

DOI: 10.19650/j.cnki.cjsi.J2311503

# 多尺度特征自适应融合的气动控制阀故障诊断\*

郝洪涛<sup>1,2</sup>, 王凯<sup>1</sup>, 张炳建<sup>1</sup>, 刘建昊<sup>1</sup>

(1. 宁夏大学机械工程学院 银川 750021; 2. 宁夏智能装备 CAE 重点实验室 银川 750021)

**摘要:**气动控制阀作为过程工业典型的终端执行机构,由于故障发生率高、故障类型繁多,导致故障识别难度大,且故障后果严重,因此对其进行智能的故障检测和诊断具有重要的实际意义。本文提出了一种多尺度特征自适应融合网络用于气动控制阀故障诊断。首先,搭建了融合自注意力机制的多尺度特征提取网络自动提取信号的空间特征和细节特征。然后,设计了权重自适应特征融合网络对多尺度特征加权融合,提高模型对故障特征的表征能力。最后,由长短时记忆神经网络和 SoftMax 函数实现特征识别和故障分类。实验结果表明,该模型在 DAMADICS 阀门基准实验平台上的平均检测准确率达到 96.82%,均高于其他对比模型。与最近发表文献中的检测结果对比发现,本文开发的模型在可检测的故障数量和检测准确率方面也具有一定的优势,并且通过实验验证了模型的检测性能。

**关键词:** 气动控制阀;故障诊断;特征提取;特征融合;卷积神经网络

**中图分类号:** TH17 TH137.52 **文献标识码:** A **国家标准学科分类代码:** 460.40

## Fault diagnosis of pneumatic control valves with multi-scale features adaptive fusion

Hao Hongtao<sup>1,2</sup>, Wang Kai<sup>1</sup>, Zhang Bingjian<sup>1</sup>, Liu Jianhao<sup>1</sup>

(1. School of Mechanical Engineering, Ningxia University, Yinchuan 750021, China; 2. Ningxia Key Laboratory of CAE on Intelligent Equipment, Yinchuan 750021, China)

**Abstract:** Pneumatic control valves act as typical terminal actuators in the process industry, which suffer from difficulties in fault identification and severe consequences of faults due to the high incidence of faults and diverse fault types. Therefore, intelligent fault detection and diagnosis of pneumatic control valves have crucial practical significance. In this paper, an adaptive multi-scale features fusion network is proposed for the pneumatic control valve fault diagnosis. Firstly, a multi-scale feature extraction network with fusion self-attention mechanism is constructed to automatically extract spatial and detail features of signals. Then a weighted adaptive feature fusion network is designed to perform the weighted fusion of multi-scale features to improve the fault feature characterization capability of model. Finally, the feature identification and fault classification are performed by the Long short-term memory neural network with SoftMax function. The experimental results show that the model achieves an average accuracy of 96.82% on the DAMADICS valve benchmark experimental platform, which are higher than other comparative models. Comparison with the detection results in the latest literature reveals that the model developed in this paper also has certain advantages such as the number of detectable faults and detection accuracy, and the detection performance of model is experimentally verified.

**Keywords:** pneumatic control valve; fault diagnosis; feature extraction; feature fusion; convolutional neural network

## 0 引言

随着现代工厂的信息化和复杂化,气动控制阀的智

能状态评估和故障诊断在生产过程中变得尤为重要。广泛应用于化工、冶金、造纸、发电、食品等行业<sup>[1]</sup>,市场上90%以上的执行器和定位器都是气动的<sup>[2]</sup>。然而,气动控制阀由于长期运行在恶劣的外部环境当中,往往会出

现各种故障,不仅影响其自身性能,还会造成控制回路失效。据统计,造纸行业中 20%~30% 的控制回路故障和化工行业中大约 70% 的故障都是由控制阀引起的<sup>[3]</sup>。由于气动控制阀故障导致的非计划停产不仅会造成巨大的经济损失,甚至还会导致人员伤亡。而通过对装备及时的故障检测和诊断来规划工厂整体的停机时间,可以有效保证工厂的安全运维。

目前阀门的故障检测方法主要包括基于模型和基于数据驱动的故障检测方法。基于模型的检测方法是通过建立控制阀的机理模型,观察模型输出变量与实际信号之间的关系来判断是否发生故障。Manninen<sup>[4]</sup>通过对控制阀动力学建模,提出了一种基于物理模型的气动控制阀故障诊断方法。Puig 等<sup>[5]</sup>从多个角度建立了气动控制阀的数学模型,通过区间观测器分析残差序列来检测故障。薄翠梅等<sup>[6]</sup>通过建立阀门正常状态的解析模型,利用外部椭圆约束迭代算法估计自适应阈值进行故障检测,在 DAMADICS 平台验证了该方法的有效性。尽管基于机理模型的故障检测方法具有较高的准确率,但对于气动控制阀这样的复杂非线性系统,建立一个准确的机理模型非常困难。相比之下,基于数据驱动的检测方法避免了建立机理模型的困难,适合于复杂系统的故障诊断研究。

基于数据驱动的智能分类算法已被广泛应用于阀门的故障诊断。Bezerra 等<sup>[7]</sup>利用典型性和偏心性数据分析方法,开发了一种无监督实时在线自学习算法,用于工业过程装备的故障检测。D'Angelo 等<sup>[8]</sup>应用模糊聚类技术将原始数据转化为符合  $\beta$  分布的数据,然后利用 Metropolis-Hastings 算法识别转化后的时间序列中变化点的概率,以此进行故障检测。Ma 等<sup>[9]</sup>提出了一种多变量数据驱动的故障诊断方法,采用典型变量分析方法计算原始数据的  $T^2$  统计量和平方预测误差 (square prediction error, SPE),通过设置合适的阈值进行故障诊断。Calado 等<sup>[10]</sup>设计了模糊定性模拟算法和模糊神经网络来识别阀门故障。Rodríguez-Ramos 等<sup>[11]</sup>提出了一种基于模糊聚类的故障诊断方法,用于在线监测和自学习,该方法已在 DAMADICS 模拟器中得到验证。Przystałka 等<sup>[12]</sup>利用混沌理论和递归神经网络搭建了系统的神经网络模型,该模型在 DAMADICS 模拟器中验证了其有效性。Kowsalya 等<sup>[13]</sup>通过主成分分析 (principal component analysis, PCA) 提取原始数据的基本特征,然后将提取的特征输入人工神经网络进行故障识别。Andrade 等<sup>[14]</sup>在构建决策树和残差模型的基础上开发了非线性自回归神经网络模型,用于气动控制阀的故障诊断。Ortiz 等<sup>[15]</sup>解决了气动控制阀的数据缺失问题,通过算术平均法和模式法来预测缺失值,然后应用长短时记忆神经网络 (long short-term memory, LSTM) 进行故障分类。虽然这种方法具有良好的鲁棒性,但能诊断出的故障类型太少。

综上所述,目前的研究方法有如下几点局限:1) 大多数方法是通过设置阈值或计算残差来进行阀门的故障诊断,这种方法过于依赖先验知识;2) 目前基于神经网络的阀门故障诊断模型都是浅层网络结构,难以挖掘深层特征,导致故障分类效果不佳;3) 目前的方法大多只考虑小部分故障类型,当故障类型增加时,这些方法的有效性就会急剧下降;基于此,本文设计了一种多尺度特征自适应融合网络用于气动控制阀的故障诊断。该网络在多尺度卷积神经网络的基础上,通过设计融合自注意力特征提取模块挖掘信号的空间特征和细节特征。同时,设计了权重自适应特征融合模块,通过对特征重要性判断,重新为多尺度特征进行权重匹配,以保留重点信息,减少信息冗余。

## 1 理论分析

### 1.1 卷积神经网络 (CNN)

卷积神经网络 (convolutional neural network, CNN) 是一种受生物启发的前馈神经网络,广泛应用于语音识别、故障分类、图像处理等领域。卷积层是特征提取的关键,卷积核负责提取相应的数据特征<sup>[16]</sup>。本文采用的卷积神经网络由多个卷积层连接而成,每个卷积层的输出被非线性函数  $\tanh$  激活后作为下一个卷积层的输入。其数学模型描述为:

$$\mathbf{Z}^l(j) = \mathbf{w}_i^l \times \mathbf{x}^l(j) + \mathbf{u}_i^l \quad (1)$$

式中:  $\mathbf{Z}^l(j)$  表示第  $l$  个卷积层的输出特征,  $\mathbf{w}_i^l$  是第  $l$  层的权重,  $\mathbf{x}^l(j)$  是第  $l$  层的输入特征,  $\mathbf{u}_i^l$  表示偏差。

池化层通常放置在两个卷积层之间,用作下采样操作,对特征图进行稀疏处理,可减少特征的空间大小和网络参数。最常用的池化层是最大池化层,最大池化变换描述如下:

$$\mathbf{P}_j^{l+1}(i) = \max_{(i-1)X+1 \leq t \leq iX} \{ \mathbf{q}_j^l(t) \} \quad (2)$$

式中:  $t$  代表第  $t$  个神经元,  $t \in [(i-1)X+1, iX]$ ,  $l$  表示第  $l$  层,  $\mathbf{q}_j^l(t)$  表示神经元的值,  $X$  表示池化的范围,  $\mathbf{P}_j^{l+1}(i)$  表示池化层的输出。

全连接层的作用是将池化的神经元展开成一维向量形式。对于多分类问题,最后一个全连接层的激活函数通常选择 SoftMax 函数,从而得到样本属于各个类别的概率分布情况,全连接层可以表述为:

$$\mathbf{Z}^{l+1}(i) = f\left(\sum_{j=1}^m \sum_{i=1}^n \mathbf{X}_{ij}^l \mathbf{a}_j^l(t) + \mathbf{u}_i^l\right) \quad (3)$$

式中:  $\mathbf{X}_{ij}^l$  代表第  $l$  层的权重,  $\mathbf{Z}^{l+1}(j)$  是第  $l+1$  层全连接层的输出值,  $\mathbf{u}_i^l$  表示偏差,  $\mathbf{a}_j^l$  是第  $l$  层的输出结果,  $f(\cdot)$  表示 SoftMax 激活函数。

### 1.2 长短时记忆神经网络

LSTM 是一种改进的递归神经网络,其在相对长期记忆方面的优势使其广泛用于时间序列预测<sup>[17]</sup>。LSTM 使用特殊的隐藏单元来保留长期记忆,其内部结构如图 1 所示。对于一个时域信号  $x_t$ , 其内部隐藏单元和输出可以表示为:

$$f_t = \sigma(H_f \cdot [k_{t-1}, x_t] + u_f) \quad (4)$$

$$i_t = \sigma(H_i \cdot [k_{t-1}, x_t] + u_i) \quad (5)$$

$$o_t = \sigma(H_o \cdot [k_{t-1}, x_t] + u_o) \quad (6)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(H_c \cdot [k_{t-1}, x_t] + u_c) \quad (7)$$

$$k_t = o_t \odot \tanh(c_t) \quad (8)$$

式中:  $u$  表示偏差,  $H$  表示权重。  $i$  表示输入门,  $f$  表示遗忘门,  $o$  表示输出门,  $\sigma$  是 Sigmoid 激活函数,  $k_t$  表示相应的输出,  $c$  表示单元状态。

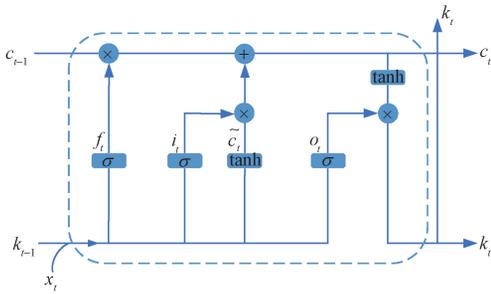


图 1 LSTM 网络结构

Fig. 1 The structure of LSTM

## 2 多尺度特征自适应融合网络模型

本文设计了一种多尺度特征自适应融合网络 (Multi-scale feature adaptive fusion network, MSFAFN), 整体框架如图 2 所示。该模型由特征提取、特征融合和特征识别 3 部分组成, 特征提取阶段设计了同时提取不同尺度特征信息的融合空间-通道并行注意力的多尺度特征提取网络同时关注通道信息和空间信息; 特征融合阶段设计了权重自适应特征融合网络 (weighted adaptive feature fusion network, WAFFN), 根据特征重要性分配不同的权重来融合深层特征, 增强了网络的特征表征能力, 大大降低了冗余特征的影响; 最后应用 LSTM 和 SoftMax 函数进行特征识别和特征分类, 显著提高了气动控制阀故障诊断准确率。

### 2.1 融合注意力的多尺度特征提取网络

#### 1) 多尺度卷积特征提取网络

多尺度卷积特征提取网络在扩大感受野的同时能够有效提取信号中不同尺度的特征信息, 防止特征丢失, 为后续特征识别提供充分的全局特征和局部特征。

多尺度卷积特征提取网络由两个不同卷积核大小的通道组成, 如图 2(a) 所示。通道 1 以  $32 \times 1, 16 \times 1$  和  $8 \times 1$  较大感受野的卷积层自动提取浅层和全局特征, 通道 2 以  $7 \times 1, 5 \times 1$  和  $3 \times 1$  较小感受野的卷积层自动提取深层

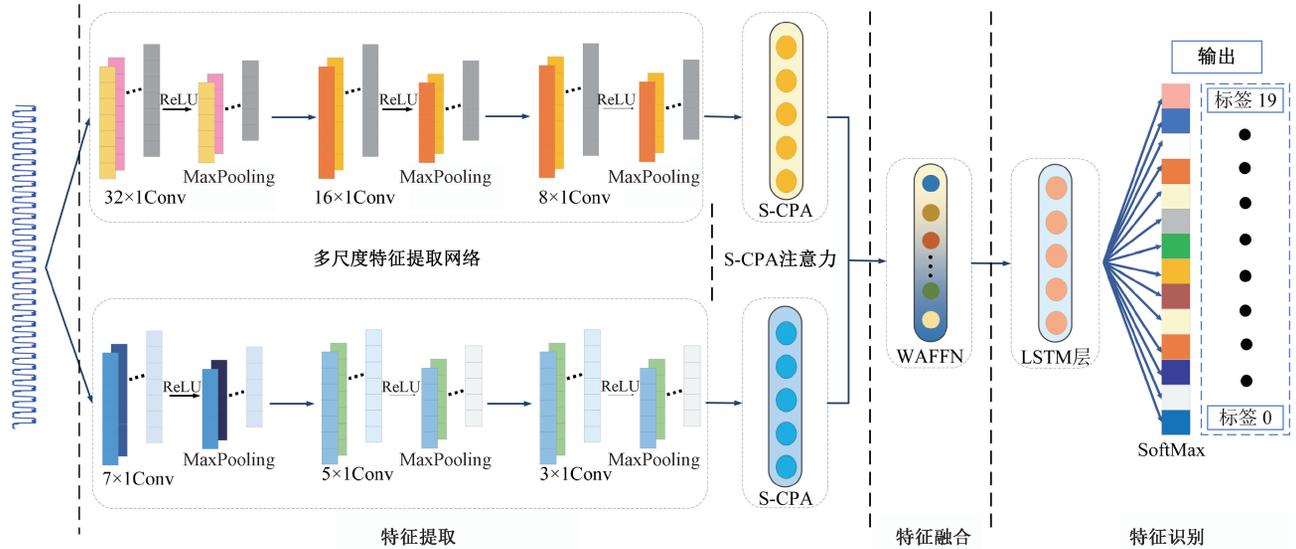


图 2 MSFAFN 网络结构

Fig. 2 The structure of MSFAFN

和细节特征。在每两层卷积之后进行池化操作, 减少冗余信息和网络参数。但如果直接对这两种特征进行融合, 必然存在信息冗余甚至会导致特征淹没, 因此要对两个通道的信息进行特征选择。

#### 2) 空间-通道并行自注意力机制 (S-CPA)

感受野较大的浅层特征提取网络能够提取信号的空间特征, 但会忽略信号中隐藏的细节特征。感受野较小的深层特征提取网络能够挖掘信号的细节特征, 但会丢

失信号的空间特征。细节特征和空间特征的融合对故障信息的表征更加全面充分。

为了挖掘信号细节特征的同时保留空间特征,受极化注意力机制<sup>[18]</sup>启发本文设计了空间-通道并联自注意力机制(spatial-channel parallel self-attention, S-CPA),如图3所示。S-CPA由空间自注意力机制和通道自注意力机制并行连接组成,空间注意力机制主要负责提取信号的空间特征,而通道注意力机制用于保留多尺度卷积特征提取模块所提取的细节特征,然后将经过空间注意力机制和通道注意力机制处理后的特征进行融合。

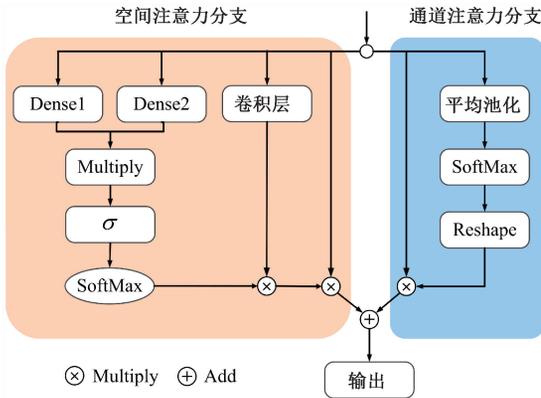


图3 S-CPA结构

Fig. 3 The structure of S-CPA

空间注意力分支:多尺度特征提取模块的每个通道特征都包含丰富的空间信息,空间注意力机制可以有效提取空间特征。本文设计的空间注意力机制  $A^{sp}(X) \in N \times W$  的表达式为:

$$A^{sp}(X) = W_q(X) \times F_{sr}[\sigma(W_{d1}(X) \times W_{d2}(X))] \quad (9)$$

式中:  $X$  表示输入,  $W_q$  卷积操作,  $W_{d1}$  和  $W_{d2}$  表示 Dense 层,  $\sigma$  表示计算张量逐元素平方根,  $F_{sr}(\cdot)$  表示 SoftMax 函数。

空间注意力分支的输出可表示为:

$$Z^{sp} = A^{sp}(X) \odot^{sp} X \in R^{C \times N \times W} \quad (10)$$

式中:  $\odot^{sp}$  表示空间乘法运算。

通道注意力分支:通道注意力机制可以对挖掘的细节特征进行加权,以保留重要的通道特征。本文设计的通道注意力机制  $A^{ch}(X) \in N \times 1$  的表达式为:

$$A^{ch}(X) = F_{sc}[W_d(W_{mp}(X))] \times X \quad (11)$$

式中:  $X$  表示输入,  $W_d$  卷积操作,  $W_{mp}$  表示平均池化操作,  $F_{sc}(\cdot)$  表示 SoftMax 函数。

通道注意力分支的输出可表示为:

$$Z^{ch} = A^{ch}(X) \odot^{ch} X \in R^{C \times N \times 1} \quad (12)$$

式中:  $\odot^{ch}$  表示空间乘法运算。

S-CPA 的最终输出为两个分支之和,其表达式为:

$$RSA(X) = Z^{sp} + Z^{ch} = A^{sp}(X) \odot^{sp} X + A^{ch}(X) \odot^{ch} X \quad (13)$$

## 2.2 权重自适应特征融合网络(WAFFN)

注意力机制的本质是学习一组自适应权值,并通过权值分配来选择关键信息,进而提高识别的准确率<sup>[19]</sup>。因此,应用注意力算法从多尺度特征中选择更关键、更相关的信息进行融合,比直接合并特征向量有更好的性能。本文提出了 WAFFN 如图4所示,具体融合过程如下:

1) 利用全局平均池化操作将两个通道的特征压缩:

$$\begin{cases} f_1 = \frac{1}{N} \sum_{i=1}^N F_1(i) \\ f_2 = \frac{1}{N} \sum_{i=1}^N F_2(i) \end{cases} \quad (14)$$

式中:  $f_1$  和  $f_2$  表示压缩后的空间特征,  $N$  表示该特征的空间维数,  $F(i)$  表示通道特征。

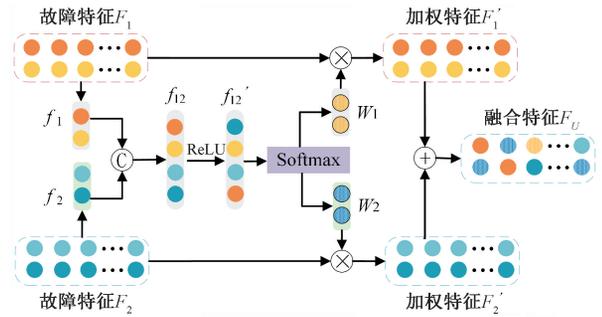


图4 WAFFN结构

Fig. 4 Structure of the WAFFN

2) 将压缩后的特征  $f_1$  和  $f_2$  进行连接,生成全局表示信息  $f_{12}$ 。并且对全局信息进行非线性操作得到特征  $f'_{12}$ 。

$$\begin{cases} f_{12} = [f_1, f_2] \\ f'_{12} = \text{ReLU}(W \cdot f_{12} + b) \end{cases} \quad (15)$$

式中:  $W$  和  $b$  表示权重和偏差。

3) 对特征  $f'_{12}$  进行 SoftMax 操作,生成每个通道特征的权重  $w_1, w_2$ 。

$$\begin{cases} w_1 = \frac{e^{w_1 f'_{12}}}{\sum_j e^{w_j f'_{12}}} \\ w_2 = \frac{e^{w_2 f'_{12}}}{\sum_j e^{w_j f'_{12}}} \end{cases} \quad (16)$$

4) 对不同通道的特征进行加权融合。

$$F_u = F'_1 + F'_2 = w_1 \otimes F_1 + w_2 \otimes F_2 \quad (17)$$

式中:  $F_u$  为融合特征,  $\otimes$  表示张量乘法运算。

### 2.3 特征识别与分类

LSTM 通过学习两个实体之间的长期依赖关系来处理全局特征,其独特的门结构对噪声有过滤作用,增强了模型的抗噪声能力,并且结合 SoftMax 函数对多分类问题的优势,提高了特征分类的准确率。本文网络训练过程中,将交叉熵函数作为损失函数,其定义如下:

$$L(Y|f(\mathbf{x})) = - \sum_{i=1}^N Y_i \log f(\mathbf{x}_i) \quad (18)$$

式中: $L$  表示损失值, $f(\mathbf{x}_i)$  表示样本  $i$  的概率分布, $Y_i$  表示符号函数。

## 3 实验结果与分析

### 3.1 数据集获取

DAMADICS 以波兰 Lublin 制糖厂制糖过程中的 3 个工业执行器为实验对象,依据执行器工作原理,综合考虑执行器的物理和电气结构特性,以及其在恶劣环境下工作所需的典型工程要求,大量收集其运行时产生的真实数据来完成平台的开发和验证<sup>[20]</sup>。执行器由控制阀、气动伺服电机和定位器组成,如图 5 所示。执行器的子元件对应于工业设备:37 型伺服电机、定位器 A785 和等百分比控制阀。执行器通过控制外部信号  $CV$  控制阀门开度,并通过设置基本参数液体温度  $T_1$ 、阀门进口压力  $P_1$  和出口压力  $P_2$  来调节系统状态,由此产生的反馈信号阀杆位移  $X$  和流体流量  $F$  将被用于故障诊断。在气动控制阀的运行过程中,控制阀、定位器、伺服电机和气动执行器等几个部件都可能发生故障,该模型可以仿真如表 1 所示的 19 种阀门故障。

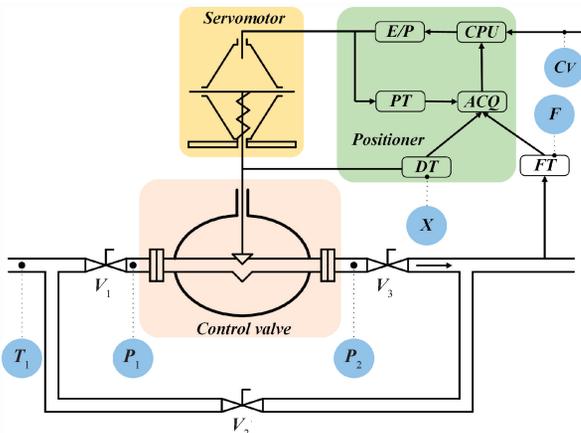


图 5 DAMADICS 结构

Fig. 5 The structure of DAMADICS

PCA 是一种将高维信息投射到低维子空间并最大限度保留原始信息的方法。此外,PCA 可以消除冗余数据的影响。由于原始信号是由反馈信号阀杆位移  $X$  和流体

表 1 故障描述

Table 1 Fault description

故障	故障描述	标签
F0	正常状态	0
F1	阀门堵塞	1
F2	阀塞或阀座沉积	2
F3	阀塞或阀座腐蚀	3
F4	阀门摩擦增加	4
F5	外漏	5
F6	内漏	6
F7	中度蒸发	7
F8	伺服电机活塞杆扭曲	8
F9	机架松动	9
F10	膜片穿孔	10
F11	弹簧失效	11
F12	电气转换器故障	12
F13	阀杆位移传感器故障	13
F14	压力传感器故障	
F15	定位反馈故障	15
F16	供气压力下降	16
F17	压差变化	17
F18	旁通阀故障	18
F19	流量传感器故障	19

流量  $F$  组成的二维数据,数据集中必然存在不相关和冗余的参数特征。引入 PCA 技术是为了降低数据维度,提高计算效率。同时,为了满足模型训练的要求,本文采用重叠采样的方法进行数据扩充<sup>[21]</sup>。

本文对气动控制阀的正常和非正常工作状态共制作了 4 066 个样本,每种状态有 214 个样本,每个样本的长度为 1 024。这些样本被随机分成两组,其中 80% 用于模型训练,20% 用于模型测试,标签采用 One-hot 编码技术进行编码。

### 3.2 实验环境

该模型是基于 TensorFlow2.9.1 开发的,所有结果都是在 Windows 1 064 bit 操作系统、Intel(R) Core(TM) i7-7700HQ CPU @ 2.80 GHz 和 8 GB RAM 上迭代训练 100 次得到的。

### 3.3 结果验证与分析

#### 1) 故障识别结果

模型训练完成后,用测试集对开发的模型进行测试,以评估模型性能。如表 2 所示,MSFAFN 模型的平均测试准确率达到 96.82%。图 6 显示了模型测试结果的混

淆矩阵,可以发现,模型有一些错误分类,将一些正常状态 F0 误分为故障 F8 和 F16,少量的 F3 误分为 F19, F4 误分为 F7 以及 F16 误分为 F0 和 F8。造成这种现象的主要原因是这些样本过于相似,甚至相互重叠,从而造成误分类。从故障发生机理角度来看,故障 F8 表示伺服电机活塞杆扭曲,在其发生微弱变形时,虽然会引起阀杆位移的微小变化进而导致流量变化,但在正常状态下,在流量反馈调节时阀杆位移和流量也会出现微弱变化,而这部分信号之间相似度较高,导致 F0 和 F8 之间出现少量误检。同样, F16 表示定位器供气压力下降故障,在早期压力下降幅度较小时,通过反馈机制能够及时进行流量调节,这与正常状态下的流量调节方式相似,所以信号变化不明显,导致少量 F16 误检。尽管如此,该模型可以成功地检测出 17 种故障,并且对其中 15 种故障的诊断准确率达到 100%。然而,为了提供一个全面综合的评价,本文还引用了额外的评估指标,精度、召回率和 F1 分数进行模型评估。其表达式为:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (19)$$

$$Precision = \frac{TP}{TP + FP} \quad (20)$$

$$Recall = \frac{TP}{TP + FN} \quad (21)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (22)$$

式中:FP 和 FN 分别表示假阳性和假阴性的数量,TP 和 TN 分别表示真阳性和真阴性的数量。

表 2 显示了该模型在测试集上测试的精度、召回率和 F1 分数。除故障 F0、F8 和 F16 之外,模型对 16 种故障状态的各项指标均超过了 95%,展现出模型良好的分类能力。

表 2 模型的故障诊断结果

Table 2 The fault diagnosis results of model

标签	精度/召回率/ F1-分数/%	标签	精度/召回率/ F1-分数/%
0	76/74/75	10	100/100/100
1	100/100/100	11	100/100/100
2	100/100/100	12	100/100/100
3	100/95/98	13	100/100/100
4	100/98/99	15	100/100/100
5	100/100/100	16	94/72/82
6	100/100/100	17	100/100/100
7	98/100/99	18	100/100/100
8	80/100/89	19	96/100/98
9	100/100/100	平均准确率	96.82

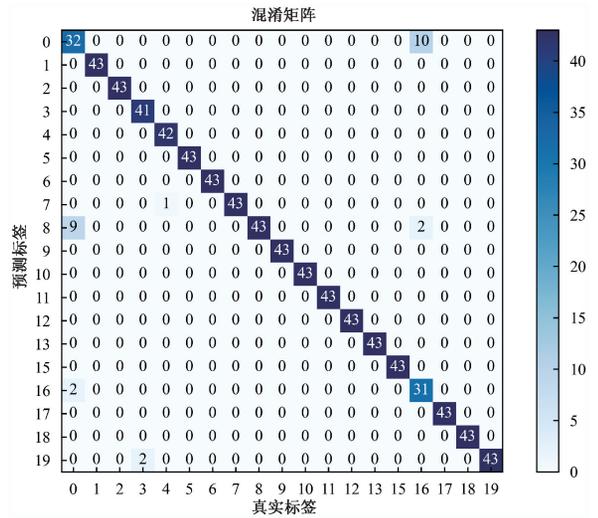


图 6 测试集混淆矩阵

Fig. 6 Confusion matrix of test set

### 2) 模型分类效果可视化

仅仅根据模型的输出评估其性能是不符合逻辑的,也是不科学的。为了进一步验证模型分类的有效性,本文采用 t-分布随机近邻嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 方法对原始数据、特征提取模块、特征融合模块、LSTM 层和分类层的输出特征可视化,如图 7 所示。可以看出,直接从原始数据中区分 19 种不同的状态信号是不可行的。但是,随着网络的深入,样本之间逐渐清晰。特征提取模块不同核的特征提取通道对信号的提取效果也不相同,但均使信号之间有了一定的区分度。样本经过特征融合模块之后,其可区分度是明显好于特征提取模块输出的,样本之间的距离也进一步扩大,证明了自适应特征融合模块对故障特征挖掘的贡献。LSTM 对特征识别的优势,使一些不易区分的样本实现可分。最后,分类层对所有故障信号进行了有效分类,分类结果显著。图 6 混淆矩阵显示的模型对 F0、F8 和 F16 的误分类情况在图 7(f) 中得到了验证,可以看出少量信号互相重叠,不易分离。分类效果随着网络深入逐渐明显,证实了模型分类结果的可靠性和网络结构的合理性。

### 3) 不同模型对比实验

通过以上综合分析,验证了该模型对气动控制阀故障诊断的有效性。为了证明所开发模型的优势,本文在 DAMADICS 基准平台上分别与典型的单尺度特征提取网络模型和近 3 年主流的多尺度特征融合网络模型进行了对比测试。

单尺度特征提取网络:LSTM 是一种优化的循环神经网络模型,对时域信号特征具有很好的捕捉能力;CNN 可以学习周期信号的局部和全局特征,对故障特征具有

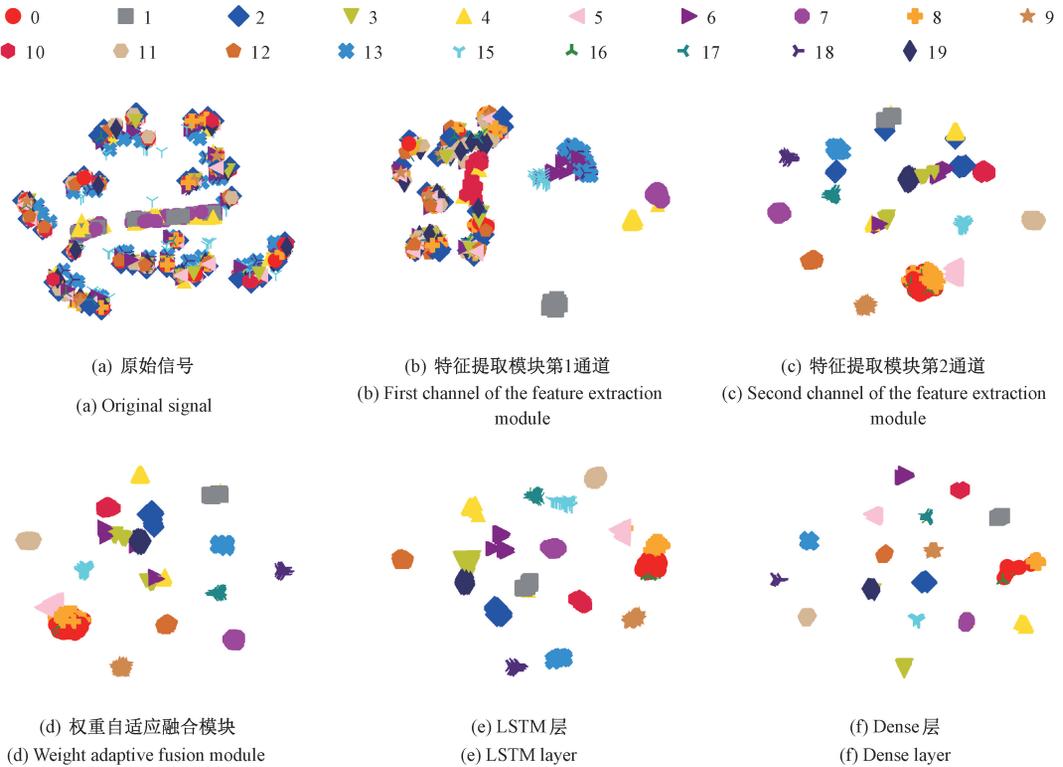


图 7 不同层输出特征可视化

Fig. 7 Visualization of the output features of the different layer

较强的特征表征能力,本文构建的 CNN 模型是开发的 MSFAFN 模型的一个分支;LeNet5 是一种典型的单尺度特征提取网络模型,对分类任务具有很好的效果。

多尺度特征融合网络: Add 是一种典型的特征融合方法,通过对两组特征逐元素相加,经线性变换后实现故障识别,实验中使用 Add 替换 WAFFN 融合网络;Cat (concatenation) 通过将两组特征线性连接后作为融合特征,这种融合方式极大保留了原始特征信息,实验中使用 Cat 替换 WAFFN 融合网络;Dot 是通过计算两组特征的点积,引入非线性变换,实现特征融合,实验中使用 Dot 替换 WAFFN 融合网络;MSCNN-BILSTM<sup>[22]</sup> 结合了多尺度卷积神经网络和双向长短时记忆网络的优势,实现了轴承的多尺度特征融合;SA-MCNN<sup>[23]</sup> 是一种融合了自注意力机制的多尺度特征融合模型,能够有效捕捉信号的状态特征,对轴承的故障诊断具有显著优势;MSD-CNN<sup>[24]</sup> 是一种多尺度深度卷积神经网络模型,通过多尺度级联卷积核提取故障信号的多尺度信息,然后使用 Cat 对多尺度信息连接实现特征融合;MSC-MpResCNN<sup>[25]</sup> 通过在输入层和中间层之间嵌入多尺度级联中点残差块,提升了网络的特征提取能力。

实验结果如表 3 所示,可以发现,多尺度特征融合网络模型的诊断效果明显好于单尺度特征提取网络模型。本文开发的 MSFAFN 模型的平均检测准确率达到

表 3 不同模型实验结果对比

Table 3 Comparison of experimental results with different models

模型	编号	精度 /%	召回率 /%	F1-分数 /%	准确率 /%
LSTM	A	74.20	74.50	74.10	74.50
CNN	B	87.30	87.50	85.90	87.50
LeNet5	C	89.66	89.70	88.11	89.70
Add	D	93.53	93.63	92.88	93.63
Cat	E	94.29	94.36	94.32	94.36
Dot	F	92.32	92.77	92.48	92.77
MSCNN-BILSTM	G	91.33	90.04	88.75	90.04
SA-MCNN	H	86.63	89.75	84.17	89.75
MSD-CNN	I	93.81	90.41	89.08	90.41
MSC-MpResCNN	J	91.61	91.43	91.06	91.43
本文模型	K	<b>97.00</b>	<b>96.82</b>	<b>96.76</b>	<b>96.82</b>

96.82%, 相比于 Add、Cat、Dot、MSCNN-BILSTM、SA-MCNN、MSD-CNN 和 MSC-MpResCNN 多尺度特征融合网络模型分别高出 3.19%、2.46%、4.05%、6.78%、7.07%、6.41% 和 5.39%。实验结果表明,本文开发的 MSFAFN

模型相较于其他网络模型在特征提取能力和特征融合效果上有一定优势。

#### 4) 文献方法检测结果对比

为了全面验证模型的有效性,还将本文方法与最近文献中同样基于 DAMADICS 基准平台研究的方法检测结果进行了对比,如表 4 所示。文献[3]可以检测 14 种故障,并且对 12 种故障的诊断准确率超过 99%。文献[6]对 9 种中等强度的突变故障检测性能较好。文献[7]检测了所有的故障类型,但对 F4 和 F13 的检测精度极低,只有 8 种故障的检测精度超过了 90%。文献[9]分别根据  $T^2$  统计量和平方预测误差 (square prediction error, SPE) 来判断是否发生故障,表中选择

列出了两种方法中检测精度较高的结果,可检测到 10 种故障。文献[8]和[10]虽然实现了 100% 的检测准确率,但检测的故障类型较少。文献[11]实现了对 8 种故障的在线检测。文献[12]对 13 种故障的检测准确率超过 95%。文献[13]只检测了阀体故障。文献[15]只进行了一些突发性故障的研究。文献[26]提出了一种多元统计学方法对 6 种早期故障进行了识别,表现出较好的故障识别能力。而本文所提出的 MSFAFN 模型的平均检测精度为 96.82%,对 16 种故障的诊断精度超过 98%。结果表明,该方法在可检测的故障数量和检测精度方面均优于其他文献中提出的方法。

表 4 文献中检测气动控制阀故障的方法对比

Table 4 Comparison of fault detection methods for pneumatic control valve in the literatures

故障类别	文献[3]	文献[6]	文献[7]	文献[8]	文献[9]	文献[10]	文献[11]	文献[12]	文献[13]	文献[15]	文献[26]	本文方法
F0	-	-	-	-	-	-	100	-	-	98.5	-	74
F1	100	100	92.01	-	77.06	-	-	100	100	97.5	97.38	100
F2	100	100	83.33	-	100	100	-	100	97.6	-	95.50	100
F3	-	90	36.63	-	2.41	-	-	93	100	-	-	95
F4	86.21	0	0	-	1.27	-	-	55	99.4	-	-	98
F5	-	82	72.28	-	2.28	-	-	60	99.1	-	-	100
F6	31.96	88	73.27	100	2.34	-	-	96	99.3	-	-	100
F7	100	98	100	-	100	100	99.17	99	99.0	99.5	100	100
F8	-	0	93.33	-	2.41	-	-	-	-	-	-	100
F9	-	0	91.3	100	2.34	-	-	19	-	-	-	100
F10	100	89	91.67	-	59.44	100	-	100	-	-	-	100
F11	100	100	89.74	100	6.97	100	-	99	-	-	20.50	100
F12	99.63	0	93.02	-	1.71	-	99.58	95	-	99.5	-	100
F13	100	86	0.09	100	77.06	100	-	100	-	-	-	100
F14	-	0	80.76	-	2.41	-	-	-	-	-	-	-
F15	100	90	68.63	-	98.80	-	97.17	99	-	97.0	98.75	100
F16	100	85	83.52	-	53.74	-	97.25	99	-	-	-	72
F17	99.71	95	83.93	100	100	100	92.33	99	-	-	92.25	100
F18	100	100	93.65	100	76.68	100	100	100	-	-	-	100
F19	100	100	97.16	-	75.29	100	96.83	100	-	99.0	-	100
可检测故障数	12	9	9	6	4	8	8	14	7	6	5	17

#### 5) 模型复杂度分析

本文从空间复杂度和时间复杂度方面对 MSFAFN 模型进行了对比分析,说明模型在浮点运算量 (Flops)、参数量和检测性能之间的权衡。将 MSFAFN 模型与 Add、Cat、Dot、MSCNN-BILSTM、SA-MCNN、MSD-CNN 和 MSC-MpResCNN 模型进行了参数量、浮点运算量和检

测性能的对比,对比结果如表 5 所示。图 8 为各模型参数量和检测性能的对应关系,从表 5 和图 8 可以看出,MSFAFN 模型的参数量为最低的 0.02 M,浮点运算量为 88.22 M,略高于 Cat、Add、MSCNN-BILSTM 和 LeNet5 网络模型,但准确率显著高于所有对比模型。相较于目前主流的多尺度特征融合模型,本文模型在较少参

数量和浮点运算量的条件下提升了检测准确率,在检测准确率、浮点运算量和参数量之间做出了较好的权衡。同时也说明模型相对轻量化,更易实现在边缘设备上的部署任务。

表 5 模型复杂度对比

Table 5 Model complexity comparison

模型	参数量/M	浮点运算量/M	准确率/%
LeNet5	0.498	50.26	89.70
Add	0.020	88.20	93.63
Cat	0.021	88.19	94.36
Dot	0.021	88.33	92.77
MSCNN-BILSTM	0.040	27.04	90.04
SA-MCNN	0.100	1 214.16	89.75
MSD-CNN	0.124	155.30	90.41
MSC-MpResCNN	0.098	172.80	91.43
本文模型	0.020	88.22	96.82

精度、召回率、F1-分数和准确率方面都有显著提升。具体来说,以准确率对比为例,加入 S-CPA 注意力机制比加入 CBAM 注意力机制高 1.92%,比不加入任何注意力机制高 2.08%,说明加入 S-CPA 注意力机制比加入 CBAM 注意力机制对模型特征提取能力的提升更加有效;而使用 WAFFN 融合网络比不使用高出 1.10%,说明自适应加权融合方法对模型的特征表征能力也有一定提升;最后同时加入 S-CPA 注意力机制和 WAFFN 融合网络比单独使用分别高出 0.74%和 1.72%。两者同时使用的效果显著优于其他组合效果,说明了本文方法对故障特征提取的优势和模型设计的合理性。

表 6 消融实验结果对比

Table 6 Comparison of ablation experiment results

方式		模型	精度 /%	召回率 /%	F1-分数 /%	准确率 /%	
CBAM	S-CPA						WAFFN
×	×	×	a	93.77	94.00	93.43	94.00
√	×	×	b	93.97	94.16	93.97	94.16
×	√	×	c	96.07	96.08	95.96	96.08
×	×	√	d	95.09	95.10	94.78	95.10
×	√	√	e	<b>97.00</b>	<b>96.82</b>	<b>96.76</b>	<b>96.82</b>

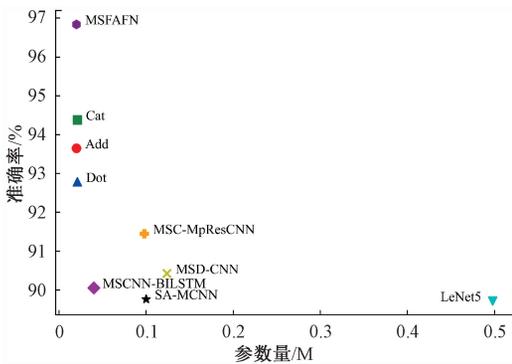


图 8 不同模型检测准确率与参数量之间的对应关系

Fig. 8 The correspondence between the accuracy and parameters of different models

3.4 消融实验

为了证明 S-CPA 和 WAFFN 对模型特征提取能力的影响,通过替换网络或删减网络的方法对模型进行消融实验。

模型 a 表示未加入空间-通道并联自注意力机制和权重自适应特征融合网络;模型 b 表示加入 CBAM 注意力机制,未进行权重自适应特征融合;模型 c 表示加入空间-通道并联自注意力机制,未进行权重自适应特征融合;模型 d 表示未加入空间-通道并联自注意力机制,进行权重自适应特征融合;模型 e 表示加入空间-通道并联自注意力机制,并进行自适应特征融合;不同模块组合的对比结果如表 6 所示,可以看出,在加入 S-CPA 注意力机制和 WAFFN 融合网络后,模型在检测

3.5 噪声实验

为了验证模型在噪声干扰环境下的检测性能,本文通过对原始信号叠加高斯白噪声和 50 Hz 正弦波,并将噪声幅度设置为信号标称范围的 2.5%,有效模拟了工业环境下的噪声干扰和传感器误差。

图 9 显示了不同模型在理想环境和噪声环境下的平均检测精度。横坐标表示模型类别,与表 3 的编号对应,纵坐标表示检测准确率。与理想环境相比,所有模型在噪声环境下的平均检测精度都有所下降,但 MSFAFN 模型的检测精度仍达到了 93.39%,而其他对比模型均未超过 90%。此外,相较于理想环境,MSFAFN 模型检测精度下降了 3.43%,而其他模型的

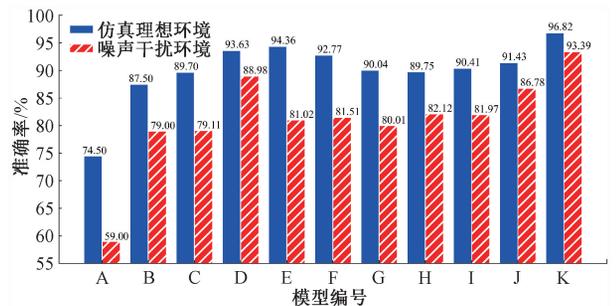


图 9 不同模型在模拟的实际工业环境中的平均检测精度  
Fig. 9 Average detection accuracy of different models in the simulated realistic industrial environment

检测精度降幅至少为 4.65%，说明本文开发的 MSFAFN 模型具有较好的抗噪性能。平均检测精度下降主要是因为加入噪声以后，噪声信号会掩盖一些特征，导致信号重叠，故障特征不易挖掘，进而发生误判的情况。从结果对比可以看出，本文开发的 MSFAFN 模型在噪声环境中表现出较好的鲁棒性。

### 3.6 模型实验验证

本文在某企业流体控制实验室进行了模型验证。如图 10 所示，为控制阀故障模拟实验平台，该平台包括 ATS 控制阀、压缩泵、管道、背压阀等，选用标准 S1 型超声波传感器和频率范围 1~1 000 Hz 微波感知传感器测量同一时间段的管道流量和阀杆位移信号。本文总共模拟了控制阀 6 种典型故障，分别为阀门堵塞 F1、摩擦增加 F4、阀门外漏 F5、膜片穿孔 F10、定位器反馈故障 F15 和流量传感器故障 F19，以及正常状态 F0。

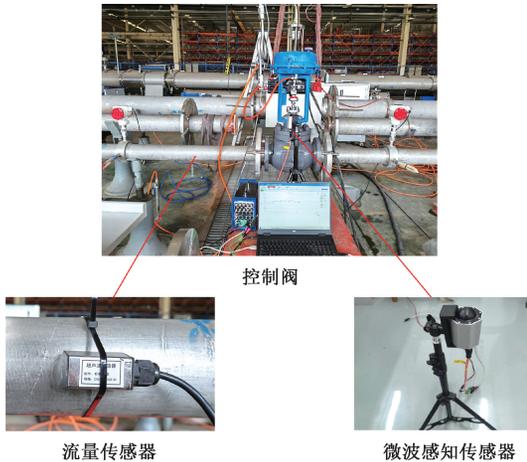


图 10 控制阀故障模拟实验平台

Fig. 10 Control valve fault simulation experiment platform

表 7 显示了 MSFAFN 模型在实验环境下对控制阀的故障检测结果。相较仿真环境，模型的检测效果有所下降，对正常状态的检测准确率较低，主要是由于实

表 7 实验检测结果

Table 7 Experimental test results %

故障标签	精度	召回率	F1-分数	准确率
F0	100.0	60.0	75.0	60.0
F1	100.0	76.0	86.4	76.0
F4	85.2	79.3	88.5	79.3
F5	100.0	92.0	95.8	92.0
F10	100.0	80.0	88.9	80.0
F15	100.0	88.0	93.6	88.0
F19	91.3	77.8	87.5	77.8
平均值	96.6	79.0	87.9	79.0

验环境中复杂噪声干扰导致模型误判。但模型的平均检测准确率达到 79.0%，平均 F1-分数为 87.9%，基本满足实际工业要求。

## 4 结 论

为了在真实故障数据不足的情况下实现对气动控制阀精确的故障诊断，本文提出了一种基于多尺度特征自适应融合网络的气动控制阀故障诊断方法。通过设计融合自注意力机制的多尺度特征提取网络和权重自适应特征融合网络，显著提升了模型的故障特征表征能力，从而提高了故障诊断准确率。试验结果表明，该模型在 DAMADICS 阀门基准平台的平均检测精度可达 96.82%，较其他深度学习模型至少提升了 2.46%；同时与其他文献方法的测试结果对比，本文方法可诊断的故障数量和诊断准确率都有明显优势；该模型在噪声环境下的平均检测精度可达 93.39%，较理想环境下降了 3.43%，而其他模型的降幅至少为 4.65%，说明了本文的 MSFAFN 模型具有较好的鲁棒性；此外，通过实验验证说明模型基本满足气动控制阀的故障诊断要求。由于真实故障数据有限，本文提出的方法在 DAMADICS 阀门基准模拟平台和典型工业环境下取得了较为理想的表现，后续研究将聚焦于在复杂工业环境下提升模型的故障检测性能和模型对不同阀门的泛化能力。

### 参考文献

- [1] 马玉山,相海军,傅卫平,等. 调节阀阀芯变开度振动分析[J]. 仪器仪表学报,2007(6):1087-1092.  
MA Y SH, XIANG H J, FU W P, et al. Analysis of core vibration of regulating valve in regulation process[J]. Chinese Journal of Scientific Instrument, 2007(6):1087-1092.
- [2] HÄGGLUND T. A friction compensator for pneumatic control valves[J]. Journal of Process Control, 2002, 12(8): 897-904.
- [3] HAN X, JIANG J, XU A, et al. Fault detection of pneumatic control valves based on canonical variate analysis[J]. IEEE Sensors Journal, 2021, 21(12): 13603-13615.
- [4] MANNINEN T. Fault simulator and detection for a process control valve[D]. Aalto University School of Engineering; Department of Engineering Design and Production, 2012.
- [5] PUIG V, STANCU A, ESCOBET T, et al. Passive

- robust fault detection using interval observers: Application to the DAMADICS benchmark problem[J]. *Control Engineering Practice*, 2006, 14(6): 621-633.
- [6] 薄翠梅,李俊,张广明,等.自适应阈值故障检测方法在 DAMADICS 基准平台中的应用[J]. *计算机集成制造系统*,2010,16(6):1279-1285.
- BO C M, LI J, ZHANG G M, et al. Application of fault detection based on adaptive threshold in the DAMADICS benchmark problem [J]. *Computer Integrated Manufacturing Systems*,2010,16(6):1279-1285.
- [7] BEZERRA C G, COSTA B S J, GUEDES L A, et al. An evolving approach to unsupervised and real-time fault detection in industrial processes[J]. *Expert Systems with Applications*, 2016, 63: 134-144.
- [8] D'ANGELO M F S V, PALHARES R M, TAKAHASHI R H C, et al. Fuzzy/Bayesian change point detection approach to incipient fault detection[J]. *IET Control Theory & Applications*, 2011, 5(4): 539-551.
- [9] MA L, LI X, LEI C, et al. Process monitoring of the pneumatic control valve using canonical variate analysis[C]. 2017 Chinese Automation Congress (CAC), IEEE, 2017: 2784-2788.
- [10] CALADO J M F, DA COSTA J M G S, BARTYS M, et al. FDI approach to the DAMADICS benchmark problem based on qualitative reasoning coupled with fuzzy neural networks [J]. *Control Engineering Practice*, 2006, 14(6): 685-698.
- [11] RODRÍGUEZ R A, NETO S D J A, LLANES-SANTIAGO O. An approach to fault diagnosis with online detection of novel faults using fuzzy clustering tools[J]. *Expert Systems with Applications*, 2018, 113: 200-212.
- [12] PRZYSTAŁKA P, MOCZULSKI W. Methodology of neural modelling in fault detection with the use of chaos engineering[J]. *Engineering Applications of Artificial Intelligence*, 2015, 41: 25-40.
- [13] KOWSALYA A, KANNAPIRAN B. Principal component analysis based approach for fault diagnosis in pneumatic valve using DAMADICS benchmark simulator [J]. *Special Issue-07, IJRET: International Journal of Research in Engineering and Technology*, 2014(May): 702-707.
- [14] ANDRADE A, LOPES K, LIMA B, et al. Development of a methodology using artificial neural network in the detection and diagnosis of faults for pneumatic control valves[J]. *Sensors*, 2021, 21(3): 853.
- [15] ORTIZ ORTIZ F J, RODRÍGUEZ-RAMOS A, LLANES-SANTIAGO O. A robust fault diagnosis method in presence of noise and missing information for industrial plants [C]. *Pattern Recognition: 14th Mexican Conference, MCPR 2022, Ciudad Juárez, Mexico, June 22-25, 2022, Proceedings*. Cham: Springer International Publishing, 2022: 35-45.
- [16] 雷春丽,夏奔锋,薛林林,等.小样本下自校正卷积神经网络滚动轴承故障识别方法[J]. *仪器仪表学报*,2022,43(9):122-130.
- LEI CH L, XIA B F, XUE L L, et al. Fault identification for rolling bearing by self-calibrated convolutional neural network under small samples conditions [J]. *Chinese Journal of Scientific Instrument*,2022,43(9): 122-130.
- [17] 魏玮,吕游,齐欣宇,等.基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法[J]. *仪器仪表学报*,2023,44(4):19-27.
- WEI W, LYU Y, QI X Y, et al. State prediction method for power plant fans based on the CNN-LSTM-AM dynamic integrated model [J]. *Chinese Journal of Scientific Instrument*, 2023,44(4):19-27.
- [18] LIU H, LIU F, FAN X, et al. Polarized self-attention: Towards high-quality pixel-wise regression[J]. *ArXiv Preprint*, 2021, ArXiv:2107.00782.
- [19] 张加劲.基于注意力机制和 CNN-BiLSTM 模型的航空发动机剩余寿命预测[J]. *电子测量与仪器学报*, 2022,36(8):231-237.
- ZHANG J J. Remaining useful life estimation of aeroengine based on CNN-BiLSTM and attention mechanism[J]. *Journal of Electronic Measurement and Instrumentation*, 2022,36(8):231-237.
- [20] BARTYS M, PATTON R, SYFERT M, et al. Introduction to the DAMADICS actuator FDI benchmark study [J]. *Control Engineering Practice*, 2006, 14(6): 577-596.
- [21] XU Y, YANG L. Based on improved CNN bearing fault detection [C]. *Journal of Physics: Conference Series*,

IOP Publishing, 2022, 2171(1): 012073.

- [22] 谢扬筱, 王国强, 石念峰, 等. 融合注意力机制的 MSCNN-BiLSTM 滚动轴承故障诊断方法[J]. 轴承, 2023;1-9.

XIE Y X, WANG G Q, SHI N F, et al. Rolling bearing fault diagnosis method using MSCNN-BiLSTM with attention mechanism[J]. Bearing, 2023;1-9.

- [23] 黄雅静, 廖爱华, 丁亚琦, 等. 多尺度 CNN 结合自注意力特征融合机制的轴承故障诊断方法[J]. 智能计算机与应用, 2022, 12(9): 37-44.

HUANG Y J, LIAO AI H, DING Y Q, et al. Bearing fault diagnosis based on multi-scale convolutional neural network and self-attention feature fusion mechanism[J]. Intelligent Computer and Applications, 2022, 12(9): 37-44.

- [24] SHAO Z, LI W, XIANG H, et al. Fault diagnosis method and application based on multi-scale neural network and data enhancement for strong noise [J]. Journal of Vibration Engineering & Technologies, 2023: 1-14.

- [25] CHAO Z, HAN T. A novel convolutional neural network with multiscale cascade midpoint residual for fault diagnosis of rolling bearings[J]. Neurocomputing, 2022, 506: 213-227.

- [26] ZHANG C, YI H, LI Y. A novel incipient fault detection and diagnosis scheme based on kernel density weighting support vector data description: Application on the

DAMADICS benchmark process[J]. Journal of Chemical Engineering of Japan, 2023, 56(1): 2204129.

## 作者简介



**郝洪涛** (通信作者), 1998 年于北京化工大学获得学士学位, 分别于 2006 年和 2016 年于上海交通大学获得硕士和博士学位, 现为宁夏大学教授, 主要研究方向为机电设备智能运维与故障诊断。

E-mail: haoht\_03@126.com

**Hao Hongtao** (Corresponding author) received his B. Sc. degree from Beijing University of Chemical Technology in 1998, M. Sc. degree and Ph. D. degree both from Shanghai Jiao Tong University in 2006 and 2016, respectively. He is currently a professor at Ningxia University. His main research interests include intelligent operation and maintenance and fault diagnosis of electromechanical equipment.



**王凯**, 2021 年于合肥工业大学获得学士学位, 现为宁夏大学硕士研究生, 主要研究方向为机械设备故障诊断和深度学习。

E-mail: hfutkk@163.com

**Wang Kai** received his B. Sc. degree from Hefei University of Technology in 2021. He is currently pursuing the master's degree at Ningxia University. His main research interests include mechanical equipment fault diagnosis and deep learning.