

基于 PRB-SAE 算法的非线性系统建模及故障诊断方法

赵佳璐,任少君,陈家乐,司凤琪

(东南大学 能源热转换及过程测控教育部重点实验室,江苏 南京 210096)

摘要:提出了一种基于并行重构堆叠自编码的故障诊断方法。该方法在常规堆叠自编码器基础上引入预设故障方向,采用梯度下降法在所有可能的预设故障方向上进行数据重构,通过比较重构后的平方预测误差(SPE)来确定最佳故障方向和故障幅值,从而抑制残差污染。针对大规模复杂系统的高维特点,进一步通过并行重构方法来提高数据重构效率,减少计算时间,满足在线诊断要求。采用数值算例和工程算例来验证所提方法的有效性。结果表明:该方法对于单参数简单故障和多参数复杂故障都有很好的诊断效果,与常规堆叠自编码方法相比,大大降低了故障误诊率,提高了诊断准确性。

关键词:深度学习;故障诊断;堆叠自编码;过程监测

中图分类号:TP206.3 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2022.09.024

[引用本文格式]赵佳璐,任少君,陈家乐,等.基于PRB-SAE算法的非线性系统建模及故障诊断方法[J].热能动力工程,2022,37(9):197-205. ZHAO Jia-lu,REN Shao-jun,CHEN Jia-le,et al. Nonlinear system modeling and fault diagnosis method based on PRB-SAE algorithm[J]. Journal of Engineering for Thermal Energy and Power,2022,37(9):197-205.

Nonlinear System Modeling and Fault Diagnosis Method based on PRB-SAE Algorithm

ZHAO Jia-lu,REN Shao-jun,CHEN Jia-le,SI Feng-qi

(Key Laboratory of Energy Thermal Conversion and Control of Ministry of Education, Southeast University,
Nanjing, China, Post Code:210096)

Abstract: This paper proposes a new fault diagnosis method of parallel reconstruction-based stacked autoencoder (PRB-SAE). In order to suppress residual pollution, this method introduces preset fault directions on the basis of conventional stacked autoencoders. The gradient descent method is used to reconstruct data in all possible preset fault directions, and the optimal fault direction and fault amplitude are determined by comparing the square prediction error (SPE) after reconstruction. In view of the high-dimensional characteristics of large-scale complex systems, the parallel reconstruction method is further used to improve the data correction efficiency, reduce the calculation time and meet the requirements of online diagnosis. The effectiveness of the proposed method is evaluated on a numerical example and an industrial example. The results show that the method proposed in this paper has a good diagnostic effect both on simple single-parameter faults and complex multi-parameter faults. Compared with the conventional stacked autoencoders method, this method greatly reduces the fault diagnosis rate and improves the diagnosis accuracy.

Key words: deep learning, fault diagnosis, stacked autoencoder, process monitoring

引 言

对发电设备进行状态监测和诊断能够及时发现故障的早期征兆,从而有效减少设备故障造成的安全事故和经济损失^[1-3]。随着人工智能技术的不断发展,基于多元统计分析^[4-6]、神经网络^[6-8]、支持向量机^[9-10]以及深度学习^[11-12]等数据驱动的故障诊断方法已经引起了研究者的广泛关注。

堆叠自编码(Stacked Autoencoder, SAE)是一种典型的深度学习方法,该方法能够有效表达复杂高维系统的线性和非线性特征^[13]。张泽瀚等人^[14]提出了一种基于变分自编码的非线性系统监测方法,对自编码提取的特征进行约束使其符合高斯分布,提高了基于统计量故障检测的准确率。Li 等人^[15]提出了基于稀疏自编码器的半监督故障分类方法来解决动态非线性问题。然而,目前基于堆叠自编码的故障诊断方法均依赖于历史故障数据进行有监督分类学习,当历史数据中缺少故障数据时,训练样本无法支撑分类器训练。

检测到故障后,需要利用故障分离的手段将实际故障变量分离,诊断出故障的根本原因。贡献图(Contribution Plots, CP)方法是通过确定每个变量对故障检测指标的贡献来进行故障分离的主要工具。但是,它容易受到的“残差污染”的影响而导致误诊,特别是对于涉及多个变量^[4]的复杂故障。Alcala 等人^[16]提出了一种基于重构的(Reconstruction-based Approach, RB)方法,通过理论证明可以保证一维缺陷变量具有最大的重构贡献,并扩展到多个故障变量以处理更复杂的故障。但在实际应用中,在故障分离之前往往没有检测到的故障的先验知识,所以重构方法必须进行详尽的搜索,通过大量的计算从可能的变量集中选择真正的故障变量。

针对上述问题,本文提出了一种基于并行重构堆叠自编码(Parallel Reconstruction-based Stacked Autoencoder, PRB-SAE)的非线性系统故障诊断方法。该方法在常规堆叠自编码器基础上引入了预设故障方向,采用梯度下降方法在所有可能的预设故障方向上进行数据重构,将最佳重构偏差对应的故障方向作为最终的故障点。进一步利用并行重构方法提高数据重构效率,减少计算时间。分析了堆叠

自编码网络结构对模型精度和诊断结果的影响关系,给出了系统建模和故障诊断的具体流程,以数值仿真系统和实际工程实例为对象进行算例分析,以验证所提方法的有效性。

1 堆叠自编码器

1.1 自编码器

自编码(Autoencoder, AE)是一种基于神经网络的无监督学习方法,该方法由编码器和解码器组成。其中,编码器将输入信号映射到隐藏层中的低维非线性特征,解码器则将低维特征映射到输出层,实现对输入信号的降噪与重构。如图1所示, $\mathbf{x} \in \mathbb{R}^n$ 为自编码网络的输入层变量, \mathbf{h} 和 $\hat{\mathbf{x}}$ 分别为隐藏层变量和输出层变量,其中输入层和输出层的节点数相同,隐藏层节点数小于输入层和输出层节点数。

在编码过程中,数据信号通过输入层和隐藏层实现数据降维,隐藏层变量可以表示为:

$$\mathbf{h} = g(\mathbf{W}\mathbf{x} + \mathbf{b}) \quad (1)$$

式中: \mathbf{W} — $n \times r$ 的权重矩阵; \mathbf{b} —偏置向量; g —隐藏层的激活函数,通常采用S型函数,如Sigmoid函数和tanh函数等。

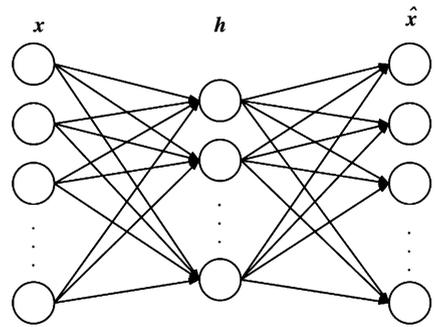


图1 自编码结构示意图

Fig. 1 Structure diagram of AE

解码器进一步将隐藏层的低维数据重构到输出层,输出层变量可以表示为:

$$\hat{\mathbf{x}} = \hat{g}(\hat{\mathbf{W}}\mathbf{h} + \hat{\mathbf{b}}) \quad (2)$$

式中: \hat{g} —输出层的激活函数, $\hat{\mathbf{W}}$ — $r \times m$ 的权值矩阵; $\hat{\mathbf{b}}$ —输出层偏置向量。

自编码器的参数集可表示为 $\theta = \{\mathbf{W}, \hat{\mathbf{W}}, \mathbf{b}, \hat{\mathbf{b}}\}$ 。自编码的训练过程是网络参数的寻优过程,其训练目标是实现模型输入与输出的总体误差值最小。对于训练样本集 $\mathbf{x}_i \in \{\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_N\}$,其训练目标

函数可以表示为:

$$J\{\mathbf{W}, \hat{\mathbf{W}}, \mathbf{b}, \hat{\mathbf{b}}\} = \frac{1}{2N} \sum_{i=1}^N \|\hat{\mathbf{x}}_i - \mathbf{x}_i\|^2 = \frac{1}{2N} \sum_{i=1}^N \|\mathbf{g}_\theta(\mathbf{x}_i) - \mathbf{x}_i\|^2 \quad (3)$$

式中: \mathbf{x}_i — 训练样本; N — 样本数; $\mathbf{g}_\theta(\cdot)$ — 自编码函数。

1.2 堆叠自编码器

堆叠自编码^[17] (Stacked Autoencoder, SAE) 由多个自编码模型堆叠组成, 图 2 为 SAE 的结构示意图。

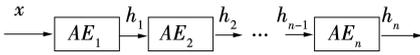


图 2 堆叠自编码器结构示意图

Fig.2 Structure diagram of SAE

SAE 的模型训练过程为:

(1) \mathbf{x} 作为第 1 个编码器 AE_1 的输入数据, 通过训练得到 AE_1 的网络参数 $\{\mathbf{W}_1, \mathbf{b}_1\}$ 和隐藏层低维特征 \mathbf{h}_1 。

(2) 将 \mathbf{h}_1 作为第 2 个编码器 AE_2 的输入数据, 通过训练得到 AE_2 的网络参数 $\{\mathbf{W}_2, \mathbf{b}_2\}$ 及其低维特征 \mathbf{h}_2 。

(3) 以此类推, 直到获得最后一个自编码 AE_k 的网络参数 $\{\mathbf{W}_k, \mathbf{b}_k\}$ 和低维特征 \mathbf{h}_k 。

与自编码器相比, 堆叠自编码具有更加强大的非线性表达能力和降维能力, 其逐层预训练的方式可以避免网络深度增加带来的梯度消散问题。

2 基于并行重构堆叠自编码的故障诊断方法

2.1 故障描述

对于 n 维系统, 定义 $\mathbf{P} = \{v_1, v_2, \dots, v_n\}$ 为所有 n 个参数的集合, $\mathbf{V}_a \in \mathbf{P}$ 为故障参数集合, 假设故障参数的个数为 d 。处于故障状态的样本 \mathbf{x} 可以表示为:

$$\mathbf{x} = \mathbf{x}^* + \Xi_{V_a} f_{V_a} \quad (4)$$

式中: Ξ_{V_a} — 故障方向; f_{V_a} — 故障幅值向量; \mathbf{x} — 测量值, \mathbf{x}^* — \mathbf{x} 对应的正常值。

若故障样本涉及单个变量, 则 Ξ_{V_a} 为列向量, 而当故障样本涉及多个变量, Ξ_{V_a} 则为矩阵。例如, 当故障样本涉及第 2 个变量时, 其故障方向可表示为

$\Xi_{\{v_2\}} = [010 \dots 0]^T$, 对应故障幅值即为 $\mathbf{f}_{\{v_2\}} = [f_2]$; 当故障样本同时涉及第 1 个和第 4 个变量时, 其故障方向可表示为 $\Xi_{\{v_1, v_4\}} = \begin{bmatrix} 10000 \dots \\ 00010 \dots \end{bmatrix}^T$, 对应故障幅值即为 $\mathbf{f}_{\{v_1, v_4\}} = [f_1 f_4]^T$ 。

2.2 基于 SPE 指标的故障检测

采用堆叠自编码进行故障诊断的第 1 步通常是利用 1 个或 1 组指标来监测故障是否发生, 采用平方预测误差 (Square Prediction Error, SPE) 来判断监测系统是否发生故障, 计算式为:

$$SPE(\mathbf{x}) = \|\mathbf{x} - \hat{\mathbf{x}}\| = \|\tilde{\mathbf{x}}\| \leq \delta_\alpha^2 \quad (5)$$

式中: $\hat{\mathbf{x}}$ — \mathbf{x} 的预测值; $\tilde{\mathbf{x}}$ — \mathbf{x} 的残差值; δ_α^2 — 置信水平为 α 时的控制限。

当 SPE 指标位于控制限以内时, 认为系统是正常的, 反之则认为系统偏离了正常运行状态, 控制限 δ_α^2 的计算式为:

$$\delta_\alpha^2 = \theta_1 \left(1 - \frac{\theta_2 h_0 (1 - h_0)}{\theta_1^2} + \frac{z_\alpha \sqrt{2 \theta_2 h_0^2}}{\theta_1} \right)^{\frac{1}{h_0}} \quad (6)$$

式中: $h_0 = 1 - \frac{2 \theta_1 \theta_3}{3 \theta_2^2}$, $\theta_i = \sum_{k=1}^m \lambda_k^i$, z_α 为 $(1 - \alpha)\%$ 置信域对应的标准分数, λ_k 是训练样本残差空间协方差矩阵的特征向量^[18]。

2.3 重构指标计算方法

SPE 指标虽然可以检测出样本是否出现故障, 但无法给出确切的故障方向和故障幅值。因此, 采用基于重构的故障分离诊断方法。根据式 (4) 可知, 故障样本对应的正常值 \mathbf{z} 可以表示为:

$$\mathbf{z} = \mathbf{x} - \Xi_{V_a} f_{V_a} \quad (7)$$

设 $\hat{\mathbf{z}}$ 为 \mathbf{z} 的模型重构值, 则:

$$SPE(\mathbf{z}) = \|\mathbf{z} - \hat{\mathbf{z}}\| = (\mathbf{z} - \hat{\mathbf{z}})^T (\mathbf{z} - \hat{\mathbf{z}}) \quad (8)$$

若预设的故障方向 Ξ_{V_a} 为实际故障方向, 则在预设故障方向下, 对故障幅值 f_{V_a} 进行优化求解获取最优值, 使 $SPE(\mathbf{x} | f_{V_a}) < \delta_\alpha^2$ 。从而在该故障方向, 监测所得的故障数据可以被恢复到正常状态; 反之, 若所获最优故障赋值 f_{V_a} 对应的 $SPE(\mathbf{x} | f_{V_a}) > \delta_\alpha^2$, 则预设故障方向不正确。

2.4 基于并行重构的故障分离方法

对于 n 维系统, 有 d 个变量发生故障, 故障方向

从假设故障变量个数为 1 时开始重构,则需要重构

$\sum_{i=1}^d C_n^i$ 次,当系统维度 n 和故障变量个数 d 增大时,重构次数将会呈指数倍递增。为了提高重构效率,每次对 1 组预设故障方向进行重构以求解最优故障幅值,重构表达式为:

$$\mathbf{Z} = \mathbf{X} - \mathbf{V} \odot \mathbf{F} \quad (9)$$

式中: $\mathbf{X} = [\mathbf{x} \ \mathbf{x} \cdots \mathbf{x}]$ —原始故障样本组; $\mathbf{V} = [\Xi_{v_1} \ \Xi_{v_2} \cdots \Xi_{v_a}]$ —预设的故障方向组; $\mathbf{F} = [f_{v_1} \ f_{v_2} \cdots f_{v_a}]$ —故障方向组所对应的故障幅值组。

对于给定的 1 组故障方向,最小综合 SPE 目标函数为:

$$\Theta = \min \text{SPE}(\mathbf{Z}) \quad (10)$$

定义 $\hat{\mathbf{Z}}$ 为 \mathbf{Z} 的模型输出值,则:

$$\text{SPE}(\mathbf{Z}) = \|\mathbf{Z} - \hat{\mathbf{Z}}\| = E(\mathbf{Z} - \hat{\mathbf{Z}})^2 \quad (11)$$

将式(9)和式(10)代入式(11),得目标函数为:

$$\Theta = \min E(\mathbf{X} - \mathbf{V} \odot \mathbf{F} - \hat{\mathbf{Z}})^2 \quad (12)$$

采用梯度下降对 Θ 进行寻优,从而获取最优故障幅值 \mathbf{F}^* 。综合 SPE 指标对故障幅值的偏导方程为:

$$\frac{\partial \text{SPE}(\mathbf{Z})}{\partial \mathbf{F}} = -\frac{1}{2} \left(\mathbf{V} + \frac{\partial \hat{\mathbf{Z}}}{\partial \mathbf{F}} \right) \quad (13)$$

根据链式求导法则,可得为:

$$\frac{\partial \hat{\mathbf{Z}}}{\partial \mathbf{F}} = \mathbf{V} \prod_k \mathbf{W}_k \sigma(\mathbf{W}_k \mathbf{h}_k + \mathbf{b}_k) [1 - \sigma(\mathbf{W}_k \mathbf{h}_k + \mathbf{b}_k)] \quad (14)$$

式中: k —堆叠自编码对应层级编号; \mathbf{h}_k —堆叠自编码第 k 层的输入; \mathbf{W}_k —第 k 层的权重; \mathbf{b}_k —第 k 层的偏置; $\sigma(\cdot)$ —Sigmoid 激活函数。

定义学习率为 η ,则对 \mathbf{F} 进行梯度下降寻优时,每次更新值为:

$$\Delta \mathbf{F} = -\eta \frac{\partial \text{SPE}(\mathbf{Z})}{\partial \mathbf{F}} \quad (15)$$

将优化所得的最优故障幅值组 \mathbf{F}^* 计算 SPE 指标:

$$\text{SPE}(\mathbf{Z} | \mathbf{F}^*) = [\text{SPE}(z_{v_1}) \text{SPE}(z_{v_2}) \cdots \text{SPE}(z_{v_a})] \quad (16)$$

SPE(z_{v_a}) 计算式为:

$$\begin{aligned} \text{SPE}(z_{v_a}) &= \|z_{v_a} - \hat{z}_{v_a}\| = (z_{v_a} - \hat{z}_{v_a})^T (z_{v_a} - \hat{z}_{v_a}) \\ \hat{z}_{v_a} &= (\mathbf{x} - \Xi_{v_a} \mathbf{f}_{v_a} - \hat{z}_{v_a})^T (\mathbf{x} - \Xi_{v_a} \mathbf{f}_{v_a} - \hat{z}_{v_a}) \end{aligned} \quad (17)$$

若存在 $\text{SPE}(z_{v_a}) < \delta_\alpha^2$,则对应的故障方向 Ξ_{v_a} 和故障幅值 f_{v_a} 即为实际的故障方向与幅值。反之则选取下一组故障方向进行重构优化求解。

2.5 算法结构

PRB-SAE 故障诊断方法,首先采用原始正常数据对堆叠自编码器进行模型训练,建立符合系统正常运行状态的堆叠自编码模型,并获得 SPE 指标控制限。当运行数据的 SPE 指标超过控制限时,则认为当前状态偏离正常工况,需要进行故障分离。基于 PRB-SAE 方法的具体故障诊断流程为:

步骤 1:构建堆叠自编码器,将 n 维原始正常数据集作为训练样本,对堆叠自编码器进行逐层模型训练以获得相关参数。通过式(6)计算得到 SPE 指标控制限 δ_α^2 。

步骤 2:利用式(5)计算实时运行数据的 SPE 指标。当 $\text{SPE}(z) < \delta_\alpha^2$ 时,表示系统当前运行状态出现故障。初始化故障方向维度为 $d = 1$,执行步骤 3。

步骤 3:生成 C_n^d 个故障方向合为 1 组 $\mathbf{V} = [\Xi_{v_1} \ \Xi_{v_2} \cdots \Xi_{v_a}]$,根据式(15)计算最优故障幅值 \mathbf{F}^* 。

步骤 4:将最优故障幅值代入式(16)计算得到 $\text{SPE}(\mathbf{Z} | \mathbf{F}^*) = [\text{SPE}(z_{v_1}) \text{SPE}(z_{v_2}) \cdots \text{SPE}(z_{v_a})]$,若存在 $\text{SPE}(z_{v_a}) < \delta_\alpha^2$,则对应 Ξ_{v_a} 和 f_{v_a} 为实际故障方向和幅值;否则更新 $d = d + 1$,返回步骤 3。

3 算例分析

3.1 数值系统

利用式(18)构建 10 维非线性数值系统:

$$\begin{cases} x_1 = u_1 + e_1 \\ x_2 = u_1^2 - 3u_1 + e_2 \\ x_3 = -u_1^4 + 3u_1^2 + e_3 \\ x_4 = u_1^4 - 4u_1^3 + 2u_1 + e_4 \\ x_5 = -2u_1^5 + 6u_1^4 - 3u_1^3 + u_1 + e_5 \\ x_6 = u_2 + e_6 \\ x_7 = u_2^2 - 3u_2 + e_7 \\ x_8 = -u_2^4 + 3u_2^2 + e_8 \\ x_9 = u_2^4 - 4u_2^3 + 2u_2 + e_9 \\ x_{10} = -2u_2^5 + 6u_2^4 - 3u_2^3 + u_2 + e_{10} \end{cases} \quad (18)$$

式中: u_1, u_2 一服从 $[-1, 1]$ 均匀分布的独立变量; $e_1 \sim e_{10}$ 一服从高斯分布的独立噪声, 平均值为 0, 方差为 0.01。

3.1.1 系统建模

由式 (18) 生成 9 000 个样本并进行归一化处理, 随机选取 3 000 个样本用于模型训练, 其余 6 000 个样本用于测试。建立不同网络结构的堆叠自编码模型, 训练并测试后得到均方根误差 (RMSE) 和相关系数 (R^2), 对比结果如图 3 和图 4 所示。RMSE 和 R^2 的计算式分别为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \frac{1}{n} \sum_{i=1}^n \hat{x}_i)^2} \quad (20)$$

可见, 当隐藏层维度相同时, 随着网络层数增加, R^2 逐渐增加, RMSE 逐渐减小, 模型的学习能力随之提高, 能够更好地提取系统参数之间的相关性。7 层网络结构的自编码模型性能在隐藏层维度为 2 时已达到最优值, 继续增加隐藏层维度模型性能相近, 其性能明显优于 3 层与 5 层网络。因此, 深度网络相比浅层网络拥有更强的特征提取能力。

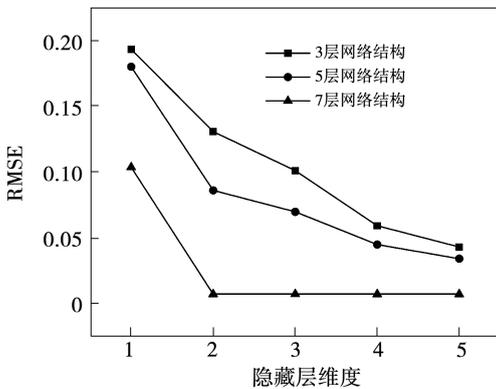


图 3 各模型 RMSE 对比

Fig. 3 Comparison chart of RMSE results of different models

3.1.2 故障数据仿真

采用蒙特卡洛方法分别生成 3 组故障测试集, 3 组测试集包含 1 000 个故障样本, 具体流程为:

(1) 初始化故障参数个数 $d = 1$, 表示将在该样本中 d 个变量上施加故障幅值。

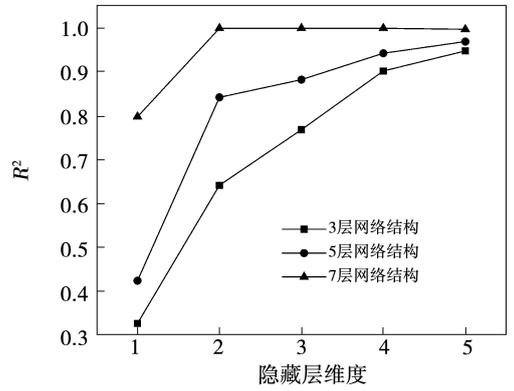


图 4 各模型 R^2 对比

Fig. 4 Comparison chart of R^2 results of different models

(2) 从 6 000 个测试样本中随机选取 1 000 个样本, 初始化样本编号 $l = 1$ 。

(3) 获取正常测试样本中的第 l 组样本 $\mathbf{x}_{nor,l}$ 。

(4) 在 $[1, 10]$ 区间内生成 d 个随机整数 $l = \{i\}$, 在 $[0, 5]$ 区间内生成 d 个随机数 $f' = \{f'_i\}$ 。在测试样本 $\mathbf{x}_{nor,l}$ 的第 i 个变量上施加大小为 f'_i 的偏差值, 得到第 l 组故障测试样本。

(5) 若 $l \leq 1000$, 更新 $l = l + 1$, 返回步骤 (3), 否则结束生成故障样本, 获得 1 组包含 1 000 个故障测试样本集 \mathbf{X}_d 。

(6) 若 $d \leq 3$, 更新 $d = d + 1$, 返回步骤 (2), 直至获得单参数 \mathbf{X}_1 、双参数 \mathbf{X}_2 和三参数 \mathbf{X}_3 共 3 组故障样本集后结束进程。

3.1.3 诊断准确性分析

采用式 (21) 和式 (22) 计算出的故障诊出率 β_{FDR} 与故障误诊率 β_{FAR} 两个指标, 对 SAE 与 PRB-SAE 方法的诊断准确性进行对比分析。

$$\beta_{FDR} = \frac{1}{n} \sum_{j=1}^n o_j / r_j \times 100\% \quad (21)$$

$$\beta_{FAR} = \frac{1}{n} \sum_{j=1}^n p_j / (m - r_j) \times 100\% \quad (22)$$

式中: r_j —第 j 个测试样本涉及的故障参数个数; o_j —第 j 个测试样本实际被诊出的故障参数个数; p_j —第 j 个测试样本被误诊的参数个数。

图 5 和图 6 为不同网络结构下 SAE 和 PRB-SAE 两种方法对单参数故障样本集 \mathbf{X}_1 进行故障诊断得到的平均诊出率和平均误诊率。随着网络层数的增加, SAE 与 PRB-SAE 的诊出率均增加, 其主要

原因在于网络深度的增加可以提升模型精度,从而降低故障检测阈值,对微小故障也就更加敏感。相同网络结构下,虽然 SAE 的诊出率略高于 PRB-SAE,但 SAE 的误诊率却远高于 PRB-SAE。因此,综合考虑诊出率与误诊率两个指标,本文方法的诊断效果要优于常规 SAE 故障诊断方法。

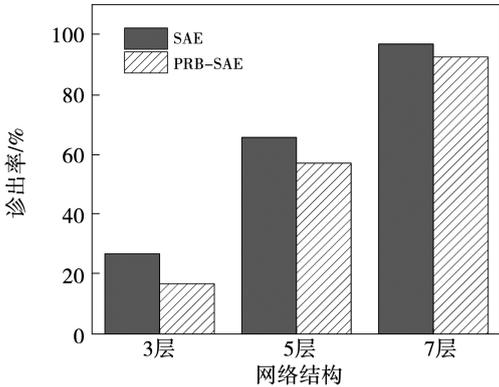


图5 各模型平均故障诊出率

Fig. 5 Average failure diagnosis rate of each model

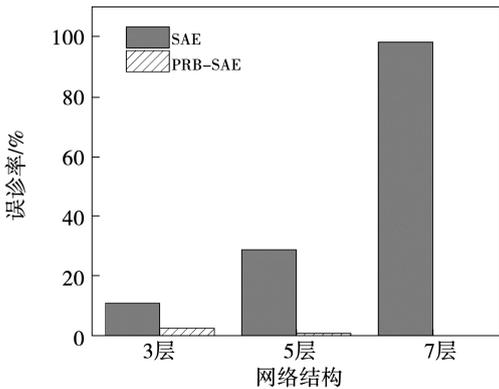


图6 各模型平均故障误诊率

Fig. 6 Average false alarm rate of each model

3.1.4 诊断耗时分析

为了进一步验证 PRB-SAE 在诊断速率上的优势,本文采用 PRB-SAE 和基于重构的堆叠自编码方法^[19] (Reconstruction-based Stacked Autoencoder, RB-SAE)对单参数 X_1 、双参数 X_2 和三参数 X_3 组故障测试样本集进行诊断分析,记录单例故障样本的平均诊断耗时,结果如图 7 所示。可见,随着故障参数的增加,PRB-SAE 平均单例故障样本的诊断耗时随着故障参数个数呈线性上升趋势,而 RB-SAE 方法则呈指数型快速增加。因此,PRB-SAE 方法的诊断速率明显优于 RB-SAE 方法。

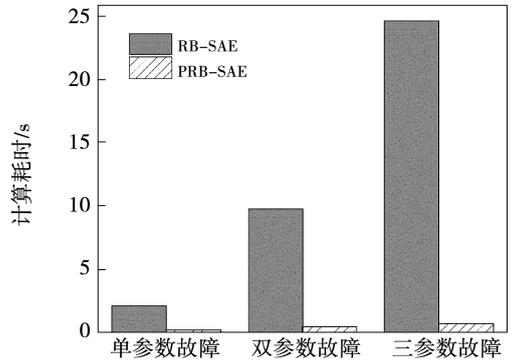


图7 各模型平均计算耗时

Fig. 7 Average diagnosis rate of each model

3.2 工程算例

为验证 PRB-SAE 方法在实际工程应用中的有效性,以某电厂第 1 排空冷风机群为对象进行算例分析,模型参数如表 1 所示。

表1 某电厂第 1 排空冷风机群建模参数详情

Tab. 1 Information of modeling parameters of 1st exhaust air cooler group of a power plant

序号	参数	最大值	最小值	平均值
1	1 排 1 风机齿轮箱温度/℃	64.2	29.14	49.89
2	1 排 1 风机电机电流/A	221.6	85.82	158.34
3	1 排 1 风机转速/r · min ⁻¹	1 109	462.12	963
4	1 排 2 风机齿轮箱温度/℃	70.78	43.95	59.97
5	1 排 2 风机电机电流/A	221.4	83.06	154.22
6	1 排 2 风机转速/r · min ⁻¹	1 105	457	957
7	1 排 3 风机齿轮箱温度/℃	75.06	46.26	64.77
8	1 排 3 风机电机电流/A	221.43	86.91	158.14
9	1 排 3 风机转速/r · min ⁻¹	1 109	454	960
10	1 排 4 风机齿轮箱温度/℃	59.44	29.85	46.94
11	1 排 4 风机电机电流/A	206.45	81.09	149.17
12	1 排 4 风机转速/r · min ⁻¹	1 099	450	950
13	1 排 5 风机齿轮箱温度/℃	68.89	41.35	57.92
14	1 排 5 风机电机电流/A	220.18	85.67	156.13
15	1 排 5 风机转速/r · min ⁻¹	1 130	476	978
16	1 排 6 风机齿轮箱温度/℃	72.05	44.14	61.73
17	1 排 6 风机电机电流/A	217.73	85.26	156.37
18	1 排 6 风机转速/r · min ⁻¹	1 106	455	955
19	1 排 7 风机齿轮箱温度/℃	73.45	44.82	63.65
20	1 排 7 风机电机电流/A	233.15	84.08	155.42
21	1 排 7 风机转速/r · min ⁻¹	1 123	474	977
22	1 排抽真空管道温度/℃	63.18	24.17	45.22
23	1 排凝结水管道温度/℃	64.18	36.54	47.20
24	风向/(°)	365	0	233.62
25	风速/m · s ⁻¹	5.04	0	0.19

从 SIS 系统中采集 7 天的运行数据, 取样间隔为 300 s, 共获取 3 259 个有效样本。对其进行归一化处理, 随机选取 2 000 个有效样本作为训练样本, 其余样本作为测试样本。

设立 4 个实验组, 分别采用 PRB-SAE、SAE、基于重构的主成分分析法^[20] (Reconstruction-based Principal Component Analysis, RB-PCA) 和主成分分析法^[4] (Principal Component Analysis, PCA), 对单参

数故障与双参数故障进行诊断分析。由于在实际生产中, 风机故障一般仅为风机齿轮箱温度异常、风机电流异常以及风机转速异常, 因此仅对这 3 类参数进行随机选择并添加 0 ~ 10 范围内的故障幅值, 生成 2 组故障样本测试集: 单参数故障, 故障参数为 3 类参数中任一参数; 双参数故障, 从上述 3 类参数中随机选取 2 个参数为作为故障参数。不同故障范围下, 单、双参数故障诊断结果比较如表 2、表 3 所示。

表 2 不同故障范围下, PRB-SAE、SAE、RB-PCA 和 PCA 的单参数故障诊断结果比较 (%)

Tab. 2 A comparison result between PRB-SAE, SAE, RB-PCA and PCA for single variable faults under different fault ranges (%)

故障幅值范围	PRB-SAE		SAE		RB-PCA		PCA	
	诊出率	误诊率	诊出率	误诊率	诊出率	误诊率	诊出率	误诊率
0 ~ 0.1	0.20	0.18	1.53	0.60	0.3	0.13	0.3	0.11
0.1 ~ 0.2	9.20	0.28	11.17	1.89	0.2	0.10	0.1	0.06
0.2 ~ 0.3	71.3	0.33	73.54	8.89	2.6	0.2	1.8	0.10
0.3 ~ 0.4	99.4	0.17	96.96	14.35	5.2	0.27	4.2	0.11
0.4 ~ 0.5	100	0.16	97.36	18.61	15.7	0.2	3.8	0.10
0.5 ~ 0.6	100	0.16	98.37	23.59	57.9	0.14	17.3	0.09
0.6 ~ 0.7	100	0.16	98.07	28.82	93.4	0.12	70.1	0.11
0.7 ~ 0.8	100	0.15	98.07	33.47	98.4	0.15	88	0.12
0.8 ~ 0.9	100	0.16	98.43	38.48	99.2	0.08	98.2	0.05
0.9 ~ 1.0	100	0.16	99.26	41.98	99.2	0.1	99	0.09
1.0 ~ 2.0	100	0.16	99.94	56.31	100	0.1	99.8	0.25
2.0 ~ 3.0	100	0.14	100	73.11	100	0.13	100	1.2
3.0 ~ 5.0	100	0.16	100	82.49	100	0.13	100	3.39
5.0 ~ 10.0	100	0.15	100	86.29	100	0.13	100	23.32

表 3 不同故障范围下, PRB-SAE、SAE、RB-PCA 和 PCA 的双参数故障诊断结果比较 (%)

Tab. 3 A comparison result between PRB-SAE, SAE, RB-PCA and PCA for double variables faults under different fault ranges (%)

故障幅值范围	PRB-SAE		SAE		RB-PCA		PCA	
	诊出率	误诊率	诊出率	误诊率	诊出率	误诊率	诊出率	误诊率
0 ~ 0.1	0.78	0.19	2.08	0.71	0	0.11	0	0.08
0.1 ~ 0.2	19.31	0.49	40.99	5.71	0.46	0.14	0.20	0.08
0.2 ~ 0.3	77.04	0.19	96.67	16.62	3.25	0.18	0.46	0.08
0.3 ~ 0.4	99.74	0.16	98.55	24.54	12.48	0.40	3.67	0.12
0.4 ~ 0.5	100	0.14	98.87	32.45	46.80	0.27	4.17	0.10
0.5 ~ 0.6	100	0.14	99.22	39.96	66.70	0.16	14.10	0.11
0.6 ~ 0.7	100	0.16	99.19	46.28	92.04	0.16	59.05	0.12
0.7 ~ 0.8	100	0.15	98.74	52.04	98.68	0.14	82.02	0.12
0.8 ~ 0.9	100	0.14	98.98	56.05	99.08	0.13	91.31	0.09
0.9 ~ 1.0	100	0.17	99.77	58.98	99.24	0.10	97.61	0.08
1.0 ~ 2.0	100	0.16	100	71.79	99.90	0.11	99.49	0.48
2.0 ~ 3.0	100	0.14	100	82.04	100	0.12	99.90	3.47
3.0 ~ 5.0	100	0.15	100	86.45	100	0.14	100	14.78
5.0 ~ 10.0	100	0.14	100	89.29	100	0.08	100	45.37

从诊出率角度分析,4种诊断方法的诊出率均随故障幅值增加而上升。值得注意的是,对于故障幅值0.5以下的微小故障,RB-PCA和PCA两种方法的诊出率都不高,始终维持在50%以下。对比之下,PRB-SAE和SAE的诊出率明显高于前两者,当故障幅值大于0.3时,对应诊出率已接近100%,其原因在于SAE模型能很好地表示系统参数间的非线性关系,残差控制限也低于PCA模型。

从误诊率角度分析,对于施加了5以上故障幅值的故障样本,PCA方法的误诊率急剧上升,而RB-PCA的误诊率始终保持在较小的水平。同样,SAE误诊率随着故障幅值的增加明显上升,而RB-SAE则始终表现良好,无论是对于微小故障还是对于显著故障,其误诊率始终保持在0.5%以内。这是因为SAE和PCA存在残差污染问题,随着故障幅值的增加,残差污染所带来的负面影响也增加,从而导致误诊率显著增加。而PRB-SAE和RB-PCA能有效抑制残差污染,这使得误诊率不会随故障幅值增加而上升。

对比表2和表3的结果,SAE方法对双参数故障的误诊率因为受到残差污染的负面影响,相比于单参数故障出现了明显的增加。同样,对于施加了1以上故障幅值的故障样本,PCA对双参数故障的误诊率相较单参数故障也有明显的上升。而PRB-SAE和RB-PCA则很好地抑制了残差污染,对于多故障样本的误诊率始终小于0.5%。此外,对于双参数故障,RB-PCA的诊出率相较于单参数故障出现了较为明显的下降,而PRB-SAE始终保持着高诊出率,当故障幅值大于0.3时,对应诊出率接近100%。

综合考虑诊出率与误诊率两个指标,本文所提的PRB-SAE方法具有对于微小故障敏感、有效抑制残差污染和降低误诊率的同时保持较高诊出率的优点。

4 结 论

(1) 提出了基于PRB-SAE的故障方法,在常规堆叠自编码器的基础上引入了预设故障方向,对比分析不同预设故障方向下的重构偏差定位故障源。

数学仿真算例结果表明,该方法能够有效抑制残差污染,有效降低误诊率。

(2) 分析了不同网络结构对堆叠自编码模型精度和诊断效果的影响关系。结果表明,相比于浅层神经网络,深度的堆叠自编码具有较高的模型精度与更优的诊断效果。

(3) 建立了基于PRB-SAE的空冷风机群故障诊断模型,进行了仿真故障分析。结果表明,本文方法对于单参数简单故障和多参数复杂故障都有很好的诊断效果。

参考文献:

- [1] QIN S J. Survey on data-driven industrial process monitoring and diagnosis [J]. Annual Reviews in Control, 2012, 36 (2): 220 - 234.
- [2] GE Zhi-qiang, SONG Zhi-huan, GAO Fu-rong. Review of recent research on data-based process monitoring [J]. Industrial & Engineering Chemistry Research, 2013, 52(10): 3543 - 3562.
- [3] YIN Shen, DING S X, HAGHANI A, et al. A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark Tennessee Eastman process [J]. Journal of Process Control, 2012, 22(9): 1567 - 1581.
- [4] QIN S J. Statistical process monitoring: basics and beyond [J]. Journal of Chemometrics: A Journal of the Chemometrics Society, 2003, 17(8-9): 480 - 502.
- [5] BAKSHIB R. Multiscale PCA with application to multivariate statistical process monitoring [J]. AIChE Journal, 1998, 44 (7): 1596 - 1610.
- [6] WESTERHUIS J A, GURDEN S P, SMLDE A K. Generalized contribution plots in multivariate statistical process monitoring [J]. Chemometrics and Intelligent Laboratory Systems, 2000, 51 (1): 95 - 114.
- [7] BALDI S, QUANG T L, HOLUB O, et al. Real-time monitoring energy efficiency and performance degradation of condensing boilers [J]. Energy Conversion and Management, 2017, 136: 329 - 339.
- [8] 李欢欢, 司风琪, 徐治泉. 一种基于鲁棒自联想神经网络的传感器故障诊断方法 [J]. 中国电机工程学报, 2012, 32 (14): 116 - 121.
- [9] LI Huan-huan, SI Feng-qi, XU Zhi-gao. A sensor fault diagnosis method based on robust auto-associative neural network [J]. Proceedings of the CSEE, 2012, 32(14): 116 - 121.
- [9] SALAHSHOOR K, KORDESTANI M, KHOSHRO M S. Fault detection and diagnosis of an industrial steam turbine using fusion of SVM (support vector machine) and ANFIS (adaptive neuro-fuzzy

- inference system) classifiers [J]. *Energy*, 2010, 35 (12): 5472 - 5482.
- [10] 刘永斌,何清波,孔凡让,等. 基于 PCA 和 SVM 的内燃机故障诊断[J]. *振动. 测试与诊断*, 2012, 32(2): 250 - 255.
LIU Yong-bin, HE Qing-bo, KONG Fan-rang, et al. Fault diagnosis of internal combustion engine using PCA and SVM [J]. *Journal of Vibration, Measurement & Diagnosis*, 2012, 32 (2): 250 - 255.
- [11] HAN Hui, HAO Li-na, CHENG De-quan, et al. GAN-SAE based fault diagnosis method for electrically driven feed pumps [J]. *PLoS One*, 2020, 15(10): e0239070.
- [12] LYU Fei-ya, WEN Cheng-lin, BAO Ze-jing, et al. Fault diagnosis based on deep learning [C]//American Control Conference (ACC). IEEE, 2016.
- [13] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18 (7): 1527 - 1554.
- [14] ZHANG Ze-han, JIANG Teng, ZHAN Cheng-jun, et al. Gaussian feature learning based on variational autoencoder for improving nonlinear process monitoring [J]. *Journal of Process Control*, 2019, 75: 136 - 155.
- [15] LI Jiang, GE Zhi-qiang, SONG Zhi-huan. Semi-supervised fault classification based on dynamic sparse stacked auto-encoders model [J]. *Chemometrics and Intelligent Laboratory Systems*, 2017, 168: 72 - 83.
- [16] ALCALA C F, QIN S J. Reconstruction-based contribution for process monitoring [J]. *Automatica*, 2009, 45(7): 1593 - 1600.
- [17] LAROCHELLE H, BENGIO Y, LOURADOUR J, et al. Exploring strategies for training deep neural networks [J]. *Journal of Machine Learning Research*, 2009, 1(10): 1 - 40.
- [18] NOMIKOS P, MACGREGOR J F. Multivariate SPC charts for batch processes [J]. *Technometrics*, 1995, 37(1): 41 - 59.
- [19] REN Shao-jun, SI Fen-qi, ZHOU Jian-xin, et al. A new reconstruction-based auto-associative neural network for fault diagnosis in nonlinear systems [J]. *Chemometrics and Intelligent Laboratory Systems*, 2018, 172: 118 - 128.
- [20] MNASSRI B, ADEL E E, OULADSINE M. Reconstruction-based contribution approaches for improved fault diagnosis using principal component analysis [J]. *Journal of Process Control*, 2015, 33: 60 - 76.

(丛敏编辑)