

软阈值时序卷积网络在冷水机组传感器故障诊断中的应用

洪琳, 李冬辉, 高龙, 赵墨刊

(天津大学电气自动化与信息工程学院, 300072, 天津)

摘要: 为了提高冷水机组传感器的故障诊断性能,提出了一种基于软阈值时序卷积网络的编码-解码器重构模型(ST-TCN),并建立基于该模型的传感器故障诊断方法。采用时序卷积网络(TCN)充分挖掘冷水机组传感器的时间相关性、热力学物理量间的数据相关性以及动态响应差异性特征。在 TCN 的残差块中引入软阈值自适应模块剔除冗余信息,降低噪声干扰。依托 ST-TCN 模型“端到端”的网络结构优势,将绝对重构残差向量与故障阈值向量进行比较,直接定位故障传感器。在实际压缩式冷水机组平台上采集传感器数据进行实验,结果表明,软阈值自适应模块能有效地增强网络模型的重构能力,从而提高故障传感器的诊断性能。以压缩机吸气温度传感器 T1 为例,ST-TCN 的平均偏差故障识别率比改进前提升了 45.9%;与其他故障诊断方法相比,所提的最新框架获得了较高的偏差故障识别率。

关键词: 时序卷积网络;编码-解码器;软阈值化;冷水机组;传感器故障诊断

中图分类号: TP277;TP306+.3 **文献标志码:** A

DOI: 10.7652/xjtuxb202302008 **文章编号:** 0253-987X(2023)02-0067-11

Application of Temporal Convolutional Network with Soft-Threshold Adaptive Module in Fault Diagnosis of Chiller Sensor

HONG Lin, LI Donghui, GAO Long, ZHAO Mogan

(School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China)

Abstract: In order to improve the capacity to identify the faults of air-cooled chiller sensor, an encoder-decoder reconstruction model based on temporal convolutional network (TCN) with a soft-threshold adaptive module (ST-TCN) is proposed, and an ST-TCN-based method for sensor fault diagnosis is established. In this method, TCN is used to fully explore the temporal correlation of the chiller sensors, the data correlation among the physical quantities, and the dynamic response characteristics of the physical quantities. In addition, a soft-threshold adaptive module is introduced into the residual module of TCN to eliminate redundant information and reduce noise interference. Relying on the advantage of the “end-to-end” network structure of the ST-TCN model, the fault sensor is directly located by comparing the absolute reconstruction error vector with the fault threshold vector. According to datasets collected from an actual air-cooled chiller platform, it is verified that the soft-threshold adaptive module will effectively improve the reconstruction performance of the network, thus facilitating diagnosis performance of faulty sensors.

收稿日期: 2022-04-19。 作者简介: 洪琳(1998—),女,硕士生;李冬辉(通信作者),男,教授。 基金项目: 国家自然科学基金资助项目(61873180)。

网络出版时间: 2022-09-22

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1069.T.20220921.1049.002.html>

Taking the compressor suction temperature sensor T1 as an example, compared with other fault diagnosis methods, ST-TCN improves the average fault identification accuracy by 45.9%. It shows that the latest framework proposed in this paper yields higher fault identification accuracy.

Keywords: temporal convolutional network; encoder-decoder; soft thresholding; air-cooled chiller; fault detection and diagnosis

建筑业作为高能耗行业,是节能减排的重点领域。其中,暖通空调(heating ventilating and air conditioning, HVAC)系统因低效运行造成的能源浪费占建筑总能耗的15%~30%^[1]。作为中央空调系统的重要组成部分,冷水机组是主要的耗能设备,及时排除冷水机组故障可有效降低20%~50%的能耗^[2],而传感器的正常工作是冷水机组稳定运行和实现优化控制的基础。因此,故障检测和诊断技术在冷水机组传感器中的应用对于降低系统维修成本和耗能、减少停机时间并提高运行效率至关重要^[3]。

故障检测与诊断技术已广泛应用于汽车、航空航天、过程控制、制造及国防等领域,主要分为数据驱动方法^[4-6]、知识规则方法^[7-8]和解析模型法^[9-10]。随着国家信息化水平不断提高,数据驱动方法在故障诊断领域展现出独特的优势。主元分析(principal components analysis, PCA)法通过降维获得独立特征,并用统计量来诊断故障源^[11]。为适合处理非线性和多模态问题, Schölkopf 等^[12]发展了核主成分分析(kernel principal components analysis, KPCA)法。陈乐瑞等^[13]利用 KPCA 法提取机器人用 RV 减速器非线性输出频率响应函数的频谱特征来实现减速器故障诊断。但是,核主元分析法对样本数据依赖性过大^[14-15],核函数参数的选取影响故障检测性能。为减少噪声的干扰, Mao 等^[16]提出了一种将经验模态分解(empirical mode decomposition, EMD)、阈值去噪(threshold denoising, TD)和 PCA 法相结合的冷水机组传感器故障检测策略(EMD-TD-PCA),提高了传统 PCA 法的故障检测准确率。

深度学习是机器学习领域的一种新兴方法,因其优异的特征自动提取能力被广泛应用于故障诊断领域。池福临等^[17]将深度残差收缩网络应用于滚动轴承故障诊断,在含噪声的数据中提取特征信息。李冬辉等^[18]对长短期记忆网络(long short-term memory, LSTM)的门结构进行改进,通过分类的方式实现对冷水机组传感器偏差故障的检测。Malhotra 等^[19]采用基于 LSTM 的编码-解码器模型(encoder-decoder network, EDN)分别对 4 个开

源时序数据集的多传感器异常情况进行检测。Li 等^[20]提出了基于数据-时间注意网络(data-temporal attention network, DAN)的诊断策略,通过比较重构残差来识别冷水机组故障传感器。Lai 等^[21]利用长、短期时间序列网络模型(long and short-term time-series network, LSTNet)提取具有相关性的多维时序数据中的特征。时序卷积网络(temporal convolutional network, TCN)在卷积结构中融入序列建模能力。Zhang 等^[22]提出了基于多尺度时序卷积网络(multiscale temporal convolutional network, MS-TCN)的新型故障诊断方法对工业过程中发生的故障进行诊断。Liu 等^[23]开发了基于双重注意力的时序卷积网络的新型深度模型,将多传感器数据与时变操作设置相结合,用于工业机器的健康评估。Meng 等^[24]提出了基于时序卷积网络自动编码器的检测框架,可以检测时间序列数据中的异常值。这些方法为提升工业过程故障诊断的准确率做出了有益尝试,但鲜有研究将这类方法应用于冷水机组传感器故障诊断任务。

为提高冷水机组传感器的偏差故障识别率,本文提出了基于改进 TCN 的重构模型(ST-TCN)以及基于该模型的传感器故障诊断方法。考虑到噪声对重构性能的影响,改进 TCN 在原始 TCN 的基础上引入软阈值自适应模块。以压缩式冷水机组为研究对象,通过实验与对比分析验证所提方法的有效性。

1 冷水机组运行机理分析

压缩式冷水机组是一个强耦合、惯性、时滞的非线性系统,其 4 个主要部件(压缩机、电子膨胀阀、蒸发器、冷凝器)之间通过能量传递和制冷剂流动共同协作又彼此联系,与 4 个主要部件相关的物理量之间的热力学耦合关系如图 1 所示。

以压缩机为例,蒸发器出口比焓 H_e 、蒸发压力 P_e 以及冷凝压力 P_{cd} 等物理量作为压缩机的输入,会对压缩机质量流量 m_{com} 、压缩机出口比焓 H_{com} 产生影响。反过来,质量流量 m_{com} 作为蒸发器的输入,连同电子膨胀阀出口比焓 H_v 和电子膨胀阀质量流量 m_v 等物理量间接影响着与压缩机有关的物理量。




图 1 压缩机冷水机组热力学物理量耦合关系示意图

Fig. 1 Schematic diagram of the thermodynamic coupling relationship of the compression chiller

由此,可得冷水机组传感器时序数据的特性如下。

(1)在制冷循环过程中,与 4 个主要部件相关的物理量存在热力学耦合关系。温度和压力类物理量通过表 1 所示的 11 个传感器监测得到,物理量之间呈现出的数据相关性由传感器实测值反映出来。

表 1 冷水机组传感器的符号描述

Table 1 Description corresponding to the chiller sensors

传感器	符号
压缩机吸气温度传感器	T1
压缩机排气温度传感器	T2
冷凝器出风温度传感器	T3
节流前温度传感器	T4
节流后温度传感器	T5
蒸发器进水口温度传感器	T6
蒸发器出水口温度传感器	T7
压缩机吸气压力传感器	P1
压缩机排气压力传感器	P2
节流前压力传感器	P3
节流后压力传感器	P4

(2)由于惯性不同,冷水机组物理量之间存在响应特性差异,温度类物理量的响应速度要慢于压力类物理量。因此,不同传感器之间的数据相关性可能表现在不同的测量时刻,即传感器时序数据存在延迟相关性。

(3)传感器与物理量之间存在一个缓慢建立平衡的过程,这主要与传感器自身动态响应特性有关,所以传感器的读数在时间上会表现出依存关系。

(4)测量物理量和采集数据等环节的随机因素导致冷水机组传感器实测数据常含有不同类型的噪声,对相关性特征的提取造成不利影响。

2 神经网络基础原理

2.1 时序卷积神经网络

具有时序数据处理能力的 TCN 利用卷积强大的特性,并行处理数据,跨时间步提取特征,在大量的序列建模任务中明显优于基线递归架构。TCN 由一维全卷积网络 (fully convolutional networks, FCN) 和因果卷积 (causal convolutions, CC) 组成^[25],其结构如图 2 所示。

(1)因果卷积。因果卷积由一维卷积组成,对于上一层 t 时刻的值,只依赖于下一层 t 时刻及其之前时刻的值,是一种严格的时间约束模型,适于挖掘时序数据的潜在特征。

(2)残差网络。在网络结构加深时,为避免梯度消失等问题的发生,TCN 构建残差块来代替卷积层,网络跨层传递信息,具有更强的泛化能力。每个残差块包含两个因果卷积和 ReLU 非线性激活函数,并对卷积核权重进行归一化以提高网络性能。此外,TCN 在残差块内添加了 Dropout 层以实现正




图 2 TCN 结构

Fig. 2 Schematic diagram of the TCN

则化,随机失活神经元。残差块的输入经恒等映射后与卷积特征图相加。当维度不同时,映射通路引入 1×1 的卷积计算(1×1 Conv)使二者维度一致。

(3)全卷积神经网络 FCN。与经典卷积神经网络不同,TCN 使用卷积层代替全连接层,对输出特征图进行上采样,使它恢复到与输入相同的尺寸。

2.2 软阈值化

软阈值化是信号降噪的常用方法。软阈值函数作为一种非线性变换,其表达式为

$$\text{Soft}(x, \tau) = \begin{cases} x + \tau, & x < -\tau \\ 0, & |x| \leq \tau \\ x - \tau, & x > \tau \end{cases} \quad (1)$$

软阈值函数将绝对值低于某个阈值的特征置为 0,其他特征也向 0 收缩。阈值直接影响着降噪的结果,如何选取合适的阈值至今 τ 仍是一个难题。利用深度学习网络自动确定阈值是该问题的解决方向之一^[26]。

3 传感器故障诊断模型及策略

建立以编码-解码器网络为基本框架的重构模型,将多变量传感器输入时序映射为准确的重构时序,开展传感器故障诊断研究。为充分挖掘冷水机组传感器数据中的相关性特征,本文从压缩式冷水机组的运行机理出发,提出基于软阈值自适应 TCN 作为编码-解码器重构模型的特征提取单元。

3.1 ST-TCN 重构模型

图 3 为 ST-TCN 重构模型的网络结构,包括输入层、载有软阈值自适应模块的双向 TCN 层和输出

层,每层描述如下。

(1)输入层。在冷水机组不同工况下,采集正常传感器时间序列,构成如式(2)所示的二维数据矩阵。标准化处理后作为模型的输入。

$$\mathbf{X}(n) = (\mathbf{x}_1^n, \dots, \mathbf{x}_t^n, \dots, \mathbf{x}_T^n) \in \mathbf{R}^{T \times M} \quad (2)$$

式中: T 为时间窗口长度; M 为传感器数; $\mathbf{x}_t^n$ 为第 t 个采样时刻的传感器时间序列,向量表示为

$$\mathbf{x}_t^n = (x_{t,1}^n, x_{t,2}^n, \dots, x_{t,M}^n)^T \in \mathbf{R}^M \quad (3)$$

(2)载有软阈值自适应模块的双向 TCN 层。冷水机组传感器的读数在正反两方向上会表现出时间依存关系。但是,具有单向结构的因果卷积仅从单一方向提取冷水机组传感器时序数据中所蕴含的特征,造成了时序特征学习不充分的问题。为了获得更多的信息,将因果卷积的单边补 0 方式改为对称补 0 方式,双向提取时序特征。

针对 ReLU 激活函数中输出值为负数的神经元一直处于抑制状态的问题,本研究采用谷歌提出的 Swish 激活函数来代替残差网络中的 ReLU 激活函数,其表达式为

$$f(x) = x \text{Sigmoid}(\beta x) \quad (4)$$

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

软阈值自适应模块是 TCN 残差块中引入的子网络。在 TCN 残差块中,卷积获得的特征向量经绝对值和全局平均池化转换为一维向量,再通过两层全连接网络的学习,让每个通道都具有独立的阈值。编码器使用改进的 TCN 提取输入时序中的相关性特征,核心特征由中间特征向量压缩表示。




图 3 ST-TCN 结构

Fig. 3 Schematic diagram of the ST-TCN

(3)输出层。解码器同样使用改进的 TCN 对编码器输出的中间特征向量进行解码,然后使用连接层重构输入时序。第 n 份反标准化重构样本在第 t 个采样时刻的传感器时序的向量表示为

$$\hat{\mathbf{x}}_t^n = (\hat{x}_{t,1}^n, \hat{x}_{t,2}^n, \dots, \hat{x}_{t,M}^n)^T \in \mathbf{R}^M \quad (6)$$

3.2 冷水机组传感器故障诊断策略

ST-TCN 重构模型通过基于软阈值自适应 TCN 的编码器深度挖掘正常传感器时序数据的非线性特征,再将特征向量输入到解码器中进行时序重构。图 4 为基于 ST-TCN 模型的冷水机组传感器偏差故障诊断流程,可分为以下 3 步。




图4 故障诊断流程

Fig. 4 Flow chart of chiller sensors fault diagnosis

(1)训练模型。在压缩式冷水机组实验平台中,采集不同工况下正常运行的传感器时序数据,构成实验数据集,分割出足够量的训练样本集和验证样本集用于训练重构模型。定义第 n 份训练样本在第 t 个采样时刻的重构残差向量为

$$\mathbf{e}_t^{\text{tr},n} = \hat{\mathbf{x}}_t^n - \mathbf{x}_t^n \quad (7)$$

定义损失函数为

$$\frac{1}{NT} \sum_{n=1}^N \sum_{t=1}^T \|\mathbf{e}_t^{\text{tr},n}\|_2^2 \quad (8)$$

选用 Adam 优化器最小化损失函数,优化模型的权重和偏置项。

(2)确定故障阈值。在数据集中分割出故障阈值确定集,第 n 个阈值确定样本在第 t 个采样时刻的重构残差向量为

$$\mathbf{e}_t^{\text{th},n} = (e_{t,1}^{\text{th},n}, \dots, e_{t,p}^{\text{th},n}, \dots, e_{t,M}^{\text{th},n})^T \quad (9)$$

式中 $\mathbf{e}_t^{\text{th},n}$ 为第 n 份阈值确定样本中,第 p 个传感器在第 t 个采样时刻的重构残差值。第 p 个传感器的故障阈值 e_p 的计算式为

$$e_p = \max(|\mathbf{e}_{t,p}^{\text{th},n}|) \quad (10)$$

式中 $1 \leq n \leq N_{\text{mor}}, 1 \leq t \leq T, N_{\text{mor}}$ 为故障阈值确定样本集的样本数量。故障阈值向量 $\mathbf{e}^{\text{th},v}$ 由 M 个传感器的故障阈值拼接而成,计算式为

$$\mathbf{e}^{\text{th},v} = (e_1, e_2, \dots, e_M)^T \quad (11)$$

(3)诊断偏差故障。在数据集中分割出测试样本集,注入不同大小的偏差故障,第 n 个测试样本在第 t 个采样时刻的重构残差向量为

$$\mathbf{e}_t^{\text{te},n} = (e_{t,1}^{\text{te},n}, \dots, e_{t,p}^{\text{te},n}, \dots, e_{t,M}^{\text{te},n})^T \quad (12)$$

式中 $\mathbf{e}_t^{\text{te},n}$ 为第 n 份测试样本中,第 p 个传感器在第 t 个采样时刻的重构残差值。将测试样本中每一个采

样时刻的重构残差向量与故障阈值向量 $e^{te,v}$ 中的对应元素进行逐一比较,识别发生故障的传感器。故障传感器的判别条件如下

$$|e_{t,p}^{te,n}| > e_p, |e_{t,q}^{te,n}| \leq e_q \quad (13)$$

式中 $q=1, \dots, p-1, p+1, \dots, M$ 。此时,可判断第 p 个传感器为故障传感器。

4 实验验证与对比分析

4.1 实验数据集

本文采用的压缩式冷水机组实验平台如图 5 所示。持续采集机组正常运行时包括压缩机吸气温度传感器 T1 等在内的 11 种传感器的时间序列,共获得 13 853 份训练样本,1 979 份故障阈值确定样本,3 959 份测试样本。每个样本由 $T=7$ 个传感器时序组成。




图 5 压缩式冷水机组实验平台

Fig. 5 Experimental platform of Compression chiller

由于冷水机组中多个传感器同一时刻发生故障的概率非常小,因此本文只针对同一时刻至多有一个故障传感器的情况进行研究。在压缩式冷水机组运行过程中难以获取故障传感器数据,故而在测试样本集中添加如表 2 和表 3 所示的不同大小的偏差来模拟传感器故障信号,其中最小故障的幅值为各传感器实测值均值的 5%,且大于最大允许误差。

表 2 温度传感器模拟不同程度偏差故障情况

Table 2 Simulation of temperature sensors deviation fault

温度传感器	偏差故障范围/ $^{\circ}\text{C}$	步长/ $^{\circ}\text{C}$
T1, T5, T6, T7	$-1.2 \sim -0.3, 0.3 \sim 1.2$	0.3
T2, T3, T4	$-2.2 \sim -1.0, 1.0 \sim 2.2$	0.4

表 3 压力传感器模拟不同程度偏差故障情况

Table 3 Simulation of pressure sensors deviation fault

压力传感器	偏差故障范围/MPa	步长/MPa
P1, P4	$-0.080 \sim -0.035, 0.035 \sim 0.080$	0.015
P2, P3	$-0.10 \sim -0.07, 0.07 \sim 0.10$	0.010

4.2 ST-TCN 模型的网络训练性能和故障诊断性能

4.2.1 网络训练性能

以 ST-TCN 重构模型的第一个残差块为例,随机选取连续的 11 个样本进行阈值向量可视化,结果如图 6 所示。分析可知,同一个样本的各个通道获得独立的阈值,组成一个阈值向量,不同样本的阈值向量各不相同。噪声会降低神经网络的特征提取能力。软阈值自适应模块通过剔除贡献比低的特征来提升网络性能。在此过程中,被剔除的信息可能包含有用信息,但输入的恒等映射通路使有用信息得以向后层传递,只是占据的比重减小。




图 6 阈值向量权重分布

Fig. 6 Threshold vector weight distribution map

本文采用均方误差(mean square error, MSE)来评价模型重构性能的优劣。测试集各传感器重构 MSE 如表 4 所示。时间序列重构 MSE 越小说明该模型对正常传感器时序数据的重构能力越强,网络的训练性能越好。

表 4 测试集重构 MSE


Table 4 Reconstruction MSE of test set

传感器	$I_{\text{MSE},T}/^{\circ}\text{C}^2$	传感器	$I_{\text{MSE},P}/\text{MPa}^2$
T1	0.012 1	P1	3.609×10^{-5}
T2	0.031 7	P2	6.991×10^{-5}
T3	0.023 9	P3	8.240×10^{-5}
T4	0.027 8	P4	3.878×10^{-5}
T5	0.016 6		
T6	0.010 4		
T7	0.009 5		


4.2.2 传感器故障诊断性能

定义故障识别率为准确识别出故障传感器时序数与测试集中偏差相同的故障传感器时序总数的比值。图 7 为传感器偏差故障识别率的分布。不同传感器的偏差故障识别率不同。基于 ST-TCN 重构模型的故障诊断方法的故障识别率均高于 85%,且随着偏差故障幅值的增加而提高,验证了该方法在


冷水机组传感器故障诊断任务中的可行性。




(a) 传感器 T1、T5、T6 和 T7 的偏差故障识别率分布



(b) 传感器 T2、T3 和 T4 的偏差故障识别率分布



(c) 传感器 P1 和 P4 的偏差故障识别率分布



(d) 传感器 P2 和 P3 偏差故障识别率分布

图7 冷水机组传感器偏差故障识别率分布

Fig. 7 Fault recognition rate distribution of chiller sensors

4.3 TCN 结构改进前后的对比实验

为了验证改进措施的有效性,在重构模型网络层数和参数相同的前提下进行对比实验,以温度传感器 T1 和压力传感器 P4 为例,比较基于传统 TCN 的重构模型(ED-TCN)与 ST-TCN 模型的网络训练性能和传感器故障诊断性能。

4.3.1 网络训练性能对比与分析

TCN 改进前后,模型训练 Loss 曲线如图 8 所示。由于网络结构不同 ED-TCN 模型与 ST-TCN 模型的损失函数在训练时的收敛速度与平稳性出现差异。两个模型在训练初期都获得了较小的损失值,但随着迭代次数的增加,ED-TCN 模型的损失值下降速度比改进后的 ST-TCN 模型缓慢,而且在迭代后期出现振荡,使得模型精度下降。






图8 模型训练 Loss 曲线及训练速度

Fig. 8 Model training Loss curve and training speed


图 9 分别给出了传感器 T1 和 P4 基于 ED-TCN 模型与 ST-TCN 模型在训练集和阈值确定集上的重构残差图。对于正常运行的传感器 T1,ED-TCN 模型和 ST-TCN 模型在阈值确定集上的重构 MSE 分别为 $0.026\text{ }^{\circ}\text{C}^2$ 和 $0.012\text{ }^{\circ}\text{C}^2$,从 ED-TCN 模型改进到 ST-TCN 模型的过程中,传感器 T1 的时序重构 MSE 降低了 53.5%。对于正常运行的传感器 P4,ED-TCN 模型和 ST-TCN 模型在阈值确定集上的重构 MSE 分别为 $1.436 \times 10^{-4}\text{ MPa}^2$ 和 $3.878 \times 10^{-5}\text{ MPa}^2$,从 ED-TCN 模型改进到 ST-TCN 模型的过程中,传感器 P4 的时序重构 MSE 降




(a) 传感器 T1 的 ED-TCN 模型重构残差



(b) 传感器 T1 的 ST-TCN 模型重构残差



(c) 传感器 P4 的 ED-TCN 模型重构残差



(d) 传感器 P4 的 ST-TCN 模型重构残差

图 9 ED-TCN 与 ST-TCN 模型在训练集和测试集上的重构残差

Fig. 9 Reconstructed residuals of ED-TCN and ST-TCN on training set and test set

低了 73.0%。结果表明,TCN 结构的改进增强了模型对正常运行的传感器时间序列的重构能力。

综上可知,ST-TCN 模型在增加少量参数计算量的前提下,明显地提升了网络的训练性能。软阈值自适应模块提高了 TCN 在冷水机组传感器数据上的特征提取能力,使模型有针对性地完成时序重构任务。通过与传统 TCN 重构模型的对比分析,进一步验证了改进措施的有效性。

4.3.2 传感器故障诊断性能对比与分析

灵敏度指故障诊断方法对小偏差故障的识别能力,可用 MSE 来定量分析。在发生较小的偏差故障时,T1 和 P4 基于 ED-TCN 与 ST-TCN 模型的重构 MSE 和故障识别率分别如表 5 和表 6 所示。当传感器发生相同幅值的偏差故障时,模型的 MSE 与正常运行时的 MSE 差距越大,则该方法的灵敏度越高。当 T1 和 P4 分别发生故障幅值为 $\pm 0.3^{\circ}\text{C}$

和 $\pm 0.035\text{ MPa}$ 的偏差故障时,改进后的 ST-TCN 方法获得了更高的灵敏度和故障诊断率,验证了该方法在冷水机组传感器故障诊断任务中的优势。

表 5 传感器 T1 和 P4 重构 MSE

Table 5 MSE of T1 and P4

传感器	状态	ED-TCN 模型 重构 MSE	ST-TCN 模型 重构 MSE
T1	正常运行	0.026°C^2	0.012°C^2
	-0.3°C	0.350°C^2	0.460°C^2
	0.3°C	0.360°C^2	0.490°C^2
	偏差故障		
P4	正常运行	$1.4 \times 10^{-4}\text{ MPa}^2$	$3.9 \times 10^{-5}\text{ MPa}^2$
	-0.035 MPa	$4.0 \times 10^{-4}\text{ MPa}^2$	$6.1 \times 10^{-4}\text{ MPa}^2$
	0.035 MPa	$4.3 \times 10^{-4}\text{ MPa}^2$	$6.0 \times 10^{-4}\text{ MPa}^2$
	偏差故障		

表 6 T1 和 P4 小偏差故障识别率

Table 6 Small deviation fault recognition rate of T1 and P4

模型	传感器小偏差故障识别率/%			
	-0.3°C	0.3°C	-0.035 MPa	0.035 MPa
ED-TCN	47.2	51.1	67.8	67.3
ST-TCN	89.3	89.6	92.6	91.1

4.4 ST-TCN 方法与其他故障诊断方法的对比实验

表 7 和表 8 分别给出了传感器 T1 和 P4 发生不同幅值偏差故障的情况下,PCA 法、改进的 LSTM(ILSTM)分类法、EDN 重构法、DAN 重构法以及本文所提方法的故障识别率。

表 7 不同方法下传感器 T1 的偏差故障识别率

Table 7 Comparison of fault recognition rates of T1

温度偏差 / $^{\circ}\text{C}$	传感器故障识别率/%				
	PCA	ILSTM	EDN	DAN	本文 方法
1.2	63.8	95.2	75.8	100.0	100.0
0.9	51.7	90.0	70.4	100.0	99.1
0.6	12.9	87.7	64.6	95.7	93.4
0.3	0.0	84.0	47.1	93.1	89.6
-0.3	0.0	81.4	44.5	92.6	89.3
-0.6	15.3	85.4	63.7	96.2	92.1
-0.9	53.4	89.5	69.3	100.0	98.7
-1.2	83.5	92.9	72.6	100.0	100.0

ST-TCN 重构法的故障识别率高于 PCA 法、ILSTM 分类法和 EDN 重构法。以压缩机吸气温传感器 T1 为例,ST-TCN 法的平均偏差故障识别率相较于深度学习方法中的 ILSTM 分类法和 EDN 重构法分别提升了 7.9% 和 50.0%,该方法利用适合处理时间序列问题的 TCN 自动提取冷水机组传感器时序数据中的相关性特征,并引入软阈值自适应模块来突出重要特征,减少不相关的信息,因此获得了较高的偏差故障识别率。DAN 模型因引入双重注意力机制,分别在时间维度和数据维度有针对性地提取特征,同时添加融合模块提升重构能力,获得了更为优异的故障诊断性能。

表 8 不同方法下传感器 P4 的偏差故障识别率

Table 8 Comparison of fault recognition rates of P4

压力偏差 /MPa	传感器故障识别率/%				
	PCA	ILSTM	EDN	DAN	本文方法
0.080	51.4	97.3	71.0	100.0	100.0
0.065	44.6	96.2	68.4	99.1	98.3
0.050	34.3	93.1	62.4	98.3	94.7
0.035	27.6	87.8	52.9	96.4	91.1
-0.035	24.7	86.1	54.3	96.7	92.6
-0.050	33.8	92.9	62.4	99.1	95.4
-0.065	42.8	93.4	69.2	100.0	97.9
-0.080	50.0	96.2	72.9	100.0	100.0

5 总 结

本文从冷水机组的机理出发,考虑噪声等干扰因素,设计了基于 ST-TCN 的冷水机组传感器故障诊断方法。通过对实验结果的分析得出以下结论。

(1)ST-TCN 重构模型依靠其“端到端”的网络结构,直接识别故障传感器。该模型在不需降维和数据压缩的前提下表现出了对故障传感器数据的敏感性。

(2)ST-TCN 在 TCN 残差块中引入软阈值自适应模块进行特征选择,并更换填充方式和激活函数,深度挖掘冷水机组传感器时序特征,有效地提升了重构模型的网络训练性能和传感器故障诊断性能。

(3)当传感器发生相同大小的偏差故障时,不同传感器的故障识别率不同,但均高于 85%,且随着幅值的增加而提高。当传感器发生大小相等符号相反的偏差故障时,ST-TCN 获得的故障识别率在分

布上具有良好的对称性。

(4)ST-TCN 重构法将信号降噪融入深度神经网络中,加强了网络对有用信息的提取能力。但是,该模型由于结构上的局限只能盲目捕获特征。因此,注意力机制的引入以及考虑电子膨胀阀开度等控制因素对冷水机组传感器时序数据的影响,成为 ST-TCN 模型改进的主要方向。

参考文献:

- [1] LUO X J, FONG K F. Novel pattern recognition-enhanced sensor fault detection and diagnosis for chiller plant [J]. *Energy and Buildings*, 2020, 228: 110443.
- [2] ZHOU Zhenxin, LI Guannan, WANG Jiangyu, et al. A comparison study of basic data-driven fault diagnosis methods for variable refrigerant flow system [J]. *Energy and Buildings*, 2020, 224: 110232.
- [3] SUN Xueting, YAN Ke, ZHOU Xiaokang. Fault detection and diagnosis of chillers with S&D convolutional neural network [C]//2020 International Conferences on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData) and IEEE Congress on Cybermatics (Cybermatics). Piscataway, NJ, USA: IEEE, 2020: 829-836.
- [4] 赵广社, 吴思思, 荣海军. 多源统计数据驱动的航空发动机剩余寿命预测方法 [J]. *西安交通大学学报*, 2017, 51(11): 150-155, 172.
- [5] ZHAO Guangshe, WU Sisi, RONG Haijun. A multi-source statistics data-driven method for remaining useful life prediction of aircraft engine [J]. *Journal of Xi'an Jiaotong University*, 2017, 51(11): 150-155, 172.
- [6] YAO Wanli, LI Donghui, GAO Long. Fault detection and diagnosis using tree-based ensemble learning methods and multivariate control charts for centrifugal chillers [J]. *Journal of Building Engineering*, 2022, 51: 104243.
- [7] WU Ping, LOU Siwei, ZHANG Xujie, et al. Data-driven fault diagnosis using deep canonical variate analysis and fisher discriminant analysis [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(5): 3324-3334.
- [8] 石大亮, 刘江岩, 李夔宁, 等. 基于关联规则分类的冷水机组故障诊断 [J]. *制冷学报*, 2020, 41(5): 66-75.
- [9] SHI Daliang, LIU Jiangyan, LI Kuining, et al. Fault diagnosis of chillers based on association classification

- rules [J]. *Journal of Refrigeration*, 2020, 41(5): 66-75.
- [8] 王卉, 李英顺. 改进型证据更新规则的动态故障诊断算法 [J]. *计算机工程与应用*, 2020, 56(2): 261-265. WANG Hui, LI Yingshun. Dynamic fault diagnosis algorithm for improved evidence update rules [J]. *Computer Engineering and Applications*, 2020, 56(2): 261-265.
- [9] 王秋杰, 金涛, 梅李鹏, 等. 基于模型分层的配电网故障诊断方法 [J]. *电力自动化设备*, 2020, 40(1): 73-79. WANG Qiujie, JIN Tao, MEI Lipeng, et al. Model-based hierarchical diagnosis method for distribution network faults [J]. *Electric Power Automation Equipment*, 2020, 40(1): 73-79.
- [10] IVANOV V, BROJBOIU M, IVANOV S. Faults diagnosis in transport and distribution lines based on the analytic model [C]//2017 International Conference on Electromechanical and Power Systems (SIELMEN). Piscataway, NJ, USA: IEEE, 2017: 605-609.
- [11] WANG Shengwei, CUI Jingtian. Sensor-fault detection, diagnosis and estimation for centrifugal chiller systems using principal-component analysis method [J]. *Applied Energy*, 2005, 82(3): 197-213.
- [12] SCHÖLKOPF B, SMOLA A, MÜLLER K R. Non-linear component analysis as a kernel eigenvalue problem [J]. *Neural Computation*, 1998, 10(5): 1299-1319.
- [13] 陈乐瑞, 曹建福, 王晓琪. 结合非线性频谱和核主元分析的机器人用 RV 减速器故障诊断 [J]. *西安交通大学学报*, 2020, 54(1): 32-41. CHEN Lerui, CAO Jianfu, WANG Xiaoqi. Fault diagnosis for robot RV reducer using nonlinear frequency spectrum and kernel principal component analysis [J]. *Journal of Xi'an Jiaotong University*, 2020, 54(1): 32-41.
- [14] 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 Kun, DU Wenxia, LV Feng, et al. Fault detect method based on improved dynamic kernel principal component analysis [J]. *CIESC Journal*, 2019, 70(2): 716-722.
- [15] YAN Xiuying, GUAN Ting, FAN Kaixing, et al. Novel double layer BiLSTM minor soft fault detection for sensors in air-conditioning system with KPCA reducing dimensions [J]. *Journal of Building Engineering*, 2021, 44: 102950.
- [16] MAO Qianjun, FANG Xi, HU Yunpeng, et al. Chiller sensor fault detection based on empirical mode decomposition threshold denoising and principal component analysis [J]. *Applied Thermal Engineering*, 2018, 144: 21-30.
- [17] 池福临, 杨新宇, 邵思羽, 等. 基于深度收缩残差网络的轴承变工况故障诊断 [J/OL]. *计算机集成制造系统* [2022-04-01]. <http://kns.cnki.net/kcms/detail/11.5946.TP.20220328.1612.007.html>. CHI Fulin, YANG Xinyu, SHAO Siyu, et al. Bearing fault diagnosis under variable working conditions based on deep residual shrinkage networks [J/OL]. *Computer Integrated Manufacturing Systems* [2022-04-01]. <http://kns.cnki.net/kcms/detail/11.5946.TP.20220328.1612.007.html>.
- [18] 李冬辉, 尹海燕, 郑博文, 等. 改进的 LSTM 方法在冷水机组传感器故障检测中的应用 [J]. *电工技术学报*, 2019, 34(11): 2324-2332. LI Donghui, YIN Haiyan, ZHENG Bowen, et al. Application of improved LSTM method in sensor fault detection of the chiller [J]. *Transactions of China Electrotechnical Society*, 2019, 34(11): 2324-2332.
- [19] MALHOTRA P, RAMAKRISHNAN A, ANAND G, et al. LSTM-based encoder-decoder for multi-sensor anomaly detection [C/OL]//ICML 2016 Anomaly Detection Workshop. Princeton, NJ, USA: IMLS [2022-04-01]. <https://doi.org/10.48550/arXiv.1607.00148>.
- [20] LI Ding, LI Donghui, LI Chengdong, et al. A novel data-temporal attention network based strategy for fault diagnosis of chiller sensors [J]. *Energy and Buildings*, 2019, 198: 377-394.
- [21] LAI Guokun, CHANG Weicheng, YANG Yiming, et al. Modeling long-and short-term temporal patterns with deep neural networks [C]//The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. New York, NY, USA: Association for Computing Machinery, 2018: 95-104.
- [22] ZHANG Jiyang, WANG Yuxuan, TANG Jianxiong, et al. MS-TCN: a multiscale temporal convolutional network for fault diagnosis in industrial processes [C]//2021 American Control Conference (ACC). Piscataway, NJ, USA: IEEE, 2021: 1601-1606.
- [23] LIU Chongdang, ZHANG Linxuan, YAO Rong, et al. Dual attention-based temporal convolutional network for fault prognosis under time-varying operating conditions [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-10.
- [24] MENG Chao, JIANG Xuesong, WEI Xiumei, et al. A time convolutional network based outlier detection for

- multidimensional time series in cyber-physical-social systems [J]. IEEE Access, 2020, 8: 74933-74942.
- [25] LEA C, VIDAL R, REITER A, et al. Temporal convolutional networks: a unified approach to action segmentation [C]//Computer Vision-ECCV 2016 Workshops. Cham, Germany: Springer International Publishing, 2016: 47-54.
- [26] ZHAO Minghang, ZHONG Shisheng, FU Xuyun, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4681-4690.

(编辑 陶晴 亢列梅)