1}^N x(n) e^{-j2\pi(k-1)\frac{n-1}{N}} \quad (9)$$

进一步以功率对周期加权,并对加权平均进行估算,即

$$T = \frac{\sum_{n=2}^N \frac{NF^2(n)}{2\pi(n-1)}}{\sum_{n=2}^N F^2(n)} \quad (10)$$

分别计算每一维时间序列的平均周期,最大平均周期  $T = \max(T_i)$  为窗口宽度。采用窗口宽度  $T$  截取监测系统各变量时序数据,并据此构建  $m$  维等长时间序列集合  $X_m = \{x_1, x_2, \dots, x_m\}$ , 其中,  $x_m$  为第  $m$  维监测变量。基于式(1)~(5)分别计算集合中两两变量之间的标度指数,进一步按照 DCCA 标度指数下标进行排列,得到的 DCCA 标度指数矩阵为

$$A = \begin{bmatrix} h_{11} & \dots & h_{1m} \\ \vdots & & \vdots \\ h_{m1} & \dots & h_{mm} \end{bmatrix} \quad (11)$$

将  $X_m$  矩阵化为网络模型可处理的形式,表示为  $X$ , 以  $X$  为节点,以 DCCA 标度系数对称矩阵  $A$  (简称 DCCA 矩阵) 为边构建耦合关系网络,图 3 为耦合关系网络示意图。网络表示为  $G = (X, A)$ , 图中每个节点代表 1 个监测时间序列,节点间的连线代表节点间的耦合关系程度,用 DCCA 矩阵表示,没有连线则表示节点之间不存在耦合关系。

## 2.2 DAE 模型的构建

如 2.1 小节所述,耦合关系网中节点表征传感

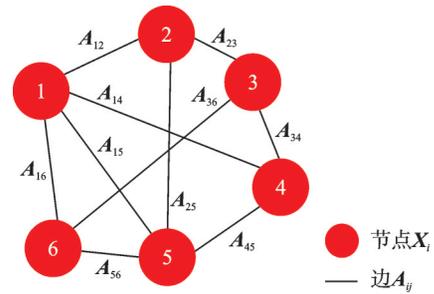


图 3 耦合关系网络示意图

Fig.3 Diagram of coupling relationship network

器监测序列,称为节点属性,边表征不同传感器监测序列间的关联关系。由于耦合网络中包含大量节点及边等高维数据,难以直接进行处理,因此需引入节点嵌入捕捉网络的拓扑结构信息。

基于此,笔者提出以 DAE 模型进行节点嵌入。图 4 为 DAE 模型结构,DAE 是一个端到端的联合特征表示学习框架,由 1 个用于网络节点间关系重构的关系自编码器和 1 个用于节点属性重构的属性自编码器组成。以网络中任一节点的属性向量和关系向量作为输入数据,DAE 的编码器分别学习节点属性和关系的嵌入表示,属性解码器和关系解码器分别对属性和关系的嵌入表示进行重构。训练过程中,模型共同捕获网络节点属性和关系间的相互作用,再通过节点属性和关系的重构误差来检测网络中节点(传感器)的异常情况。

### 2.2.1 关系自编码器的构建

与 2.1 节中矩阵  $A$  不同,本节以  $A$  表示当前关系自编码器的标识,用于区分不同的编码器。为获得足够具有代表性的节点特征,采用关系编码器将耦合关系网络中原始的节点属性  $X$  通过编码层转换

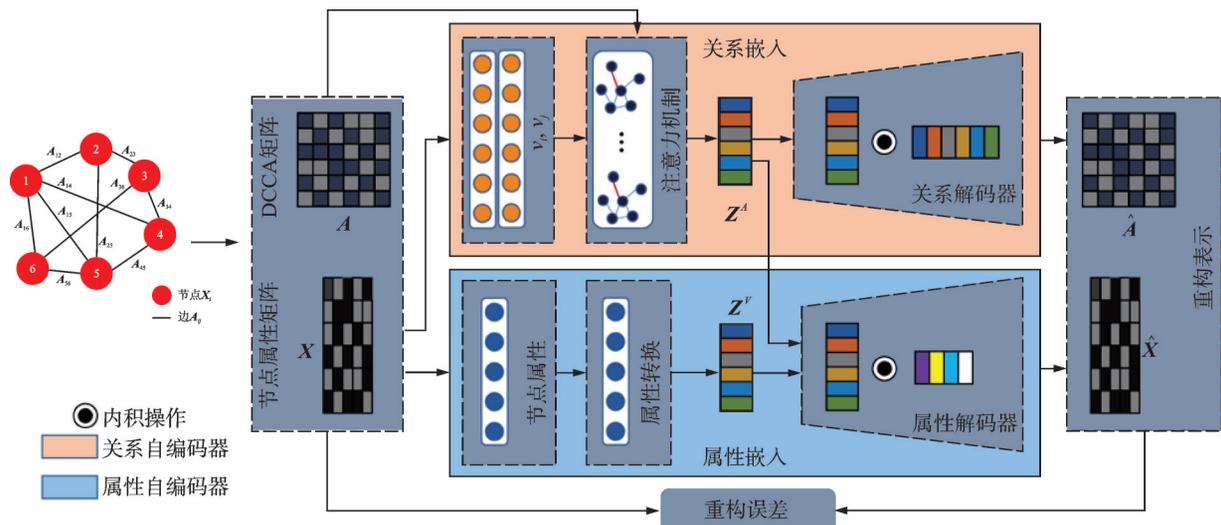


图 4 DAE 模型结构

Fig.4 The architecture of DAE model

为低维潜在嵌入 $\tilde{Z}^A$ ,即

$$\tilde{Z}^A = \sigma(\mathbf{X}\mathbf{W}^{A(1)} + \mathbf{b}^{A(1)}) \quad (12)$$

其中: $\mathbf{W}^{A(1)} \in R^{D_{in}^{A(1)} \times D_{out}^{A(1)}}$ 、 $\mathbf{b}^{A(1)} \in R^{D_{out}^{A(1)}}$ 分别为需要学习的编码器权重和偏差; $D_{in}^{A(1)}$ 、 $D_{out}^{A(1)}$ 分别为 $\mathbf{X}$ 和 $\tilde{Z}^A$ 的维度。

给定转换后的节点潜在嵌入表示后,使用图注意力层执行共享注意力机制融合邻域节点的信息,即

$$I_{i,l} = \text{attn}(\tilde{Z}_i^A, \tilde{Z}_l^A) = \sigma\left(\mathbf{a}^\top [\mathbf{W}^{A(2)} \tilde{Z}_i^A // \mathbf{W}^{A(2)} \tilde{Z}_l^A]\right) \quad (13)$$

其中: $I_{i,l}$ 为节点 $v_i$ 对 $v_l$ 的重要度;attn( $\cdot$ )为在所有节点上共享参数 $\mathbf{a} \in R^D$ 和 $\mathbf{W}^{A(2)} \in R^{\frac{D}{2} \times D_{out}^{A(1)}}$ 的参数化神经网络;//为级联操作。

再通过softmax函数规范化得到重要度权重为

$$\gamma_{i,l} = \frac{\exp(I_{i,l})}{\sum_{k \in N_i} \exp(I_{i,k})} \quad (14)$$

其中: $N_i$ 为节点 $v_i$ 的邻域节点集合,由DCCA矩阵得到。

获取所有邻域节点的重要度权重,并与对应的节点潜在嵌入加权后求和,可得到节点 $v_i$ 最终的关系嵌入为

$$\mathbf{Z}_i^A = \sum_{k \in N_i} \gamma_{i,k} \tilde{Z}_k^A \quad (15)$$

最后,关系解码器以最终节点的关系嵌入 $\mathbf{Z}_i^A$ 作为输入,对其进行解码,重构的原始耦合网络节点关系为

$$\hat{\mathbf{A}} = \text{sigmoid}\left(\mathbf{Z}^A (\mathbf{Z}^A)^\top\right) \quad (16)$$

其中:sigmoid( $\cdot$ )为激活函数。

解码器通过计算节点 $v_i$ 与其邻域节点的内积来估计两节点间连接的概率,即

$$p(\hat{A}_{i,l} = 1 | \mathbf{Z}_i^A, \mathbf{Z}_l^A) = \text{sigmoid}\left(\mathbf{Z}_i^A (\mathbf{Z}_l^A)^\top\right) \quad (17)$$

### 2.2.2 属性自编码器的构建

本小节中,以 $\mathbf{X}$ 表示当前属性自编码器的标识。在属性自编码器中,采用2个非线性特征变化层,将耦合网络节点的属性数据映射为潜在属性嵌入表示 $\mathbf{Z}^X$ ,即

$$\tilde{\mathbf{Z}}^X = \sigma((\mathbf{X})^\top \mathbf{W}^{X(1)} + \mathbf{b}^{X(1)}) \quad (18)$$

$$\mathbf{Z}^X = \tilde{\mathbf{Z}}^X \mathbf{W}^{X(2)} + \mathbf{b}^{X(2)} \quad (19)$$

其中: $\mathbf{W}^{X(1)} \in R^{D_{in}^{X(1)} \times D_{out}^{X(1)}}$ 、 $\mathbf{W}^{X(2)} \in R^{D_{out}^{X(1)} \times D}$ 与 $\mathbf{b}^{X(1)} \in R^{D_{out}^{X(1)}}$ 、 $\mathbf{b}^{X(2)} \in R^D$ 分别为两层多层感知机的权重和偏差; $D_{in}^{X(1)}$ 、 $D_{out}^{X(1)}$ 和 $D$ 分别为 $(\mathbf{X})^\top$ 、 $\tilde{\mathbf{Z}}^X$ 和 $\mathbf{Z}^X$ 的维度。

随后,属性解码器以关系编码器学习到的节点关系嵌入 $\mathbf{Z}^A$ 和属性编码器学到的节点属性嵌入 $\mathbf{Z}^X$ 作为输入,联合捕获网络节点关系与属性之间的相互作用,并进行解码重构,即

$$\hat{\mathbf{X}} = \mathbf{Z}^A (\mathbf{Z}^X)^\top \quad (20)$$

### 2.2.3 损失函数的构建

DAE模型的训练目标是最小化网络节点关系和属性的重构误差,其重构误差为

$$L = \alpha \left\| (\mathbf{A} - \hat{\mathbf{A}}) \odot \theta \right\|_F^2 + (1 - \alpha) \left\| (\mathbf{X} - \hat{\mathbf{X}}) \right\|_F^2 \quad (21)$$

其中: $\alpha$ 为控制节点关系重建和属性重建之间占比的权衡参数; $\odot$ 为Hadamard积。

$\theta$ 为惩罚参数,定义为

$$\theta_{i,l} = \begin{cases} 1 & (A_{i,l} = 0) \\ \theta & \text{其他} \end{cases} \quad (22)$$

由于网络节点的DCCA矩阵中存在零元素(即存在节点间无连接的情况),因此 $\theta > 1$ 可用于对非零元素的重构误差添加更多的惩罚,以获取更多有用特征。

采用梯度下降法最小化损失函数,通过多轮的迭代优化,模型的损失函数逐渐下降至趋于稳定,表示模型训练已完成。

## 2.3 基于DCCA-DAE的传感器异常检测流程

为检测传感器异常状态,将DAE衔接DCCA耦合关系网络,以节点属性及关联关系为输入,通过重构原始节点关系和属性的方式学习节点的关系和属性特征。节点发生异常时,其关系和属性特征将发生变化,DAE模型的重构误差将会增大。基于此,可实现检测传感器是否发生故障的目的。

基于模型的重构误差定义节点 $v_{it}$ 的异常分数 $S_{it}$ 为

$$S_{it} = \alpha \left( \mathbf{A}_{it} - \hat{\mathbf{A}}_{it} \right) \odot \theta_{it}^2 + (1 - \alpha) \left( \mathbf{X}_{it} - \hat{\mathbf{X}}_{it} \right)_F^2 \quad (23)$$

其中: $\mathbf{A}_{it}$ 、 $\hat{\mathbf{A}}_{it}$ 分别为第 $t$ 时间窗口下节点 $v_i$ 的关系向量和重构关系向量; $\mathbf{X}_{it}$ 、 $\hat{\mathbf{X}}_{it}$ 分别为第 $t$ 时间窗口下节点 $v_i$ 的属性向量和重构属性向量。

进一步使用以下规则判断节点(传感器)是否异常,即

$$y_{it} = \begin{cases} 1 & (S_{it} \geq \lambda) \\ 0 & \text{其他} \end{cases} \quad (24)$$

其中: $y_{it}$ 为待检测节点的标签;1为异常状态;0为正常状态; $\lambda$ 为异常阈值。

综上,基于DCCA-DAE的传感器故障检测流程如图5所示。

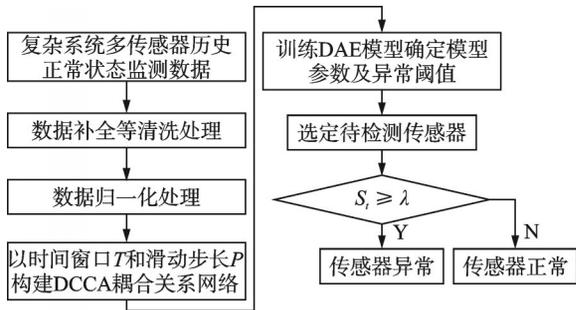


图5 基于DCCA-DAE的传感器故障检测流程

Fig.5 Sensor fault detection process based on DCCA-DAE method

### 3 实验数据分析

为验证所提传感器异常检测方法的有效性,在真实的汽轮机转子系统传感器监测数据上增加漂移软故障,开展一系列仿真实验。

#### 3.1 汽轮机数据集描述与处理

数据来源于某火力发电厂正在服役的日立东方N1000-250/600/600型汽轮机,取自DCS监测系统中2017年全年的历史运行状态数据,去除冗余测点后,保留33个监测序列。表1为汽轮机转子系统监测变量,仅展示了部分保留下的监测变量。图6为汽轮机转子系统测点位置示意图,轴承1安装位置对应图中一瓦处,轴承4安装位置对应图中四瓦处,其他同理。

表1 汽轮机转子系统监测变量表

Tab.1 Monitoring variables of turbine rotor system

变量序号	变量名	变量描述
0	DCS2.20MAD11CT011A	轴承1前上温度
1	DCS2.20MAD11CY021	轴承1上的振动1
2	DCS2.20MAD14CY940	轴承4上的振动2
3	DCS2.20MAD18CY021	轴承8上的振动

由于DCS的稀疏存储规则、温度与振动传感器采样率均存在差异,笔者使用相邻2个监测数据点变化范围内的随机插值方法,对监测数据进行补全。补全后不同监测序列点数均为525 600点。以DCS2.20MAD11CT011A和DCS2.20MAD11CY021为例,图7为监测点序列图。

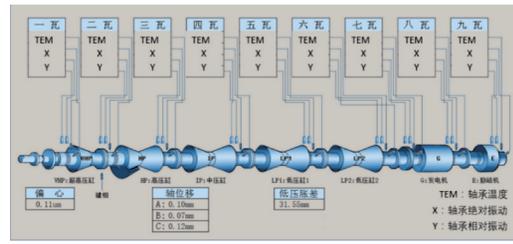


图6 汽轮机转子系统测点位置示意图

Fig.6 Diagram of measuring point position in turbine rotor system

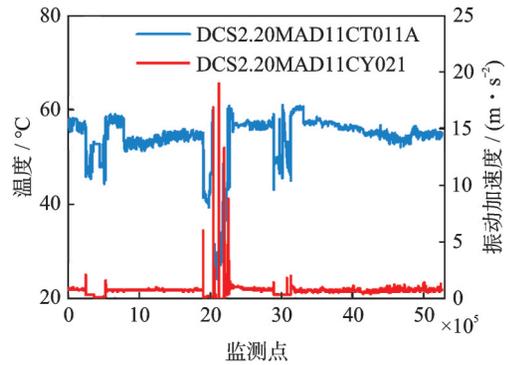


图7 监测点序列图

Fig.7 Time series of measuring points

选择全年中汽轮机设备正常平稳运行状态下的历史监测数据段(监测点87 100~95 000)为对象,分为训练数据段(87 100~90 000,包含2 900监测点)和测试数据段(90 000~95 000,包含5 000监测点)。选取其中3个具有不同波动特性的传感器DCS2.20MAD11CT-011A、DCS2.20MAD14CY940和DCS2.20MAD-18CY021,图8为原始监测序列及仿真故障监测序列,分别对测试数据段监测点4 000位置处注入漂移软故障,以模拟不同的传感器异常。此外,考虑到不同传感数据量纲不同,对所筛选的33维时间序列的训练数据段和测试数据段进行最大、最小归一化处理。

对于处理好的训练数据段,采用全部33个正常传感器监测序列构建耦合关系网络训练集。对于测试数据段,则每次取其中1个故障传感器序列,与剩余32个正常传感器监测序列共同构建耦合关系网络测试集,产生3类模拟故障测试集。关于耦合关系网络的构建,以式(9)、(10)计算得出最大平均周期为 $T=1\ 900$ 。以步长 $P=10$ 对预处理后的多维时间序列进行滑动遍历。由式(11)构建出连续耦合关系网络数据集。在某一传感器故障模式下进行滑动遍历,可构建出共计412个耦合网络(训练集101个,测试集311个)。

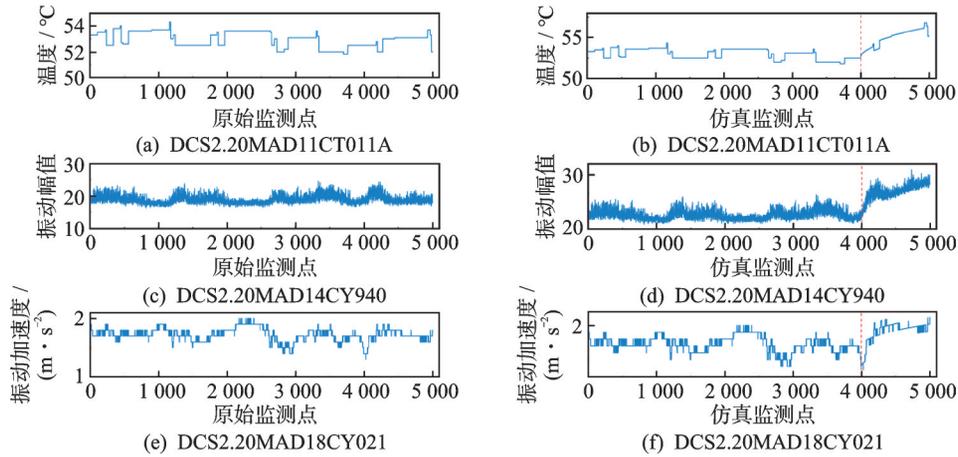


图 8 原始监测序列及仿真故障监测序列

Fig.8 Raw monitoring series and corresponding simulated fault monitoring series

### 3.2 模型参数设置

本节通过改变单一参数取值来分别讨论模型关键参数对模型性能的影响。为降低初始化等随机因素的干扰,以单次设定参数下 10 次重复实验的受试者工作特征曲线下面积(area under curve,简称 AUC)<sup>[10]</sup>的平均值为指标进行评价,AUC 为无量纲。

图 9 为不同参数对模型性能的影响。图 9(a)为模型的编码层数对性能的影响,可以看出模型在编码层数为 2 时表现最佳。过多的层数增加了计算成本,也会使模型产生过拟合。图 9(b)为不同嵌入维度对模型性能的影响,嵌入维度增大至 18 时性能较好,嵌入维度继续增加,性能则开始下降,原因在于维度过高会提取无关特征信息。图 9(c)为不同权衡参数对模型整体性能的影响, $\alpha = 0.7$  时的模型性能有较大提升,表明网络节点关系与属性之间均包

含重要的特征信息,验证了所提方法的必要性和有效性。图 9(d)为惩罚参数对模型性能的影响,当  $\theta$  过小或过大时,性能均会降低。因此,在训练模型时应重视非零元素的重建,但同时不能完全忽略零元素的影响。

综上,选取属性编码层数为 2 层,嵌入维度  $D$  为 18,权衡参数  $\alpha$  取 0.7,惩罚参数  $\theta$  取 10。模型整体迭代次数为 300,使用 Adam 优化算法进行优化,学习率设置为 0.001。

### 3.3 实验结果与分析

同样以 AUC 为异常检测模型指标来评价实验结果,据此验证所提方法的有效性,图 10 为 10 次实验中 DAE 的检测精度。由图可知,10 次验证的 AUC 值均在 0.95 以上,说明所提基于 DCCA 耦合网络的 DAE 异常检测模型能够有效检测出汽轮机组系统级传感器的软故障。

将 3.1 节中已组织的耦合关系网络训练集输入到 DAE 模型中进行训练。由式(21)、(22)计算出模型训练集的重构误差分布,从而确定异常阈值  $\lambda$ 。

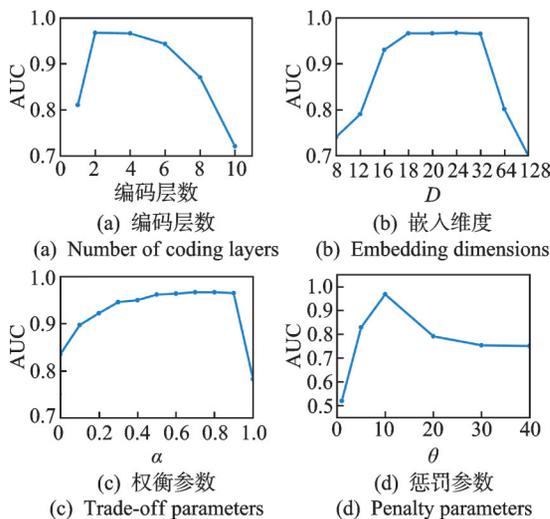


图 9 不同参数对模型性能的影响

Fig.9 Impact of different parameters on model performance

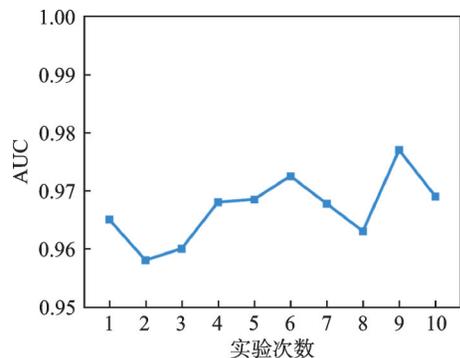


图 10 10 次实验中 DAE 的检测精度

Fig.10 Detection accuracy of DAE in 10 experiments

训练集的误差分布如图11所示,正常数据经过模型编码和解码后的误差分布在19~23范围内。经过模型编码解码后,新数据集的重构误差超出该范围的,则可认为是异常数据,因此取异常阈值 $\lambda = 23$ 。

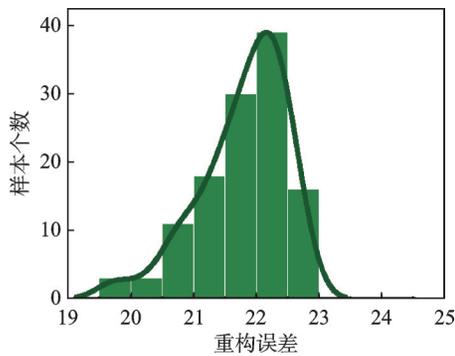


图11 训练集误差分布图

Fig.11 Error distribution based on the training set

在3.1节中,构建了3类不同波动特性传感器模拟故障的耦合网络测试集。依据式(23)计算对应3种故障传感器节点的异常分数 $S_i$ ,当 $S_i$ 大于异常阈值 $\lambda$ 时,模型判定出现异常。图12为不同传感器异常检测结果,当传感器发生故障时, $S_i$ 超过异常阈值,说明提出的DCCA-DAE模型可有效实现系统级传感器的异常检测。

为进一步验证DCCA-DAE的优越性,将该方法与局部异常因子(local outlier factor,简称LOF)方法<sup>[11]</sup>、支持向量描述(support vector domain description,简称SVDD)<sup>[12]</sup>和AE<sup>[13]</sup>等常见检测方法进行对比。LOF和SVDD均未考虑系统传感器间的耦合关系,仅检测待检测传感器时间序列。AE

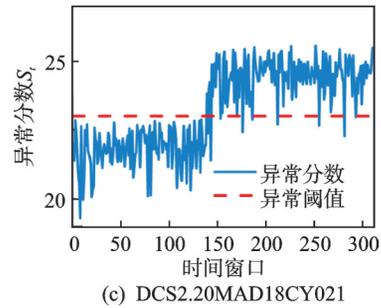
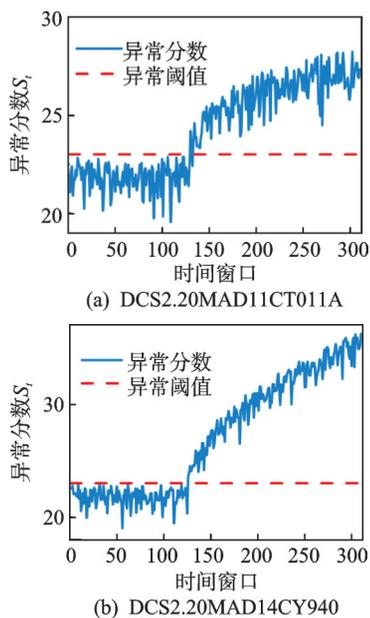


图12 不同传感器异常检测结果

Fig.12 Anomaly detection results for different sensors

方法分别以原始传感器序列(AE)、耦合网络节点属性(X-AE)和耦合网络节点关系(A-AE)作为输入进行异常检测。

将所提方法与上述对比方法分别进行实验,在3种传感器故障模式下各方法的AUC如表2所示。分析可知,SVDD算法检测效果最差,LOF算法在不同模式下的表现存在较大差异,鲁棒性较差。AE、X-AE和A-AE的性能均低于DAE模型,后者性能分别相当于DAE模型中 $\alpha = 1$ 及 $\alpha = 0$ 的极端情况。DAE模型结合网络节点关系和属性信息,可捕捉节点的更深层特征,能够准确检测出传感器的异常演化。

综上可知,具有不同波动特性的传感器发生漂移软故障时,笔者所提方法均能准确地检测出传感器异常。分析结果表明,所提方法的性能优于其他方法,验证了基于DCCA-DAE模型的异常检测方法的有效性与优越性。

表2 3种传感器故障模式下各方法的AUC

Tab.2 AUC of each method under 3 sensor failure modes

方法	DCS2.20- MAD- 11CT011A	DCS2.20- MAD- 14CY940	DCS2.20- MAD- 18CY021
SVDD	0.761	0.728	0.694
LOF	0.665	0.902	0.728
AE	0.836	0.944	0.710
X-AE	0.835	0.810	0.781
A-AE	0.762	0.937	0.824
DCCA-DAE	0.967	0.972	0.905

## 4 结论

1) 笔者提出了一种基于DCCA-DAE的传感器故障检测方法,解决了复杂装备系统传感数据多源多态及工况复杂变化条件下,传感器故障难以分析

和鉴别的问题。

2) 采用DCCA方法建立耦合网络,将数据从欧氏空间扩展到拓扑空间,实现了系统多源多态监测数据蕴含信息的全面表征。在此基础上,衔接一个基于DAE的异常检测方法,消除工况变化对传感器监测序列产生的影响,实现了工况复杂变化的系统传感器故障准确检测。

3) 在验证评估阶段,采用某电厂汽轮机转子系统历史多源传感器数据,使用不同传感器的软故障仿真数据进行了验证。结果表明,所提的DCCA-DAE模型特征提取能力强,检测精度显著优于传统SVDD、AE等模型,该模型在工业场景下的传感器故障检测领域具有良好的应用前景。

### 参 考 文 献

- [1] PENG Y, QIAO W, QU L, et al. Sensor fault detection and isolation for a wireless sensor network-based remote wind turbine condition monitoring system [J]. IEEE Transactions on Industry Applications, 2017, 54(2): 1072-1079.
- [2] 谢振龙, 岳彩旭, 刘献礼, 等. 基于EMD-SVM的钛合金铣削过程刀具磨损监测[J]. 振动、测试与诊断, 2022, 42(5): 988-996.  
XIE Zhenlong, YUE Caixu, LIU Xianli, et al. Tool wear monitoring based on EMD-SVM in milling process of Ti-alloy[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(5): 988-996. (in Chinese)
- [3] KAVAZ A G, BARUTCU B. Fault detection of wind turbine sensors using artificial neural networks[J]. Journal of Sensors, 2018, 2018(1): 5628429.
- [4] GAO L, LI D H, YAO L L, et al. Sensor drift fault diagnosis for chiller system using deep recurrent canonical correlation analysis and k-nearest neighbor classifier[J]. ISA Transactions, 2022, 122: 232-246.
- [5] 曹鹏. 旋转机械状态监测方法研究及系统实现[D]. 成都: 西南石油大学, 2014.
- [6] JIANG G Q, HE H B, YAN J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. IEEE Transactions on Industrial Electronics, 2019, 66(4): 3196-3207.
- [7] LIU J J, ZHANG M, WANG H, et al. Sensor fault detection and diagnosis method for AHU using 1-D CNN and clustering analysis [J]. Computational Intelligence and Neuroscience, 2019, 2019(1): 5367217.
- [8] CHOI J, LEE S J. Consistency index-based sensor fault detection system for nuclear power plant emergency situations using an LSTM network[J]. Sensors, 2020, 20(6): 1651.
- [9] PODOBNIK B, STANLEY H E. Detrended cross-correlation analysis: a new method for analyzing two nonstationary time series[J]. Physical Review Letters, 2008, 100(8): 084102.
- [10] 秦锋, 杨波, 程泽凯. 分类器性能评价标准研究[J]. 计算机技术与发展, 2006, 16(10): 85-88.  
QIN Feng, YANG Bo, CHENG Zekai. Research on measure criteria in evaluating classification performance [J]. Computer Technology and Development, 2006, 16(10): 85-88. (in Chinese)
- [11] BREUNIG M M, KRIEGER H P, NG R T, et al. LOF: identifying density-based local outliers[C]// Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data. New York, NY, USA: Association for Computing Machinery, 2000: 93-104.
- [12] 王洪波. 单分类支持向量机的学习方法研究[D]. 杭州: 浙江大学, 2012.
- [13] ZHAO H S, LIU H H, HU W J, et al. Anomaly detection and fault analysis of wind turbine components based on deep learning network[J]. Renewable Energy, 2018, 127: 825-834.



**第一作者简介:**黄凯,男,1997年12月生,博士生。主要研究方向为旋转机械装备的智能故障诊断。

E-mail: 3195730241@qq.com

**通信作者简介:**朱永生,男,1973年9月生,博士、教授。主要研究方向为智能故障诊断及轴承仿真分析。

E-mail: yszhu@xjtu.edu.cn